



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM RECURSOS NATURAIS**



JOHN ELTON DE BRITO LEITE CUNHA

**Monitoramento ambiental por sensoriamento remoto: avaliação,
automação e aplicação ao bioma Caatinga utilizando séries
históricas Landsat**

Campina Grande
2018

JOHN ELTON DE BRITO LEITE CUNHA

Monitoramento ambiental por sensoriamento remoto:
avaliação, automação e aplicação ao bioma Caatinga utilizando
séries históricas Landsat

Tese de doutorado apresentada à Universidade Federal de Campina Grande (UFCG), como parte das exigências do Programa de Pós-Graduação em Recursos Naturais, para obtenção do título de Doutor.

Área de concentração: Sociedade e Recursos Naturais

Orientadores: Carlos de Oliveira Galvão (UFCG)
Fernanda Valente (Instituto Superior de Agronomia,
Universidade de Lisboa)

JOHN ELTON DE BRITO LEITE CUNHA

“MONITORAMENTO AMBIENTAL POR SENSORIAMENTO REMOTO:
AVALIAÇÃO, AUTOMAÇÃO E APLICAÇÃO AO BIOMA CAATINGA UTILIZANDO
SÉRIES HISTÓRICAS LANDSAT”

BANCA EXAMINADORA

Prof. Dr. CARLOS DE OLIVEIRA GALVÃO

Universidade Federal de Campina Grande – UFCG

Prof^a. Dra. FERNANDA MARIA DOS REIS TORROAES VALENTE

Universidade de Lisboa, Instituto Superior de Agronomia – UL-ISA

Prof. Dr. BERNARDO BARBOSA DA SILVA

Universidade Federal de Campina Grande – UFCG

Prof. Dr. SÉRGIO MURILO SANTOS DE ARAÚJO

Universidade Federal de Campina Grande – UFCG

Prof. Dr. JOSÉ CARLOS DE ARAÚJO

Universidade Federal do Ceará – UFC

Prof. Dr. BARTOLOMEU ISRAEL DE SOUZA

Universidade Federal da Paraíba

A Deus, criador de todas as coisas
Aos meus pais,
minha esposa,
meus avós e
mestres,
dedico

AGRADECIMENTOS

Primeiramente, a Deus por estar sempre guiando os meus caminhos e protegendo a minha mente.

À minha esposa Tatiane, por toda paciência, amor e companheirismo.

Aos meus pais, pelo o apoio aos estudos.

Aos meus avós, pela amizade e confiança sempre depositada.

Externo minha gratidão e admiração ao meu orientador, Professor Carlos Galvão, por todas as oportunidades e desafios apresentados.

À minha orientadora Fernanda Valente, que sempre me acolhe de forma muito simpática no Instituto Superior de Agronomia. Obrigado por toda dedicação as nossas atividades de pesquisa, por ser exemplo de profissional.

À colega Iana Rufino, minha primeira orientadora, por sempre acreditar e incentivar o meu trabalho.

Ao prof. Dr. Bernardo Barbosa da Silva por ter contribuído de forma significativa na minha formação acadêmica.

Aos Professores Dr. José Carlos de Araújo, Dr. Bartolomeu de Souza, Dr. Sérgio Murilo de Araújo pela dedicação e contribuição na análise desta tese.

Ao projeto de EU BRAZIL Cloud Connect pelo o apoio financeiro para realização do intercâmbio e desenvolvimento desta pesquisa.

Aos professores Manuel Campagnolo e Isabel Ferreira e aos pesquisadores Nuno Conceição e Filipe Costa e Silva pela disponibilização de dados.

Aos meus colegas e alunos do Laboratório Hidráulica II que contribuíram de maneira direta ou indireta na elaboração deste trabalho.

À minha turma de doutorado, formada por pessoas que admiro bastante por toda capacidade técnica e dedicação aos estudos.

À CAPES, pela bolsa de doutorado sanduíche.

À Universidade Federal de Campina Grande, por conceder afastamento das minhas atividades docentes para realização do doutorado e por todo apoio técnico no desenvolvimento desta tese.

*“Para chegar onde quer que seja, aprendi que não é preciso dominar a força, mas
a razão”
(Amyr Klink)*

RESUMO

O baixo monitoramento e altas pressões climáticas e antrópicas fazem do bioma Caatinga, semiárido brasileiro, um dos mais vulneráveis do mundo. Séries temporais de sensoriamento remoto são valiosas para analisar as LCC em áreas com alta sazonalidade, mas demandam muitos recursos computacionais. Estudos anteriores utilizam séries temporais superiores a 30 anos de índices de vegetação com baixa resolução espacial (1 a 8 km). No entanto, esta resolução espacial geralmente não permite identificar ações humanas (impactos) no meio ambiente. Nos últimos anos, houve melhorias na qualidade da imagem do Landsat (radiométrica e geométrica) e agora estão prontas para suportar o monitoramento e análise dos processos na superfície terrestre. O objetivo deste estudo é analisar, a partir de sensores de média resolução espacial, as alterações na cobertura do solo de origem antrópica numa área do bioma Caatinga. Para este fim, utilizou-se algoritmos para gerar índices de vegetação, albedo de superfície e evapotranspiração a partir de dados dos sensores a bordo dos satélites da família Landsat. Para aumentar a eficiência na geração dessas informações, os algoritmos foram conduzidos para operar com baixa demanda por dados de estações meteorológicas e sem intervenção humana durante o processamento. Além disso, um serviço de alto desempenho para processamento de dados orbitais é proposto. Os dados gerados por estes algoritmos foram testados com a informações de campo, demonstrando a possibilidade de utilizar os algoritmos em processos automáticos. As técnicas de computação em nuvem e paralelização utilizadas neste estudo foram eficientes na produção de séries temporais superiores a 30 anos de variáveis em média resolução espacial. A principal aplicação desenvolvida neste trabalho utilizou séries temporais do Landsat por um período de 31 anos em resolução temporal mensal, a fim de investigar os padrões espaciais e temporais da mudança de cobertura do solo em uma área de Caatinga, semiárido do estado da Paraíba, no Brasil. Um novo índice espectral - Índice Surface Albedo (SAI) - é proposto para melhorar a observação da condição biofísica da vegetação. Os índices NDVI, EVI e SAI foram utilizados para avaliar o monitoramento das LCC impulsionadas por ações humanas em contraste a alteração induzida pelo clima. Séries temporais dos índices foram aplicados ao método TSS RESTREND para monitoramento das LCC. O método é empregado para remover as influências a curto prazo da precipitação na fisionomia da cobertura do solo, permitindo assim avaliar a capacidade dos índices utilizados para discriminar alterações nas regiões semiáridas. Google Earth, imagens RapidEye e observações *in situ* (a partir de outubro de 2017) foram usadas para observar condições de preservação/degradação ao longo do tempo. Os resultados mostram que o índice SAI é capaz de distinguir entre cobertura do solo "alterada" e "inalterada" com uma alta acurácia, 87%, para detectar corretamente o ano da LCC. Quando utilizado o índice SAI, o TSS RESTREND demonstrou-se adequado para detectar LCC na Caatinga, e seu melhor desempenho foi alcançado quando o evento de mudança ocorre na região central da série temporal (1990-2010), com algumas imprecisões em anos secos. O menor desempenho dos índices EVI e NDVI na detecção das LCC no bioma da Caatinga é explicado pela sua alta sensibilidade às variações da cobertura de folhas, como resultado de condições sazonais ou extremas de seca. O LCC afeta todo o sistema solo-planta-atmosfera, como remoção de biomassa e mudanças nas propriedades do solo, bem como no microclima, devido à exposição direta à radiação, precipitação e vento. A este respeito, a SAI é suposto ser mais sensível às alterações artificiais na superfície terrestre, devido à sua capacidade de capturar uma maior quantidade de feedback ambiental.

ABSTRACT

Low monitoring plus high human and climate pressures make the Caatinga biome one of the most vulnerable biomes in the world. Time series of remote sensing are valuable for analyzing LCC in areas with high seasonality, but they require a lot of computational resources. Earlier studies mostly use > 30- years time series of vegetation indexes at low spatial resolution (1 to 8 km). However, this spatial resolution usually does not allow to identify human actions (impacts) on the environment. Landsat imagery quality (radiometrically as well as geometrically) and availability has improved in recent years and is now ready to support high temporal resolution monitoring and analysis of land surface processes. The objective of this study is to analyze, from sensors of medium spatial resolution, the changes in land cover of anthropic origin in an area of the Caatinga biome. For this purpose, algorithms were used to generate vegetation indices, surface albedo and evapotranspiration from sensor data on the satellites of the Landsat family. To increase the efficiency in generating this information, the algorithms were conducted to operate with low demand for meteorological station data and without human intervention during processing. In addition, a high performance service for orbital data processing is proposed. The data generated by these algorithms were tested to field observations, demonstrating the possibility of using these algorithms in automatic processes. The techniques of cloud computing and parallelization used in this study were efficient in producing long time series (over 30 years) of these variables in average spatial resolution. The main application developed in this work, used Landsat time series for a period of 31 years at monthly resolution in order to investigate spatial and temporal patterns of hotspots of land cover change in a Caatinga area of the semi-arid region of the Paraíba state, Brazil. A new spectral index – Surface Albedo Index (SAI) – is proposed to improve the observation of vegetation biophysical condition and change. SAI, NDVI and EVI are compared in order to evaluate the suitability of monitoring LCC driven by human actions in contrast to climate induced (drought) alteration. The TSS RESTREND method was successfully applied to Landsat time series for LCC monitoring. It is employed in order to remove the short-term influences of precipitation on land cover physiognomy, thus allowing to assess the ability of the index time series to discriminate LCC in drylands. Google Earth, Rapid Eye images and *in situ* observations (from October 2017) were used to observe preservation / degradation conditions along the time. Results show that SAI is able to distinguish between “changed” and “unchanged” land cover with a high accuracy (87%) to detect the year of change. When using the SAI index, TSS RESTREND is suitable to detect LCC in the Caatinga, and its best performance was achieved when the change event occurred in the middle of the time series (1990–2010), with some inaccuracies in dry years. The lower ability of EVI and NDVI in the detection of LCC in the Caatinga biome is explained by their high sensitivity to leaf cover variations (as a result of seasonal or extreme drought conditions). LCC impacts the whole soil-plant-atmosphere system, such as biomass removal and changes in soil properties as well as microclimate, due to the direct exposure to radiation, precipitation, and wind. In this regard, SAI is supposed to be more sensitive to man-made alterations of the land surface, due to its ability to capture a higher number of environmental feedbacks.

LISTA DE FIGURAS

Figura 1- Localização das três áreas experimentais	24
Figura 2- Descrição das etapas metodológicas.....	26
Figura 3 - Ilustração da área de contribuição projetada sobre um grid Landsat a partir do ângulo de visão do radiômetro instalado (h metros da superfície)	32
Figura 4- Valores observados e modelados de saldo de radiação diário para os dois conjuntos de dados Landsat.....	36
Figura 5 - Albedo de superfície para os dois conjuntos de dados Landsat e MODIS.....	38
Figura 6 - Valores de ET modelados (y - vertical) e observados (x - horizontal) para o teste 1 (A), teste 2 (B), teste 3 (C), teste 4 (D), teste 5 (E) e melhores resultados (F)	49
Figura 7- Componentes do sistema SAPS.....	58
Figura 8 - Estado das tarefas de trabalho	59
Figura 9 - Taxas evapotranspirativas para dez classes de cobertura dos solos na região do bioma Caatinga	64
Figura 10 - Localização do bioma Caatinga, cena Landsat utilizada e área de estudo (Xmin: -37,07; Xmax: -36,84; Ymin: -7,86; Ymax: -7,74) em (A), Imagem de 07/10/1984 representando a situação inicial estudada (B) e Imagem de 27/09/2015 representando	71
Figura 11 - SPEI e a precipitação para as coordenadas geográficas x:-36,75, y:-7,75	71
Figura 13 - Resposta do TSS-RESTREND para o pixel nas coordenadas geográficas -36.85912, -7.84013. A) identificação do ponto de ruptura do BFAST; Yt é índice VPR-residual, Tt é o componente de tendência e et é o BFAST residual; e B) Índice máximo anual vs. tempo	79
Figura 14 - Período observado e modelado, SAI, EVI e NDVI para áreas-alvo: A) Descrição e B) Classificação.....	80
Figura 15 - Período de LCC - TSS RESTREND para SAI, EVI e NDVI (A) e Imagens do Google Earth, sobrepostas aos Polígonos de LCC observado	81
Figura 16 - LCC observada nas diferentes parcelas da região selecionada, em comparação com os resultados obtidos com o método TSS RESTREND para os três índices estudados: A) porcentagem do número total de pixels em cada parcela onde LCC não foi detectado; B) mediana do ano em que foi detectada LCC.	82

Figura 17 - Séries temporais dos índices SAI, EVI e NDVI (A), período observado de LCC (B) e coeficiente de variação para cada um dos índices entre os nove polígonos LCC (C)	83
Figura 18 - Período de LCC quando utilizado o índice SAI no método TSS RESTREND para toda a área de estudo	84
Figura 19 - Comportamento da reflectância em diferentes faixas espectrais, NDVI e SA para Grama verde, Grama seca e solo seco	88

LISTA DE TABELAS

Tabela 1- Bandas espectrais para os sensores a bordo dos satélites Landsat.....	28
Tabela 2 - Coeficientes utilizados para o cálculo do albedo de superfície	28
Tabela 3 – Coeficientes (Equação 4) utilizados para o cálculo do albedo sem correção atmosférica (α TOA)	29
Tabela 4 - Descrição por área experimental (Exp.) de: número de imagens utilizadas, altura do radiômetro instalado nas torres, raio do footprint, área de contribuição em cada experimento (footprint) e número de pixels associado a cada observação.....	33
Tabela 5 - Descrição das imagens utilizadas na comparação entre albedo de superfície Landsat e MODIS	34
Tabela 6 - Descrição das imagens utilizadas no olival para os estudos de evapotranspiração.....	42
Tabela 7 - Descrição das etapas de seleção dos pixels de referência.....	45
Tabela 8 - Ordem do quantil utilizada para selecionar os pixels âncora na Etapa 2.....	46
Tabela 9 - Informação sobre os fatores que podem influenciar a evapotranspiração observada (ET Obs) e modelada (ET Mod)	51
Tabela 10 - Classes de cobertura do solo e sua localização geográfica.....	62

LISTA DE ABREVIATURAS E SIGLAS

API - *Application Programming Interface*
AVHRR - *Advanced Very High Resolution Radiometer*
BFAST - *Breaks For Additive Season and Trend*
BSA - *Black Sky Albedo*
CHIRPS - *Climate Hazards group Infrared Precipitation with Stations*
CIMEC - *Calibration Using Inverse Modeling at Extreme*
CNUC - *Cadastro Nacional de Unidades de Conservação*
CSI - *Consortium for Spatial Information*
CTS - *Complete Time Series*
DN - *Digital Number*
ETM+ - *Enhanced Thematic Mapper Plus*
ET_{r24h} - *Evapotranspiração real diária*
EVI - *Enhanced Vegetation Index*
FD - *Fração de luz difusa*
FOV - *Field of view*
G – *densidade de fluxo de calor no solo*
GEE - *Google Earth Engine*
GIMMS - *Global Inventory Modeling and Mapping Studies*
GIOVANNI - *Goddard earth sciences data and information services center - Interactive Online Visualization ANd aNalysis Infrastructure*
GUI - *Graphical User Interface*
H – *Densidade de fluxo de calor sensível*
LaSRC - *Surface Reflectance Code*
LCC - *Land Cover Change*
LE – *Densidade de fluxo de calor latente*
LEDAPS - *Ecosystem Disturbance Adaptive Processing System*
LST - *Land Surface Temperature*
MDE - *Modelo Digital de Elevação*
MERIS - *MEdium Resolution Imaging Spectrometer*
METRIC - *Mapping EvapoTranspiration at high Resolution with Internalized Calibration*
MMA - *Ministério do Meio Ambiente*
MODIS - *Moderate Resolution Imaging Spectroradiometer*
MVC - *Maximum-Value Composite*
NDVI – *Normalized Difference Vegetation Index*
NIR - *Near-Infrared*
NOAA - *National Oceanic and Atmospheric Administration*
OLI - *Operational Land Imager*

OPA- *Optimal Precipitation Accumulated*
RESTREND - *Residual Trend*
RMSE – *Root Mean Square Error*
Rn_{24h} – *Saldo de radiação diário*
SA – *Surface Albedo*
SAI – *Surface Albedo Index*
SAPS – *Sistema Automático de Processamento do SEBAL*
SEB - *Surface Energy Balance*
SEBAL - *Surface Energy Balance Algorithms for Land*
SKYL LUT - *Sky Light Look-Up Table*
SLS - *Scan Line Corrector*
SPEI - *Standardised Precipitation-Evapotranspiration Index*
SPOT - *Satellite Pour l'Observation de la Terre*
SR- *Surface Reflectance*
SRO – *Sensoriamento remoto orbital*
STSEB - *Simplified Two-Source Energy Balance*
SWIR - *Shortwave Infrared*
Ta – *Temperatura do ar*
TIRS - *Thermal Infrared Sensor*
TM - *Thematic Mapper*
TOA - *Top of Atmosphere*
TS- *Temperatura de Superfície*
TSS RESTREND - *Time Series Segmentation and Residual Trend*
UCs - *Unidades de Conservação*
UR – *Umidade Relativa do ar*
USGS - *United States Geological Survey*
VI - *Vegetation Index*
VM – *Virtual Machine*
VPR - *Vegetation Precipitation Relationship*
WSA - *White Sky Albedo*

SUMÁRIO

CAPÍTULO I - INTRODUÇÃO GERAL	16
1.1. Objetivo geral	20
1.2. Objetivos específicos	20
CAPÍTULO II - ANÁLISE COMPARATIVA DO ALBEDO DA SUPERFÍCIE OBTIDO POR DOIS CONJUNTOS DE DADOS LANDSAT	22
2.1. Introdução	22
2.2. Áreas de estudo	23
2.3. Material e métodos.....	25
2.3.1. Dados de entrada	26
2.3.2. Processamento do albedo de superfície.....	27
2.3.3. Avaliação do Albedo de superfície.....	30
2.4. Resultados e Discussão.....	35
2.5. Conclusões	39
CAPÍTULO III - ESTIMATIVA DA EVAPOTRANSPIRAÇÃO REAL EM OLIVAL INTENSIVO UTILIZANDO O SEBAL AUTOMATIZADO	40
3.1. Introdução	40
3.2. Área de estudo.....	41
3.3. Material e métodos.....	42
3.3.1. Dados de entrada	42
3.3.2. Processamento de dados	43
3.3.3. Comparação entre os valores observados de ET e os estimados por SRO 46	
3.3.4. Análise de influências.....	47
3.4. Resultados e discussão	48
3.5. Conclusões	52
CAPÍTULO IV - SERVIÇO COMPARTILHADO DE ALTO DESEMPENHO PARA ESTIMAR A EVAPOTRANSPIRAÇÃO USANDO IMAGENS LANDSAT	53
4.1. Introdução	53
4.2. Material e métodos.....	55
4.2.1. Arquitetura do sistema SAPS	56
4.2.2. Avaliação do sistema SAPS	61
4.2.3. Demonstração dos dados gerados pelo sistema SAPS	61
4.3. Resultados	62

4.4. Discussão.....	63
4.5. Conclusões	65
CAPÍTULO V - USO DE SÉRIES HISTÓRICAS MENSAIS LANDSAT NA IDENTIFICAÇÃO DO PERÍODO DAS REMOÇÕES NA COBERTURA DO VEGETAL NO BIOMA CAATINGA	67
5.1. Introdução	67
5.2. Área de estudo.....	70
5.3. Material e Métodos.....	72
5.3.1. Dados.....	72
5.3.2. Índices espectrais	73
5.3.3. TSS RESTREND	74
5.3.4. Procedimentos usados para avaliação do desempenho das variáveis espectrais utilizadas	76
5.4. Resultados	78
5.5. Discussão.....	85
5.6. Conclusões	88
CAPÍTULO VI – CONCLUSÕES GERAIS	90
REFERÊNCIAS.....	93

CAPÍTULO I - INTRODUÇÃO GERAL

A configuração da paisagem é resultante de processos que atuam em múltiplas escalas espaciais e temporais. Fatores abióticos têm uma influência significativa na distribuição das comunidades de plantas (SEBASTIÁ et al., 2008). As atividades desenvolvidas pelo homem, particularmente o pastoreio e a agricultura, têm contribuído para modificar a paisagem. Existem inúmeras incertezas acerca da importância relativa de fatores abióticos e humanos na dinâmica de áreas desertificadas e propensas à desertificação (ALADOS et al., 2011). A quantificação e avaliação dos seus efeitos constitui-se em um desafio de pesquisa que precisa ser transposto, visto que nos últimos anos têm sido observadas perdas de importantes recursos ambientais, resultantes do efeito antropogênico (D'ODORICO et al., 2013; FOLEY et al., 2005; MEA, 2005), representando uma séria ameaça para a subsistência sustentável.

Em regiões semiáridas, o desafio de identificar áreas que tiveram a cobertura vegetal substituída por solo exposto é potencializado, pois a produção vegetal está intimamente relacionada não apenas à precipitação média de longo prazo, mas também à variabilidade interanual e espacial da precipitação (HEIN et al., 2011). Os impactos humanos são muitas vezes obscurecidos pela variabilidade climática (ZHANG et al., 2014; WESSELS et al., 2007), em particular, pelos efeitos das secas periódicas.

Diversos estudos têm apresentado propostas metodológicas para distinguir entre a remoção completa da vegetação por ação humana e os efeitos que a variabilidade da precipitação em regiões semiáridas (HEIN et al., 2015; LI et al., 2015; WESSELS et al., 2007; EVANS & GEERKEN, 2004). Nesses estudos, é comum a utilização de índices de vegetação obtidos por Sensoriamento Remoto Orbital (SRO) para identificar as ações de remoção da cobertura vegetal, que são normalmente retratadas a partir de análises de tendência (ERASMI et al., 2014; ANYAMBA et al., 2014; HIGGINBOTTOM & SYMEONAKIS, 2014; FENSHOLT et al., 2013; FENSHOLT et al., 2012; WESSELS et al., 2012). Entre os métodos utilizados, observa-se que o método de tendência residual tem apresentado grande destaque em diversas aplicações (IBRAHIM et al., 2015). O resíduo é obtido a partir da regressão entre a variável em análise e uma variável exógena (em geral, precipitação e/ou umidade do solo).

A série de sensores *Advanced Very High Resolution Radiometer* (AVHRR) capturam informações com cobertura global razoavelmente contínua desde junho de 1979, com até duas aquisições de dados no período diário. A resolução espacial do AVHRR é de 1,1 km no nadir. O projeto *Global Inventory Modeling and Mapping Studies* (GIMMS) processa dados provenientes do AVHRR para obter composições espaciais de 8 km e temporais quinzenais de índices de vegetação. Os índices de vegetação disponibilizados pelo projeto GIMMS são a fonte de informação mais utilizada na maioria das análises de tendência com séries temporais (ANYAMBA et al., 2014; HIGGINBOTTOM & SYMEONAKIS, 2014; IBRAHIM et al., 2015; KARLSON & OSTWALD, 2016; LEROUX et al., 2017), especialmente por reunir uma alta resolução temporal e observação da superfície terrestre superior a 30 anos. Tem sido observado aumento da disponibilidade de produtos de maior resolução espacial, tais como *Satellite Pour l'Observation de la Terre* (SPOT) -1 km, *MEdium Resolution Imaging Spectrometer* (MERIS) - 1 km e *Moderate Resolution Imaging Spectroradiometer* (MODIS) - 500 m, os quais apresentam reduzido tempo de observação da superfície terrestre (inferior a 18 anos).

No entanto, apesar da alta resolução temporal ajudar na compreensão das variações temporais, a baixa resolução espacial (500 m - 8 km) desses sensores captura variações que nem sempre são compatíveis com a escala de intervenção humana (LAMBIN et al., 2003; STROPPIANA et al., 2012). Em alguns casos, a escala espacial da ação humana é considerada pequena quando comparada a resolução espacial dos sensores orbitais comumente utilizados. Essa condição dificulta a avaliação das técnicas utilizadas na identificação das alterações de origem antrópica, não sendo possível relacioná-las a mudanças observadas na superfície. Os sensores de média resolução espacial (15 – 120 metros) a bordo dos satélites, a exemplo da série LANDSAT, permitem o monitoramento ao nível de pequenas propriedades rurais, pois um pixel de 30 metros apresenta área de 0,09 ha e um histórico de visualização da superfície terrestre superior a 30 anos. Assim como outros sensores multiespectrais, as análises podem ser beneficiadas pela possibilidade de utilizar outras variáveis, além dos índices de vegetação, como, por exemplo, albedo e temperatura da superfície e evapotranspiração real diária (ET_{r24h}) que também podem ser derivados de sensores orbitais.

Entretanto, existem três principais desafios na utilização do SRO de média resolução espacial para este fim: 1) a determinação da (s) variável (eis) que melhor representam a remoção completa da cobertura vegetal no monitoramento ambiental em áreas com elevada sazonalidade climática; 2) a capacidade computacional para o processamento de grande volume de dados com resolução espacial de 30 metros; 3) a distinção entre a remoção completa da vegetação por ação humana e os efeitos que a variabilidade da precipitação.

No primeiro desafio, entre os efeitos que ocorrem nas áreas que apresentam mudanças na cobertura do solo (área vegetada para solo exposto), estão as mudanças nos diferentes componentes do balanço de massa e energia. As alterações na cobertura do solo provocam mudanças no albedo, temperatura e rugosidade de superfície, condicionando, deste modo, as taxas de transferência de energia, em particular, da evapotranspiração (D'ODORICO *et al.*, 2013). Apesar de o albedo, temperatura e rugosidade da superfície e evapotranspiração serem diretamente influenciados por alterações na cobertura do solo, essas variáveis precisam ser comparadas com instrumentação de superfície, para que possam expressar, fielmente, as alterações que ocorreram na cobertura do solo. Quando se utiliza SRO para fornecer essas informações ambientais é importante avaliar o resultado da modelagem a partir de instrumentação de campo.

O segundo desafio parte da constatação que as pesquisas ambientais utilizando SRO estão provendo dados em grandes escalas, mas estão tendo dificuldades em encontrar arquiteturas de software para acomodar o grande volume de dados (LI *et al.*, 2010). As plataformas *Amazon's Elastic Compute Cloud*, *Google App Engine* e *Microsoft's Windows Azure* estão entre as recentes tecnologias que permitem maior capacidade computacional para análise e processamento de grandes volumes de dados (*Big Data*) ambientais advindos do SRO (WANG *et al.*, 2015; MA *et al.*, 2015; YANG *et al.*, 2015). No entanto, há desafios na conversão dos métodos e algoritmos utilizados tradicionalmente pela comunidade de usuários de SRO: algumas análises visuais e interativas, realizadas pelo operador, precisam ser substituídas por procedimentos computacionais automáticos; em muitos casos, há a necessidade de trabalhar com frações das imagens que cobrem a área de estudo; automatizar os processos de coleta de dados em banco de dados, muitas vezes heterogêneos e inconsistentes; e a necessidade de implementação de procedimentos computacionais

para o gerenciamento dos processos, desde a coleta de dados à geração do produto final.

No terceiro desafio, observa-se que alguns trabalhos têm tido sucesso na distinção entre a remoção completa da vegetação por ação humana e os efeitos que a variabilidade da precipitação em regiões áridas. As metodologias empregadas utilizam análises de tendência e série temporais de dados orbitais com alta resolução temporal e baixa resolução espacial (WESSELS et al., 2012; FENSHOLT et al., 2012). Além disso, essas análises de tendência têm sido baseadas em índices de vegetação calculados com base nos dados de SRO. E então, um outro ponto importante é saber se a utilização de outras variáveis ambientais, possíveis de serem quantificadas por SRO de média resolução, como o albedo da superfície e a evapotranspiração real diária, poderá contribuir para uma melhor identificação da remoção completa da cobertura vegetal.

Diante do que foi exposto, este trabalho procurará dar resposta a três questões de pesquisa: 1) Qual é a qualidade das estimativas das variáveis obtidas por SRO quando comparadas a informações coletadas em campo? 2) As ferramentas computacionais atualmente disponíveis são capazes de subsidiar pesquisas que demandem o processamento de grande volume de dados orbitais com média resolução espacial? 3) É possível distinguir entre a remoção completa da vegetação por ação humana e os efeitos que a variabilidade da precipitação em região semiárida?

A hipótese formulada neste trabalho é que é possível distinguir entre a remoção completa da vegetação por ação humana e os efeitos que a variabilidade da precipitação provoca na vegetação do bioma Caatinga. Contudo, uma abordagem interdisciplinar é necessária para estudar a complexidade inerente às relações entre clima e apropriação humana da paisagem neste processo de alteração da cobertura do solo.

Para isto, propõe-se estudar uma área situada na bacia hidrográfica do Alto Paraíba, Semiárido brasileiro, constituída pelo bioma Caatinga. Na região semiárida, a irregularidade na distribuição das chuvas, a temperatura elevada e a forte taxa de evaporação são características climáticas que “projetam derivadas radicais para o mundo das águas, o mundo orgânico das caatingas e o mundo socioeconômico dos viventes dos sertões” (AB’SÁBER, 2003). Nessa região vivem aproximadamente 25

milhões de brasileiros, em uma área correspondendo a 969.589,4 km², 11% do território nacional (LIMA et al., 2011).

O uso não sustentável dos recursos oferecidos pelo Bioma Caatinga tem proporcionado a fragmentação da sua cobertura vegetal, restringindo sua distribuição a remanescentes que podem ser considerados refúgios para a biodiversidade local (OLIVEIRA et al., 2009). Entre as regiões brasileiras, as áreas de Caatinga são as que apresentam menor proteção, pois as unidades de conservação cobrem menos de 2% do seu território (LEAL, 2006). A introdução de práticas econômicas e tratos culturais nem sempre adequados aos ecossistemas locais é resultado do processo de ocupação do Semiárido (SILVA, 2006). A pressão da população sobre os recursos naturais leva à deterioração ambiental, gerando um ciclo de pobreza e miséria, tornando a região cada vez mais vulnerável (SALES, 2003).

A atual situação do bioma Caatinga exige do Estado o desenvolvimento de políticas públicas que levem em consideração os diferentes fatores que estão envolvidos na problemática da degradação da cobertura do solo, sendo necessário uma melhor compreensão das alterações de origem antrópica. Para tanto, torna-se necessária a articulação eficiente de diversas tecnologias para que a análise, efetuada em diferentes escalas temporais e espaciais, consiga identificar as remoções completas da cobertura vegetal, influenciadas (ou não) pelo processo de ocupação humana na região semiárida brasileira.

1.1. Objetivo geral

Analisar, a partir de sensores de média resolução espacial, as remoções completas da cobertura vegetal em uma área da bacia hidrográfica do Alto Paraíba, Semiárido brasileiro, no período 1985 - 2015.

1.2. Objetivos específicos

- a) Comparar as estimativas de albedo e evapotranspiração realizadas por SRO e instrumentação de campo;
- b) Automatizar o processamento da estimativa de variáveis obtidas por SRO de média resolução espacial;

- c) Determinar a(s) melhor(es) variável(eis) para representar a remoção completa da vegetação no bioma Caatinga.

O principal estudo desenvolvido nesta tese refere-se a análise das alterações de origem antrópica em uma área do bioma Caatinga (Capítulo V). Esta aplicação reúne elementos inovadores – novas variáveis e longas séries temporais aplicadas em modelos estatísticos de tendência para determinação das alterações induzidas pelo homem. Esses novos elementos requisitaram análises para aferir a capacidade de mensuração destas variáveis (Capítulo II e III), especialmente quando submetidos a procedimentos automáticos para construção das longas séries temporais (Capítulo IV). De forma mais específica, a organização desta tese reflete o percurso que foi necessário trilhar para alcançar o objetivo geral deste trabalho. Após fazer uma introdução global ao tema em estudo, o Capítulo II visa a identificação de um conjunto de dados Landsat e de um algoritmo que permitam reduzir a demanda por dados e procedimentos para obtenção do albedo da superfície; o Capítulo III apresenta a automatização de procedimentos para o cálculo de um maior número de variáveis ambientais, com destaque para a evapotranspiração; o Capítulo IV amplia a visão de automação, integrando procedimentos de coleta, gerenciamento de processos e demanda por recursos computacionais para geração de um extenso conjunto de informações ambientais que será aplicada no Capítulo V, na identificação das alterações antropogênicas da cobertura do solo. Por fim, no Capítulo VI tecem-se as considerações finais e apresentam-se algumas perspectivas de trabalho futuro.

CAPÍTULO II - ANÁLISE COMPARATIVA DO ALBEDO DA SUPERFÍCIE OBTIDO POR DOIS CONJUNTOS DE DADOS LANDSAT

2.1. Introdução

Mudanças no uso e nas propriedades do solo provocadas por queimadas (WANG et al., 2016), por variações sazonais fenológicas (WANG et al., 2017), ou por outros fatores (CAI et al., 2016) podem alterar o albedo de superfície (*Surface Albedo* - SA) e o balanço de energia (SILVA et al., 2005; SHUAI et al., 2011).

A mensuração e modelagem do SA através de dados de Sensoriamento Remoto Orbital (SRO) são afetadas pela composição da atmosfera: vapor de água, aerossóis, dióxido de carbono e nuvens que retêm radiação infravermelha. A correção destes efeitos atmosféricos deve ser tida em conta quando se calcula o SA (VERMOTE & KOTCHENOVA, 2008). No entanto, os procedimentos para esta correção normalmente exigem uma grande quantidade de informações climáticas, o que limita a aplicação do SA ao monitoramento ambiental.

Os arquivos Landsat têm passado por aperfeiçoamentos nos últimos anos (WULDER et al., 2017). Em 2016, a *United States Geological Survey* (USGS) reorganizou os arquivos Landsat em uma nova coleção (*Landsat Collection Level 1*). Essa nova estrutura de dados fornece informação adicional sobre a qualidade radiométrica, geométrica e de cobertura de nuvens, tornando-se um bom suporte para análises temporais. Além disso, a análise dos produtos derivados dos dados Landsat, é também beneficiada por este novo conjunto de informação pois permite uma melhor identificação das possíveis fontes de erros.

Além dos arquivos Landsat Collection Level 1, a USGS disponibiliza também os produtos Landsat *Surface Reflectance Higher-Level Data* para Landsat 4-5 *Thematic Mapper* (TM), Landsat 7 *Enhanced Thematic Mapper Plus* (ETM+) e Landsat 8 *Operational Land Imager* (OLI). O Landsat *Ecosystem Disturbance Adaptive Processing System* (LEDAPS) é o algoritmo utilizado pela USGS para processar a refletância de superfície Landsat TM e Landsat ETM+ (MASEK et al., 2013; 2006). O Landsat 8 OLI *Surface Reflectance Code* (LaSRC) é o algoritmo utilizado pela USGS para processar a refletância de superfície Landsat OLI (VERMOTE et al, 2016).

Desde 30 de abril de 2017, as recém adquiridas cenas dos satélites Landsat 7 ETM+ e Landsat 8 OLI/TIRS passaram a estar acessíveis somente na estrutura Landsat *Collection 1*, deixando os conjuntos de dados Landsat *Pre-Collection* de estar

disponíveis a partir de 1 de outubro de 2017. Diante deste novo cenário, é necessário que as pesquisas que utilizam os dados Landsat para o cálculo do SA percebam qual dos dois conjuntos de dados Landsat disponíveis (Collection 1 e SR) oferecem a melhor oportunidade.

O procedimento utilizado para o cálculo do SA com o conjunto de dados da Collection 1 requer o uso de dados meteorológicos de superfície do local onde está sendo desenvolvido o estudo (TREZZA et al., 2013; ALLEN et al., 2007). Essa necessidade, em muitos casos, pode limitar o uso do SA para análises multitemporais, como, por exemplo, as realizadas para avaliar mudanças na cobertura da superfície ou a sua utilização em modelos de evapotranspiração real em escala operacional.

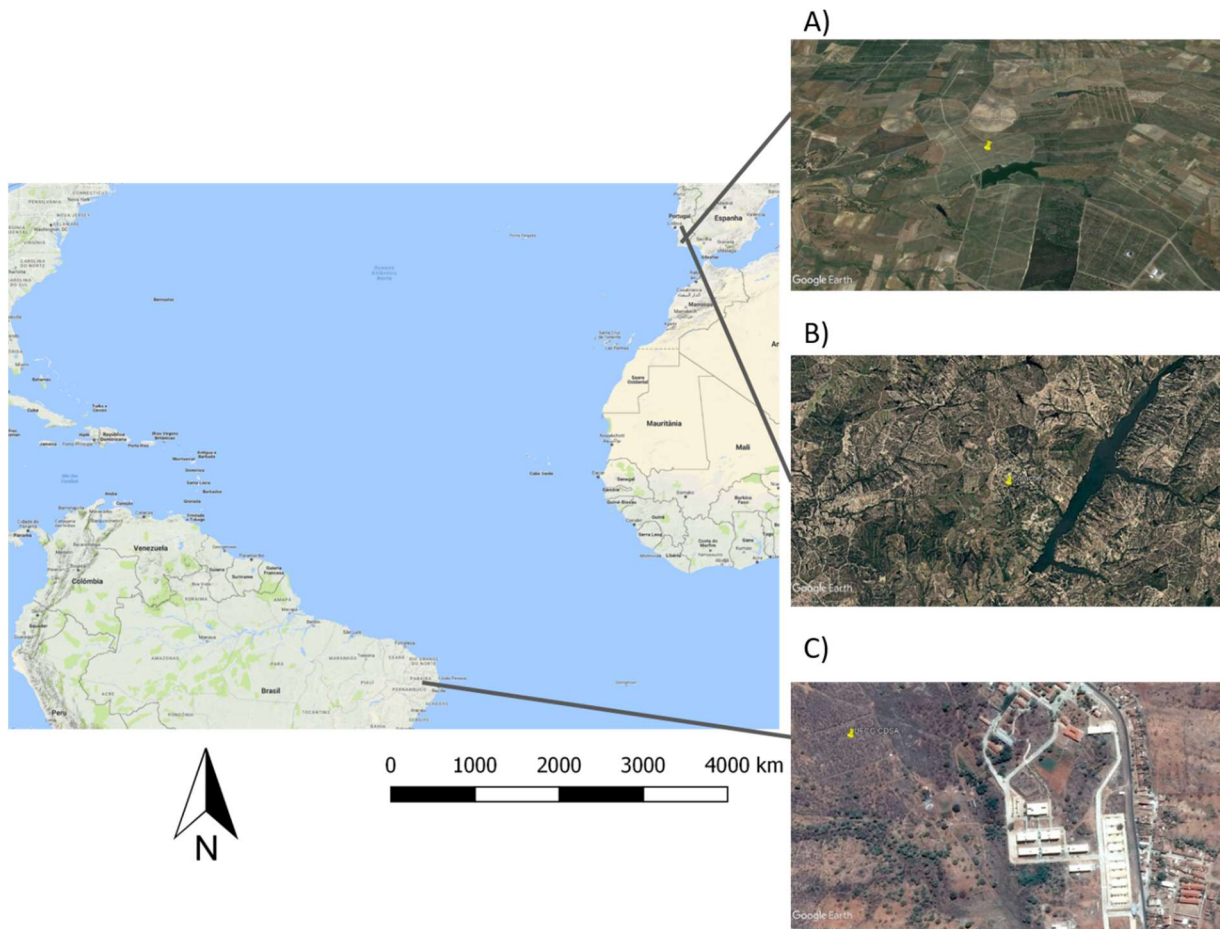
O objetivo deste capítulo é identificar o conjunto de dados Landsat que apresenta melhor desempenho para estimativa do albedo de superfície. O albedo da superfície gerado pelos novos conjuntos de dados Landsat (Level 1 e SR) foram comparados a medições obtidas por instrumentação de campo (avaliação indireta, pelo R_{n24h}) e albedo da superfície derivado do sensor MODIS.

2.2. Áreas de estudo

Para o desenvolvimento do estudo foram utilizadas três áreas experimentais: duas situadas na região portuguesa de clima mediterrânico (Figura 1A e B) e uma região brasileira de clima semiárido (Figura 1C). A primeira corresponde a um olival explorado de forma intensiva (*Olea europea cv. Arbequina*), ocupando uma área de 10 ha com um espaçamento entre árvores de 4,8 m e entre linhas de 7 m, localizado na região do Alentejo, Portugal (38°01'15,90"N, 8°10'44,50"W), 97 m acima do nível do mar (CONCEIÇÃO et al., 2017). A segunda área experimental é uma plantação de sobreiros com cerca de 50 anos de idade (*Quercus suber*), localizado na Herdade da Machoqueira, Coruche, Portugal (39°09'00"N, 8°19'48"W), 150 m acima do nível do mar (COSTA E SILVA et al., 2015). Em ambos os locais, os invernos são suaves e úmidos e os verões são quentes e secos. A precipitação média anual de longo prazo e a temperatura média do ar são em torno de 670-680 mm e de 15-16° C, respectivamente. A terceira área experimental corresponde a uma área protegida com vegetação composta por Caatinga arbustiva (7°39'38,8"S, 36°53'42,4"W), 535 m acima do nível do mar, localizada no estado da Paraíba, Nordeste brasileiro. A

precipitação média anual e temperatura média anual são em torno de 470-500 mm e 25°C a 28°C, respectivamente.

Figura 1- Localização das três áreas experimentais



Em cada uma das três áreas experimentais estão instaladas torres meteorológicas que forneceram os dados de superfície para o desenvolvimento deste estudo. As torres meteorológicas instaladas no território português foram operadas e tiveram seus dados processados por pesquisadores do Instituto Superior de Agronomia, da Universidade de Lisboa (ISA-UL). A torre instalada no território brasileiro foi instalada e operada pelo autor desta tese em conjunto com pesquisadores da Universidade Federal de Campina Grande. As torres são equipadas com diversos sensores, neste estudo utilizou-se as informações do radiômetro (Rn_{24h} , $W m^{-2}$) e a temperatura (T_a , °C) e umidade relativa do ar (UR, %). A utilização das três áreas experimentais, em duas regiões climáticas diferentes, possibilitou lidar com uma maior amplitude dos valores medidos e modelados devido às diferenças na cobertura

vegetal da superfície e no clima, permitindo uma melhor avaliação dos parâmetros em estudo.

As três áreas experimentais contêm os mesmos instrumentos e estão configurados para registrar informações em intervalos de 30 minutos. O radiômetro utilizado nas três áreas experimentais foi o modelo NR Lite desenvolvido pela empresa Kipp & Zone (Delft, The Netherlands), com campo de visão (FOV – *Field Of Vision*) de 180°. Os dados de temperatura e umidade do ar foram obtidos pelo sensor Campbell CS215-L.

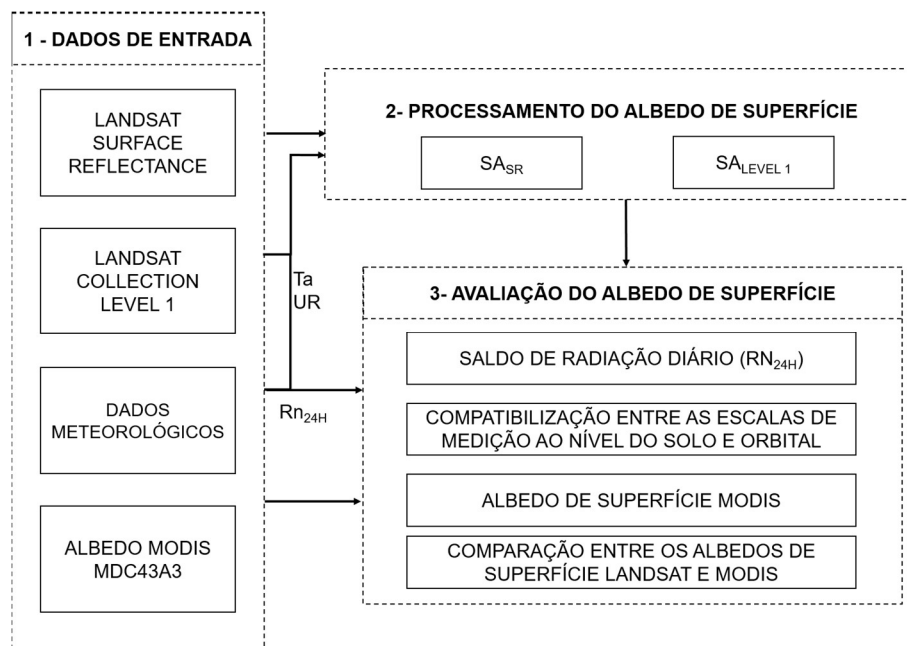
2.3. Material e métodos

A metodologia utilizada neste trabalho para o cálculo do SA usando dados Landsat *Surface Reflectance* (SR) foi a apresentada recentemente por Wang et al. (2016), para Landsat 8, e por Shuai et al. (2014) para Landsat 5 e 7. Para os dados da Landsat *Collection Level 1* aplicou-se as tradicionais metodologias descritas em Duguay e LeDrew (1992), Liang (2000) e Bastiaanssen (2000): primeiro calculou-se o albedo no topo da atmosfera (*Top of Atmosphere* – TOA, α_{TOA}) a que se aplicou a correção atmosférica para se obter o SA.

A Figura 2 apresenta a descrição metodológica das três fases do trabalho: dados de entrada, processamento do albedo de superfície e avaliação dos valores obtidos. A fase de entrada de dados contém quatro conjuntos de dados: Landsat *Collection Level 1*, Landsat SR, dados meteorológicos e albedo MODIS (MCD43A3), que reúne os dados necessários às fases de processamento e análise para as três áreas experimentais. Na fase de processamento do SA foram usados o conjunto de dados Landsat *Surface Reflectance* para processar o SA_{SR} e o conjunto de dados Landsat *Collection Level 1* e dados meteorológicos para processar o SA_{LEVEL1} . Na fase de avaliação não foi possível realizar uma comparação entre os SA estimados (SA_{SR} e SA_{LEVEL1}) e observado (medido ao nível do solo), pois as torres não estavam equipadas com sensores do tipo albedômetros. Em geral, os albedômetros são raramente utilizados nas torres meteorológicas. As áreas experimentais instaladas no território português têm como objetivo principal o monitoramento da evapotranspiração real, tendo a mensuração da radiação realizada a partir do radiômetro.

Um outro problema relacionado a avaliação do albedo ao nível de superfície refere-se a escala temporal de mensuração das variáveis nas estações meteorológicas. Os sistemas de correlações turbulentas utilizados para a mensuração da evapotranspiração real são, necessariamente, configurados para apresentar medidas a cada 30 minutos. Em virtude das limitações de amostragem temporal do sistema de correlações turbulentas, todos os outros sensores presentes na torre são configurados para mesma escala de medição (30 minutos). Entretanto, as medidas realizadas por instrumentação orbital são obtidas numa escala instantânea. Para o saldo de radiação (R_n) é possível utilizar algoritmos para realizar um *upscaling* temporal para obter o R_n na escala de 24 horas, e assim permitir uma valiação na mesma escala temporal para os dados obtidos por sensores orbitais e de superfície. Para suprir a carência de uma avaliação direta do albedo de superfície, utilizou-se o SA MODIS. Procedimentos para compatibilização das escalas de observação foram necessárias para as análises ao nível de superfície e orbital.

Figura 2- Descrição das etapas metodológicas



2.3.1. Dados de entrada

A família de satélites Landsat tem adquirido informações sobre a superfície terrestre há mais de 40 anos. Esta é a mais longa e contínua coleção de dados de média resolução espacial (30 metros) disponível gratuitamente. Os produtos *Surface*

Reflectance e *Collection Level 1* são processados a partir de dados brutos coletados pelos sensores a bordo dos satélites Landsat. Os arquivos Landsat *Collection level 1* e Landsat SR foram obtidos junto ao USGS (<http://earthexplorer.usgs.gov/>). Todos os produtos Landsat utilizados neste trabalho foram processados no formato padrão da USGS, incluindo a correção de nível 1, resultando em imagens ortorretificadas de alta precisão geométrica.

O produto de Albedo MODIS (MCD43A3), fornecido com 500 metros de resolução espacial, descreve a reflectância hemisférica direcional (*black-sky* albedo) e a reflectância bihemisférica (*white-sky* albedo). Esses arquivos foram disponibilizados pela USGS (<https://e4ftl01.cr.usgs.gov/MOTA/MCD43A3.006/>). Os sensores MODIS estão a bordo de dois satélites Terra e Aqua que apresentam uma defasagem de cerca de 3 horas entre os horários de passagem. A informação conjunta dos dois sensores MODIS é usada para obter o produto MCD43A3. A possibilidade de utilizar a informações dos dois sensores MODIS possibilita uma maior probabilidade de ter dados de boa qualidade (livre de nuvens ou sombra de nuvens).

Os dados meteorológicos serão utilizados para o cômputo do SA quando usado o conjunto de dados Landsat Level 1 e para o cômputo do R_{n24h} . Além disso, serão utilizados os dados R_{n24h} coletados pelo radiômetro para realizar as avaliações entre os dados orbitais e de superfície.

2.3.2. Processamento do albedo de superfície

i) Albedo de superfície a partir de Landsat SR (SA_{SR})

O produto Landsat SR é distribuído pela USGS com correção atmosférica, possibilitando a obtenção do SA_{SR} a partir da execução da Equação 1. Wang et al. (2016) e Shuai et al. (2014) apresentaram os parâmetros para a obtenção do SA_{SR} utilizando imagens de OLI-Landsat SR e TM/ETM+ Landsat SR, respectivamente.

$$SA_{SR} = b_{blue} \times \rho_{blue} + b_{green} \times \rho_{green} + b_{red} \times \rho_{red} + b_{NIR} \times \rho_{NIR} + b_{SWIR1} \times \rho_{SWIR1} + b_{SWIR2} \times \rho_{SWIR2} + b_0 \quad (1)$$

onde ρ e b são a reflectância de superfície e os correspondentes coeficientes de conversão para as seis bandas do Landsat não termais, i.e. *Blue*, *Green*, *Red*, *Near-Infrared* (NIR) e duas *Shortwave Infrared* (SWIR1 e SWIR2). As Tabelas 1 e 2

apresentam a definição das bandas espectrais e seus respectivos valores b para cada um dos satélites utilizados neste estudo.

Tabela 1- Bandas espectrais para os sensores a bordo dos satélites Landsat (nm)

Sensor	Blue	Green	Red	NIR	SWIR1	SWIR2
TM/ETM+	450 – 520	520 – 600	630– 690	760 – 900	1550–1750	2080–2350
OLI	452 – 512	533 – 590	636 – 673	851 – 879	1566–1651	2107–2294

Fonte: USGS, 2018

Tabela 2 - Coeficientes utilizados para o cálculo do albedo de superfície

Sensor	b_{blue}	b_{green}	b_{red}	b_{NIR}	b_{SWIR1}	b_{SWIR2}	b_0
TM	0.3206	0	0.1572	0.3666	0.1162	0.0457	0.0063
ETM+	0.3141	0	0.1607	0.3694	0.1160	0.0456	0.0057
OLI	0.2453	0.0508	0.1804	0.3081	0.1332	0.0521	0.0011

Fonte: Wang et al. (2016) e Shuai et al. (2014)

ii) Albedo de superfície a partir Landsat *Level 1* ($SA_{LEVEL 1}$)

Ao utilizar o conjunto de dados Landsat *Level 1*, o albedo de superfície é calculado a partir da Equação 2 (Zhong e Li, 1988).

$$SA_{LEVEL 1} = \frac{\alpha_{TOA} - \alpha_{ATM}}{\tau_{SW}^2} \quad (2)$$

onde α_{TOA} , α_{ATM} e τ_{SW} são albedo sem correção atmosférica, albedo atmosférico e transmitância atmosférica no domínio de onda curta, respectivamente. α_{ATM} representa a porção média da radiação solar recebida pelo satélite em todas as bandas antes de atingir a superfície da Terra. Os valores de α_{ATM} estão entre 0,025 e 0,040, sendo utilizado neste estudo o valor de 0,03 (Allen et al., 2002).

O cômputo do albedo sem correção atmosférica é realizado a partir da combinação linear das refletâncias espectrais de cada banda refletiva dos sensores a bordo dos satélites Landsat (Equação 3). Entretanto, cada sensor utilizado exige coeficientes diferentes para mensuração do α_{TOA} , conforme apresentado na Tabela 3.

$$\alpha_{TOA} = \omega_{blue} \times \rho_{TOA blue} + \omega_{green} \times \rho_{TOA green} + \omega_{red} \times \rho_{TOA red} + \omega_{NIR} \times \rho_{TOA NIR} + \omega_{SWIR1} \times \rho_{TOA SWIR1} + \omega_{SWIR2} \times \rho_{TOA SWIR2} \quad (3)$$

onde ω e ρ_{TOA} são coeficientes para o cálculo do α_{TOA} e a refletância TOA, respectivamente.

Para os satélites Landsat 5 e 7, antes do cálculo da refletância TOA (ρ_{TOA}), é necessário o cômputo da radiância espectral. Apesar das recentes mudanças nos conjuntos de dados Landsat, pode-se continuar utilizando os procedimentos descritos em Chander et al. (2009) para conversão de DN (*Digital Number*) para radiância espectral e ρ_{TOA} . O processo de conversão de DN para ρ_{TOA} para o satélite Landsat 8 utiliza o procedimento descrito pela USGS (2018).

Os coeficientes para o cálculo do albedo sem correção atmosférica são dados pela Equação 4 (Allen et al., 2002).

$$\omega_i = \frac{ESUN_i}{\sum ESUN_i} \quad (4)$$

onde $ESUN_i$ representa a irradiação solar exoatmosférica média para cada banda espectral. Para os satélites Landsat 5 e 7 os valores de $ESUN_i$ são apresentados em Chander et al. (2009). Para o Landsat 8, os procedimentos para determinação dos valores de $ESUN_i$ foram detalhados em Silva et al. (2016).

Tabela 3 – Coeficientes (Equação 4) utilizados para o cálculo do albedo sem correção atmosférica (α_{TOA})

Sensor	ω_{blue}	ω_{green}	ω_{red}	ω_{NIR}	ω_{SWIR1}	ω_{SWIR2}
TM	0.2982206	0.2700979	0.2309968	0.1550506	0.0330854	0.0125484
ETM+	0.2982065	0.2705810	0.2289187	0.1551510	0.0344647	0.0126779
OLI	0.3001036	0.2765390	0.2331990	0.1427060	0.0354900	0.0119620

A Equação 5 é apresentada em Allen et al. (2007) para o cômputo da transmitância atmosférica no domínio de onda curta (τ_{SW}).

$$\tau_{SW} = 0.35 + 0.627 \exp \left[-\frac{0.00146P}{k_t \cos Z} - 0.075 \left(\frac{W}{\cos Z} \right)^{0.4} \right] \quad (5)$$

onde P = Pressão atmosférica (KPa); W = Teor de água na atmosfera (mm); $\cos Z$ = ângulo solar zenital (disponível nos metadados dados da imagem) e k_t = Coeficiente de turbidez do ar (1,0 para ar limpo e 0,5 para o ar extremamente turvo ou poluído; o valor utilizado neste estudo foi de 1,0).

Segundo Allen et al. (2007) é possível utilizar a Equação 6 para determinação da pressão atmosférica.

$$P = 101.3 \left(\frac{293 - 0.0065z}{293} \right)^{5.26} \quad (6)$$

O Modelo Digital de Elevação (MDE) disponibilizado pelo *Consortium for Spatial Information* (CSI - <http://srtm.csi.cgiar.org/>) foi utilizado para determinar o valor de z (m) necessário para o cálculo de P pela Equação 6. A utilização do valor de z a partir do MDE possibilita a obtenção dos valores de pressão atmosférica para todos os pixels presentes na cena.

O teor de água na atmosfera – W (Equação 7) é calculada a partir da mensuração ou da estimativa da pressão de vapor de água atmosférico, conforme descrito em Garrison e Adler (1990). Neste estudo, W foi estimado usando as Equações 7, 8 e 9.

$$W = 0.14e_a P + 2.1 \quad (7)$$

$$e^o = 0.6108 \exp \left(\frac{17.27T_a}{T_a + 237,3} \right) \quad (8)$$

$$e_a = \frac{UR}{100} e^o \quad (9)$$

onde e_a = pressão de vapor de água próximo da superfície (kPa); e^o = pressão de vapor de saturação à temperatura do ar (kPa); T_a = Temperatura do ar no horário próximo à passagem do sensor na região de estudo (°C); e UR = Umidade relativa do ar (%) no horário próximo à passagem do sensor na região de estudo.

2.3.3. Avaliação do Albedo de superfície

A comparação dos valores de SA obtidas por SRO com medições de campo é uma abordagem independente e ótima para a validação dos produtos, mas sofre com a disponibilidade limitada de medições de albedo medido na superfície. A comparação cruzada com outros produtos de SRO pode ser realizada em um grande volume de dados MODIS, permitindo análises para diferentes tipos de cobertura do solo presentes numa imagem de satélite, mas deve-se estar atento para possíveis imprecisões oriunda deste conjunto de dados.

i) Saldo de radiação diário (Rn_{24h})

As estações meteorológicas à superfície, em sua maioria, não estão equipadas com sensores que permitam a avaliação direta do albedo da superfície. O instrumento mais comum presente nestas estações é radiômetro, que fornece informação sobre o balanço entre a radiação incidente do Sol e céu e a emitida/refletida pela superfície (i.e., o saldo de radiação), em uma resolução temporal pré-definida. Uma outra limitação na análise é referente a resolução temporal dos instrumentos à superfície, esses sensores não são configurados para atender a experimentos em SRO que representam medidas instantâneas. Então, para contornar as limitações por falta de medição direta de albedo da superfície e resolução temporal, optou-se por avaliar o albedo de superfície a partir do saldo de radiação diário, possível de ser obtido pela aplicação da Equação 10. É possível obter mais detalhes para aplicação da Equação 10 em Walter et al. (2005).

$$Rn_{24h} = (1 - \alpha)Rs - \sigma f_{cd} (0.34 - 0.14\sqrt{e_a}) \left[\frac{T_{máx}^4 - T_{mín}^4}{2} \right] \quad (10)$$

onde Rs = Radiação de onda curta incidente (W/m^2) ; σ = Constante de Stefan-Boltzmann ($5,6704 \times 10^{-8} W/m^2 K^{-4}$); $T_{máx}$ e $T_{mín}$ = Temperaturas absolutas máxima e mínima diária ($K = ^\circ C + 273,16$); e f_{cd} = Função de nebulosidade [adimensional] (limitado $0,05 \leq f_{cd} \leq 1,0$).

ii) Compatibilização entre as escalas de medição da torre e Landsat

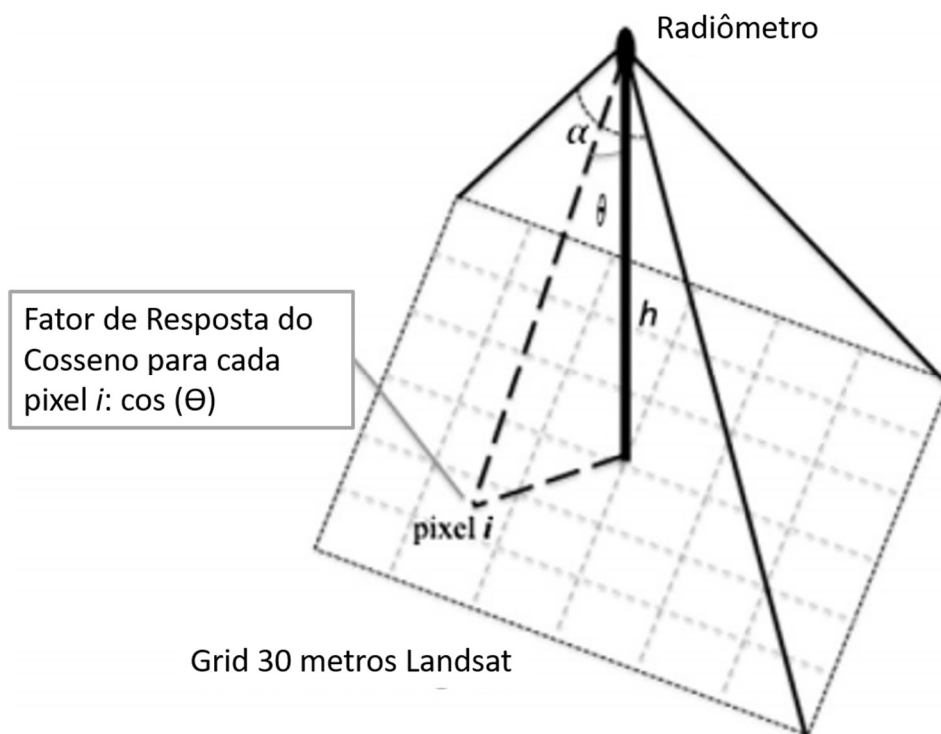
A diferença na escala espacial entre medições orbitais e *in situ* é uma das barreiras para a validação de produtos derivados de satélites. Vários estudos concluíram que a comparação direta "ponto a pixel", sem considerar escalas espaciais, não é suficiente para a validação do produto albedo, a menos que a validação se centre em regiões grandes e homogêneas (LIANG et al., 2002; ROMÁN et al., 2009).

O radiômetro é influenciado pela "lei do cosseno" na determinação da sua área de contribuição. Uma resposta perfeita ao cosseno mostrará sensibilidade máxima em um ângulo de incidência de zero graus (perpendicular à superfície do sensor) e zero sensibilidade em um ângulo de incidência de 90 graus (radiação que passa sobre a

superfície do sensor). Em qualquer ângulo entre 0 e 90 graus, a sensibilidade deve ser proporcional ao cosseno do ângulo de incidência.

No entanto, a empresa Kipp & Zone fabricante do radiômetro indica baixa sensibilidade para um ângulo incidente próximo de 90°. Por isso, adotou-se como ângulo efetivo para o (Field Of View) FOV o ângulo de 170°. A área da região associada às medições efetuadas por cada um dos radiômetros (Equação 11) é assim determinada pelo raio no plano horizontal na superfície definido pelo ângulo de visão descendente do sensor (Figura 3). A altura do radiômetro, área de contribuição, número de pixel presentes na área do *footprint* e número de imagens utilizadas em cada área experimental são listados na Tabela 4.

Figura 3 - Ilustração da área de contribuição projetada sobre um grid Landsat a partir do ângulo de visão do radiômetro instalado (h metros da superfície)



Fonte: Shuai et al. (2014)

Para facilitar a comparação neste estudo, foi aplicado um método de escala ascendente (uma média ponderada) baseado em cosseno para agregar o Rn_{24h} Landsat e radiômetro (Equação 12).

$$A = \pi(h \tan(FOV/2))^2 \quad (11)$$

$$Rn_{24h\ footprint} = \frac{\sum_{i=1}^N (\cos \theta_i \times Rn_{24h}(i))}{\sum_{i=1}^N \cos \theta_i} \quad (12)$$

Tabela 4 - Discriminação por área experimental (Exp.) de: número de imagens utilizadas, altura do radiômetro instalado nas torres, raio do footprint, área de contribuição em cada experimento (footprint) e número de pixels associado a cada observação

Exp.	Nº de imagens	Altura do Sensor (m)	Raio do Footprint (m)	Footprint (m ²)	Nº de Pixels
Olival	45	5	60	10.261	21
Coruche	19	22	250	198.651	285
Caatinga	85	6	70	14.776	21

iii) Albedo de superfície MODIS

Para análise comparativa dos dados de albedo de superfície obtidos pelos dois conjuntos de dados Landsat, usou-se o produto MODIS MCD43A3 que compreende, entre outras informações, o *White Sky Albedo* (WSA) e o *Black Sky Albedo* (BSA). O albedo de superfície derivado dos dados do produto MCD43A3 é constituído pela interpolação entre WSA e BSA em função da fração de luz difusa (FD), denominado *Blue Sky Albedo* (BSA) e obtido a partir da aplicação da Equação 13 (SCHAAF, 2002):

$$\alpha_{MODIS} = WSA \times FD + BSA \times (1 - FD) \quad (13)$$

Utilizou-se esta equação para obter o albedo de superfície MODIS no intervalo de 0,250 a 4,000 μm . A fração difusa (FD) pode ser obtida da tabela SKYL LUT (*Sky Light Look-Up Table*) disponível no pacote computacional do produto MCD43A3. Para identificar o valor da FD a partir da tabela SKYL LUT, é necessário conhecer a profundidade óptica (0 a 1, com variação de 0,02) e ângulo zenital solar (0° a 89° , variação em passos de 1°) corrigidos dos efeitos atmosféricos (código 6S, *Second Simulation of the Satellite Signal in the Solar Spectrum*).

Neste estudo, a profundidade óptica do aerossol (AOD - *Aerosol Optical Depth*) foi obtida a partir do serviço GIOVANNI (*Goddard earth sciences data and information services center - Interactive Online Visualization ANd aNalysis Infrastructure*), que fornece dados de sensoriamento remoto em nível global. O produto utilizado tem

resolução temporal mensal e resolução espacial de 1°. O ângulo zenital (φ) solar foi obtido a partir da aplicação da Equação 14. A hora indicada para a hora local foi sempre a hora da passagem do sensor que está sendo comparado.

$$\cos \varphi = \sin(lat) \times \sin(d) + \cos(lat) \times \cos(d) \times \cos(h) \quad (14)$$

onde lat = Latitude do pixel; d= declinação solar calculada pela Equação 15; h= ângulo horário (Hora local – 12) x 15.

$$d = 0,409 \sin \left[\left(\frac{2\pi}{365} \times Dia \text{ Juliano} \right) - 1,39 \right] \quad (15)$$

iv) Comparação entre os albedos de superfície Landsat e MODIS

A comparação entre o albedo de superfície Landsat e MODIS foi realizada para os três sensores Landsat nos dois conjuntos de dados estudados, conforme descrição das imagens na Tabela 5. As imagens foram selecionadas por apresentar pouca cobertura de nuvens. Para garantir a qualidade dos dados utilizados, foi analisada a banda pixel_qa dos arquivos Landsat associados. Apenas os pixels classificados como “clear” foram considerados observações de boa qualidade e foram utilizados na comparação com os dados MODIS. Para os arquivos Landsat SR os pixels são classificados como “clear” quando apresentam os valores 66 e 130 nos arquivos Landsat 5 e 7 ou 322 e 386 no Landsat 8. Para os arquivos Landsat *Collection Level* 1 os pixels são classificados como “clear” quando apresentam os valores 672 nos satélites 5 e 7 ou 2720 no Landsat 8.

Tabela 5 - Descrição das imagens utilizadas na comparação entre albedo de superfície Landsat e MODIS

Sensor	OÓrbita/ponto	Região	Data da passagem
TM	203/033	Mediterrâneo	12/09/2011
ETM+	215/065	Semiárido	10/12/2016
OLI	215/065	Semiárido	27/09/2015

As imagens provenientes do sensor ETM+ registradas após o dia 31 de maio de 2003 possuem lacunas de dados devido ao problema *Scan Line Corrector* (SLS)-

off, mas ainda são úteis e mantêm as mesmas correções geométricas e radiométricas que os dados coletados antes da falha do SLC. A região central da cena, com aproximadamente 22 km de largura, contém pouca perda de dados, e esta região de cada imagem é muito similar em qualidade ao anterior (STOREY et al., 2005; CHANDER et al., 2009). Em virtude do problema relatado nas imagens Landsat 7, optou-se por utilizar apenas a região central de 22 km que apresenta baixa perda de informação na comparação com os dados MODIS. Para os demais sensores Landsat, utilizou-se toda a área da cena.

As informações derivadas do MODIS apresentam resolução espacial diferente das imagens Landsat, por isso foram efetuados procedimentos para compatibilização espacial das imagens dos dois satélites. Assim, os pixels Landsat com 30 metros de resolução espacial foram agregados para apresentar a mesma resolução espacial dos pixels MODIS (500 metros).

Todo processamento dos dados orbitais ocorreu no software R (R Core Team, 2018) através da interface Rstudio (RStudio Team, 2018) a partir de scripts desenvolvidos pelo autor desta tese.

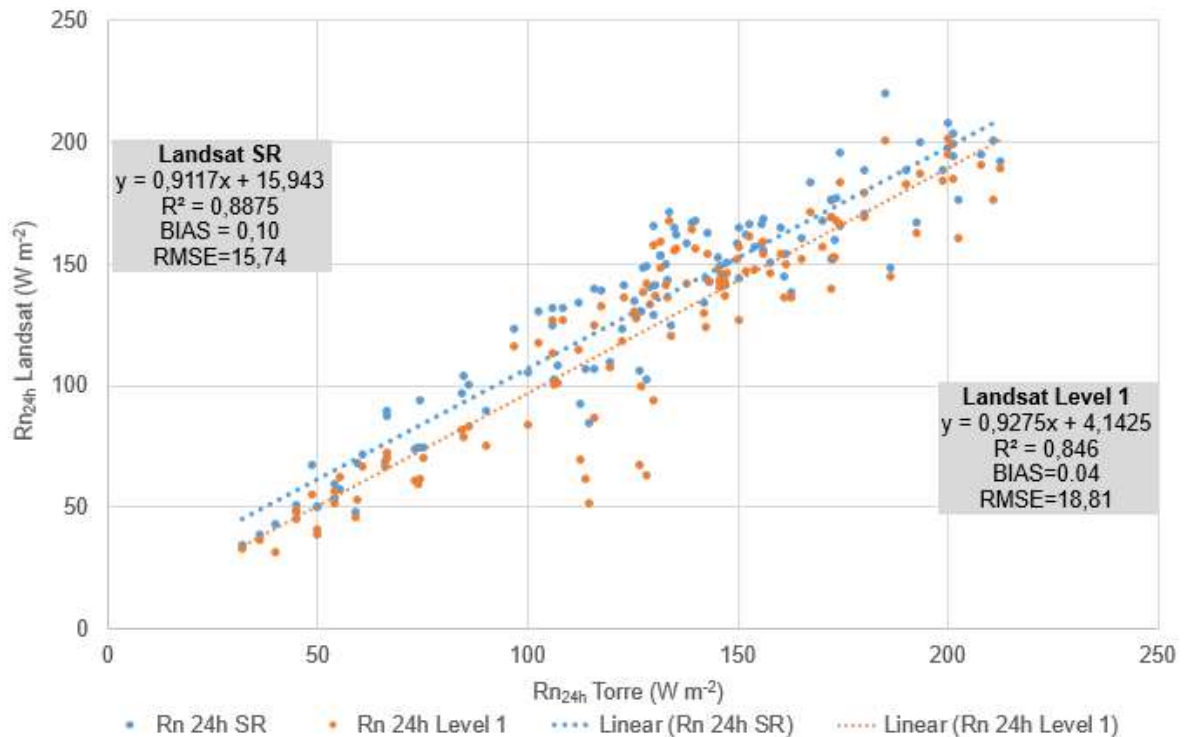
2.4. Resultados e Discussão

A metodologia aplicada aos dados Landsat SR para cômputo do SA apresenta, de início, uma vantagem em relação à que utiliza dados Landsat *Collection Level 1*: não requer dados meteorológicos por parte do usuário para a sua aplicação. Apesar de em princípio ser mais vantajosa, a metodologia que utiliza Landsat SR possui ainda poucos testes realizados, num número reduzido de regiões climáticas. A união dos conjuntos de dados das três áreas experimentais contribuiu para um amplo espectro de informações, cerca de 200 W m^{-2} entre o menor e maior valor observados. Caso se tivesse optado por utilizar apenas uma área experimental, essa amplitude seria menor e o conjunto de dados seria mais restrito. Por exemplo, para o experimento realizado na região de Caatinga, a gama de variação é em torno de 90 W m^{-2} e as densidades de fluxo observadas seriam elevadas, com valores a variar entre 126 W m^{-2} e 212 W m^{-2} . Ao analisar as áreas na região de clima Mediterrânico, percebe-se uma alta amplitude com valores entre 32 W m^{-2} e 213 W m^{-2} , mas os dois experimentos contemplam apenas 43% dos dados analisados. Além disso, foi possível contemplar

a análise dos três sensores Landsat, devido ao maior período de abrangência da série temporal avaliada.

Na Figura 4 são apresentados os valores observados e modelados de Rn_{24h} para os dois conjuntos de dados Landsat estudados. O albedo de superfície é única variável que diferencia o Rn_{24h} obtido pelos conjuntos de dados investigadas, qualquer diferença deve ser atribuída ao SA utilizado. Entende-se que a comparação direta do albedo obtido em campo e por sensores orbitais seria o método mais eficiente de análise, mas com a ausência de medições de albedo por instrumentação de campo, optou-se por analisar indireta em função do Rn_{24h} . Ao analisar o gráfico e comparando as linhas de tendência dos dois conjuntos de dados com a reta 1:1, percebem-se três situações distintas. O conjunto de dados Landsat *Level 1* apresentou melhores resultados para a gama de valores entre 30 W m^{-2} e 100 W m^{-2} . No intervalo central, entre 100 W m^{-2} e 150 W m^{-2} foi a que apresentou as maiores diferenças para os dois conjuntos de dados Landsat. A inclinação da reta linear que corresponde aos dados Landsat SR está mais próxima da reta 1:1 na gama de valores acima de 150 W m^{-2} , sendo esta faixa de valores predominante na área experimental de Caatinga.

Figura 4- Valores observados e modelados de saldo de radiação diário para os dois conjuntos de dados Landsat



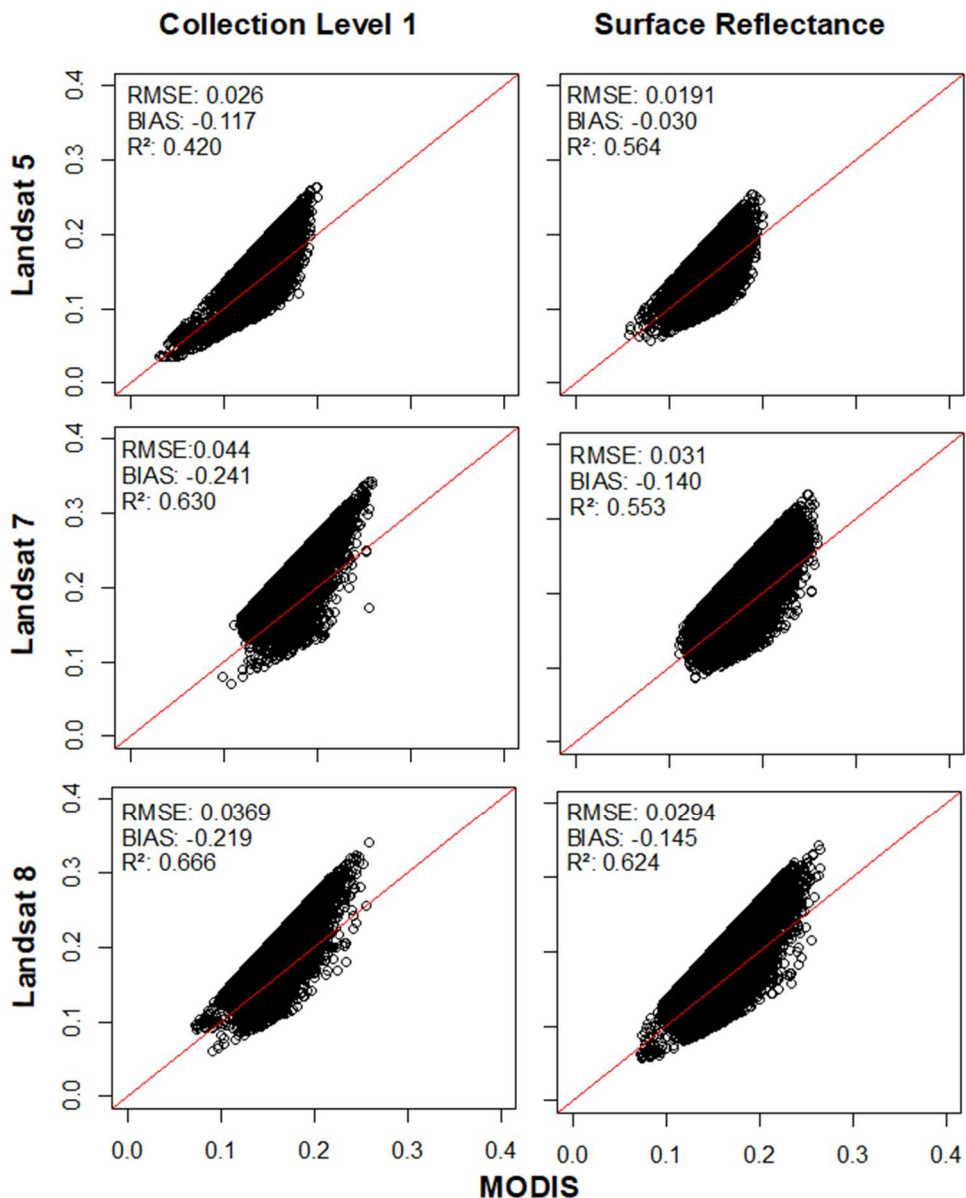
Os valores de R^2 e raiz do erro médio quadrático (*Root-Mean-Square Error* – RMSE) foram superiores para o conjunto de dados Landsat SR, mas apresentou um desempenho ligeiramente inferior para a declividade da reta e erro médio ou viés (BIAS). No entanto, apesar de haver alguma diferença entre os indicadores analisados, essas diferenças são pequenas, o que sugere um desempenho equivalente entre os dois conjuntos de dados utilizadas para obtenção do albedo de superfície. Entretanto, outras análises estatísticas devem ser aplicadas para melhor avaliação da equivalência das estimativas realizadas pelos dois conjuntos de dados.

Os valores de R^2 da regressão linear entre os valores modelados e observados de Rn_{24h} são compatíveis com os descritos em Shuai et al. (2011) para áreas experimentais representativas. Em áreas experimentais com cobertura do solo heterogênea, pode haver porções do *footprint* do albedômetro ou radiômetro que pertençam a áreas de solo exposto ou estradas. Essa heterogeneidade da superfície pode contribuir para que uma área experimental seja classificada como não representativa. Em Shuai et al. (2011), as áreas experimentais classificadas como não representativas, apresentaram R^2 de 0,78 e declividade da reta de 1,11 para análise entre o albedo de superfície estimado por Landsat e observações ao nível de superfície.

Na Figura 5 observam-se os gráficos com a comparação entre os valores de albedo de superfície para os dois conjuntos de dados Landsat e MODIS. Os indicadores de desempenho RMSE e BIAS indicam sempre maior similaridade entre Landsat SR e MODIS para estimativas de SA. Shuai et al. (2014) computaram o RMSE para comparar o SA MODIS e LANDSAT para uma única imagem, obtendo o valor de 0,0260. O RMSE para os dados de SA Landsat SR e MODIS foi entre 0,0191 e 0,0305 para os três satélites Landsat analisados. Para o conjunto de dados Landsat Level 1 os valores de RMSE são entre 0,0260 e 0,0444. Na avaliação do RMSE o albedo processado com os conjuntos de dados Landsat SR apresentou melhor desempenho, mas os dois conjuntos apresentam desempenho similar ao identificado por Shuai et al., (2014). O mesmo estudo de Shuai et al. (2014) identificou R^2 de 0.521 para regressão linear do SA MODIS e Landsat. O valor de R^2 foi entre 0,553 e 0,624 quando utilizado o conjunto de dados Landsat SR. Quando utilizado o conjunto de dados Collection Level 1 para o cálculo do albedo de superfície o valor de R^2 na regressão linear com os SA MODIS foi entre 0,420 e 0,666. Os valores de R^2 são compatíveis

com o identificado no estudo de Shuai et al. (2014), apresentando o melhor desempenho quando utilizado o Landsat 8 para os dois conjuntos de dados. O valor de R^2 para Landsat 5 Collection Level 1 foi o que apresentou menor desempenho entre os conjuntos de dados analisadas. Para todos os conjuntos de dados utilizadas, os valores de BIAS indicam que as estimativas de SA Landsat são em média superiores ao estimado pelo MODIS, esse comportamento também foi observado em Shuai et al. (2014).

Figura 5 - Albedo de superfície para os dois conjuntos de dados Landsat e MODIS



Santos et al. (2017) realizou estimativas de SA com dois conjuntos de dados MOD09A1 e MCD43A3, obtendo valores 0,308 e 0,253 para BIAS quando comparado a observações ao nível de superfície, respectivamente. Os dados MODIS representam

uma fonte de dados preciosa, mas conforme apresentado em Santos et al. (2017) são passíveis de erros. A análise realizada a partir dos dados MODIS completa diferentes alvos de observação da imagem, possibilitando uma investigação para diferentes tipos de cobertura do solo. A análise conjunta com a instrumentação de superfície, possibilita uma ampliação da análise realizada espacial realizada com os dados MODIS, devido ao aspecto temporal representado nas 149 imagens investigadas.

A partir desta análise, percebe-se que apesar da pequena superioridade das estimativas realizadas com conjunto de dados Landsat SR, a principal diferença entre as metodologias estaria a associada ao número de procedimentos e dados ambientais necessários para sua aplicação. Neste caso, a utilização do conjunto de dados Landsat SR requer um número menor de procedimentos e informações para o cômputo do albedo de superfície, o que facilita o desenvolvimento de aplicações em escala regional e utilizando extensas séries temporais.

2.5. Conclusões

A utilização de áreas experimentais com características climáticas e vegetação distintas contribuiu com um universo de dados com maior variação, permitindo melhor identificação de faixas de melhor desempenho para os conjuntos de dados utilizadas. Os dois conjuntos de dados Landsat investigadas apresentaram resultados similares para determinação do albedo de superfície, com indicadores de desempenho muito bons quando comparados aos dados da instrumentação de superfície. A avaliação do albedo de superfície a partir do Rn_{24h} foi uma alternativa interessante para suprir a ausência de albedômetros nas estações meteorológicas utilizadas.

Quando avaliadas a partir dos dados MODIS, as estimativas de albedo de superfície realizadas a partir do conjunto de dados Landsat SR mostraram maior similaridade. O SA derivado dos dados Landsat foram sempre superiores ao identificado com conjunto de dados MODIS. Os valores de R^2 da regressão linear entre os dados de SA MODIS e Landsat foram baixo, mas compatíveis com valores apresentado na literatura. O conjunto de dados Landsat SR demonstrou um grande potencial para aplicação em análises ambientais que requerem a utilização de extensas séries temporais, devido ao baixo número de procedimentos e demanda por dados meteorológicos para obtenção do albedo de superfície.

CAPÍTULO III - ESTIMATIVA DA EVAPOTRANSPIRAÇÃO REAL EM OLIVAL INTENSIVO UTILIZANDO O SEBAL AUTOMATIZADO

3.1. Introdução

A estimativa da evapotranspiração real (ET_r) por Sensoriamento Remoto Orbital (SRO) começou a ser desenvolvida aproximadamente na década de 1980 e evoluiu para uma variedade de abordagens (ZHANG et al., 2016). Quando as imagens de média resolução espacial são utilizadas, três abordagens são mais comuns: métodos de balanço de energia de superfície – *Surface Energy Balance* - SEB (ALLEN et al., 2007; SU, 2002; ROERINK et al., 2000; BASTIAANSSEN et al., 1998; NORMAN et al., 1995; KUSTAS, 1990), métodos empíricos (HUNSAKER et al., 2005; ER-RAKI et al., 2010) e método da temperatura da superfície - índice de vegetação (*Land Surface Temperature – LST/ Vegetation Index* - VI) (YANG et al., 1997; 1996).

O desafio para a implementação operacional utilizando os métodos de SEB para estimativas da evapotranspiração em escala regional é a necessidade de extensos dados meteorológicos, registrados em estações meteorológicas (KITE; DROOGERS, 2000). Para contornar esses problemas, os métodos SEB de uma camada (*one-source layer*) e LST-VI foram propostos, exigindo apenas uma pequena quantidade de dados oriundos de estações meteorológicas. O *Surface Energy Balance Algorithm for Land - SEBAL* (BASTIAANSSEN et al, 1998a;1998b) e o *Mapping EvapoTranspiration at high Resolution with Internalized Calibration - METRIC* (ALLEN et al, 2011; 2007) são dois exemplos amplamente utilizados desses métodos SEB de uma camada. Eles foram aplicados com sucesso em áreas agrícolas (JIMÉNEZ-BELLO et al., 2015; PAÇO et al., 2014; ALLEN et al., 2007b) e em florestas (SILVA et al., 2015; TEIXEIRA et al., 2009).

Durante muitos anos, a dependência de uma análise visual interativa tem sido um obstáculo severo para o uso dos modelos SEBAL ou METRIC para a construção de longas séries temporais, em grandes áreas (BIGGS et al., 2016; ALLEN et al., 2013). Esses algoritmos requerem um procedimento de calibração/identificação, conhecido como calibração usando modelagem inversa em condições extremas (*Calibration Using Inverse Modeling at Extreme Conditions* - CIMEC). Esta metodologia consiste na seleção de pixels de calibração/identificação para cada imagem, incluindo um pixel quente onde o fluxo de calor latente (LE) é assumido como zero, e um pixel frio onde H é assumido como zero pelo que LE é igual à diferença

entre a radiação líquida (R_n) e fluxo de calor no solo (G), ou seja, $LE = R_n - G$. De acordo com Long et al. (2011), a seleção dos pixels âncoras é o critério que mostra a maior influência sobre a estimativa de ET. Destacam-se avanços na construção de procedimentos para seleção automática dos pixels âncoras (ALLEN et al., 2013, BIGGS et al., 2016; FENG, 2015; 2014; LONG et al., 2011), com desempenho semelhante ao alcançado pela calibração/identificação manual (MORTON et al., 2013). Esses procedimentos usam, em geral, valores limiares ou quantis de LST e VI para determinar os pixels quentes e frios. Resalta-se que as avaliações dos procedimentos automáticos para obtenção da evapotranspiração têm sido realizadas a partir de procedimentos tradicionais (visuais) ou a informações provenientes de outros sensores orbitais.

Além da automação do processo de estimar ET por métodos de sensoriamento remoto, também foi feito progresso na identificação de fontes de incerteza nestes métodos (LIOU & KAR, 2014), na fusão de diferentes métodos de sensoriamento remoto (ZHANG et al. 2016) e no uso de multifonte de dados de sensoriamento remoto (LAING et al., 2017; CAMMALLERI et al., 2012).

Entretanto, apesar de todos os avanços na operacionalização das estimativas de ET, esses novos procedimentos ainda não foram suficientemente testados, portanto, é necessário transpor obstáculo da identificação visual dos pixels de referência através da identificação dos procedimentos que permitam a construção de extensas séries de ET_r (Cap. IV). Objetivo deste capítulo é propor e avaliar um procedimento automático que pudesse identificar os pixels de referência e quantificar a evapotranspiração real por sensoriamento remoto para uma área com cobertura arbórea esparsa e alta variabilidade meteorológica.

3.2. Área de estudo

No Capítulo II foi apresentada entre as áreas experimentais o olival intensivo, localizado na região de clima mediterrânico portuguesa, Figura 1A. Neste capítulo, essa área experimental foi utilizada para avaliar as estimativas de ET realizadas por uma proposta de automatização do algoritmo SEBAL. No início do período experimental (que decorreu de junho/2010 a outubro/2012) a altura média das árvores foi 3,2 metros, a média da área projetada das copas das árvores foi $5,7 \text{ m}^2$ e a média do índice de área foliar foi de $1,01 \text{ m}^2/\text{m}^2$ (CONCEIÇÃO et al., 2017). O clima da região

(temperado mediterrâneo) é caracterizado por invernos suaves e úmidos e verões muito quentes e secos. Estas características reúnem elementos que tornam complexas as estimavas de ET, como a alta variabilidade meteorológica e a cultura agrícola ser lenhosa e esparsa (FERREIRA et al., 2008; ALLEN e PEREIRA, 2009).

3.3. Material e métodos

3.3.1. Dados de entrada

i) Orbitais

Neste estudo utilizou-se o conjunto de dados Landsat SR para obtenção das bandas reflectivas e, para a banda de infravermelho termal, o conjunto de dados Landsat *Collection Level 1*. A escolha do conjunto de dados Landsat SR foram decorrentes das vantagens relatadas no Capítulo II.

Este estudo se beneficiou por a área experimental se encontrar entre duas órbitas (203 e 204) Landsat, possibilitando um maior número de imagens sem nuvens e com boa qualidade radiométrica. Os locais que compreendem duas orbitas o tempo de revisita é o dobro de uma área localizada no nadir do sensor. Entretanto, sabemos que isso é condição interessante para sensores com as características geométricas do Landsat, outros sensores podem apresentar grandes diferenças no ângulo azimutal entre um pixel no nadir e um no extremo da imagem. Na Tabela 6 são apresentadas as descrições dos dados utilizados. No total foi possível identificar 18 imagens dos satélites Landsat 5 e 7, durante os anos de 2010 e 2012.

Tabela 6 - Descrição das imagens utilizadas no olival para os estudos de evapotranspiração

Nº	Satélite	Orbita/ Ponto	Data	Nº	Satélite	Orbita /Ponto	Data
1	5	203/034	21/06/2010	10	5	203/034	12/09/2011
2	7	203/034	29/06/2010	11	5	204/034	19/09/2011
3	5	203/034	07/07/2010	12	7	203/034	06/10/2011
4	7	203/034	15/07/2010	13	5	204/034	21/10/2011
5	5	204/034	30/07/2010	14	7	204/034	29/10/2011
6	5	204/034	15/06/2011	15	5	204/034	30/10/2011
7	5	203/034	24/06/2011	16	7	203/034	21/08/2012
8	5	203/034	26/07/2011	17	7	203/034	06/09/2012
9	5	204/034	18/08/2011	18	7	204/034	13/09/2012

ii) Meteorológicos

Conforme já relatado no capítulo II, os dados experimentais das torres instaladas no território português foram cedidos pelo grupo de pesquisadores do ISA-UL, responsáveis pela instalação, operação e processamento. CONCEIÇÃO et al. (2017) descrevem detalhadamente o conjunto de sensores micrometeorológicos instalados na parcela experimental do olival. A medição das densidades de fluxo de calor latente (LE) e de calor sensível (H) foi realizada através do método das correlações turbulentas. Para tal, um anemômetro sônico tridimensional (CSAT3-D, Campbell Scientific, Inc., Logan, UT, USA) e um higrômetro de krypton (KH20, Campbell Scientific, Inc., Logan, UT, USA), foram montados em uma torre metálica a 4,5 m acima do solo e orientado segundo a direção dominante do vento (N/NW). Os dados brutos de velocidade do vento e humidade foram medidos com uma frequência de 8 Hz e médias de 30 min dos fluxos (H e LE) foram calculadas online e armazenadas por um *datalogger* (CR10X, Campbell Scientific, Inc., Logan, UT, USA). Mais informações sobre o processamento dos dados podem ser encontradas em CONCEIÇÃO et al. (2017). Neste capítulo, todas as análises foram efetuadas com valores de evapotranspiração diária.

3.3.2. Processamento de dados

i. Descrição geral do algoritmo utilizado

Conforme mencionado anteriormente, este trabalho utilizou o algoritmo SEBAL para calcular a evapotranspiração real para o cultivo intensivo de oliveiras. O algoritmo requer o cômputo do saldo de radiação (R_n) e do fluxo de calor no solo (G). Neste trabalho o R_n foi calculado segundo os procedimentos descritos em Allen et al. (2007) e utilizou-se a metodologia apresentada em Bastiaanssen (2000) para determinação do fluxo de calor no solo. Qualquer um dos métodos anteriores requer o cômputo do albedo de superfície. Em virtude dos bons resultados, da menor demanda por informações meteorológicas e do número reduzido de etapas para o cômputo do albedo de superfície, foi utilizando o conjunto de dados Landsat SR, conforme procedimentos descritos no Capítulo II deste trabalho.

Segundo Bastiaanssen et al. (1998), para aplicar o SEBAL é necessário definir, para cada imagem, dois pixels de referência (o pixel quente e o pixel frio) para calcular

iterativamente o fluxo de calor sensível (H). A obtenção direta do fluxo de calor latente (LE) ainda não é possível em sensoriamento remoto (FRENCH et al., 2015), apesar de existir alguns estudos demonstrando os procedimentos para condições bastante específicas (HILKER et al., 2013). A grande maioria dos modelos determina LE como resíduo da equação do balanço de energia (Equação 16) (ALLEN et al., 2007; SU, 2002; ROERINK et al., 2000; BASTIAANSSEN et al., 1998; NORMAN et al., 1995). Teoricamente, o LE pode ser obtido como resíduo do saldo de radiação (Rn), fluxo de calor no solo (G) e fluxo de calor sensível (H) que são possíveis de serem quantificados por sensoriamento remoto.

$$R_n = G + H + LE \quad (16)$$

Apesar dos fluxos instantâneos serem importantes fontes de informação ambiental, os valores diários são os que normalmente apresentam maior interesse prático. Procedimentos de *upscaling* temporal são assim aplicados aos produtos instantâneos para os converter em totais diários.

Esse procedimento é possível graças ao comportamento diário da fração evapotranspirativa ($ETF = LE/(R_n - G)$). Segundo Shuttleworth et al. (1989), a ETF obtida entre o intervalo de 10:00 às 14:00 horas (horário local) apresenta o valor igual à média diária da ETF. Crago (1996) afirma que em dias com pouca nebulosidade a ETF apresenta pouca variação durante o período diurno. Este fenômeno ocorre devido a dependência da ETF sobre o saldo de radiação e tendência de progressões na umidade, temperatura, resistência da superfície reduzirem as variações sistemáticas da ETF. Como as imagens do Landsat são obtidas por volta das 10 - 11 horas (horário local) é possível utilizar a relação da ETF e obter a evapotranspiração na escala diária (ET_{r24h}) com uma única passagem do sensor na região de estudo.

A seleção dos pixels de referência, que tradicionalmente prevê a interação humana para identificação visual dos dois pixels em uma imagem de satélite, foi substituída no presente trabalho por um procedimento de seleção automática.

ii. Descrição do processo de automatização da seleção dos pixels âncoras

Para cada momento (imagem) estudado é necessária a calibração/identificação de dois pixels em condições extremas (CIMEC) onde, por definição, os fluxos de calor

sensível e calor latente (evapotranspiração) são conhecidos no momento da passagem do satélite (ALLEN et al., 2011). Neste estudo, a seleção automática dos pixels de referência usou os limiares do Índice de Vegetação de Diferença Normalizada (NDVI), quantis de temperatura da superfície (TS), fluxo de calor sensível (H) e análise de homogeneidade dos pixels vizinhos, conforme apresentado na Tabela 7.

Tabela 7 - Descrição das etapas de seleção dos pixels de referência

Etapa	Descrição	Critério de seleção pixel frio/molhado	Critério de seleção pixel quente/seco
1	Selecionar um conjunto de pixels com base no seu valor de NDVI	NDVI < 0	0,15 < NDVI < 0,20
2	Do grupo isolado na etapa 1, selecionar um subconjunto com base no valor de TS	Valor observado de TS mais próximo do quantil de ordem p considerado	Valor observado de TS mais próximo do quantil de ordem p considerado
3	Do grupo isolado na etapa 2, selecionar um subconjunto com base no valor de Rn - G	25 % dos mais altos e mais baixos valores de Rn - G são removidos	
4	Com base na homogeneidade dos pixels vizinhos, selecione um pixel do grupo restante	Número máximo de pixels vizinho com NDVI < 0	Valor mínimo do coeficiente de variação do NDVI

Fonte: Adaptado de Cunha et al. (2018)

Relativamente à escolha do pixel quente, o procedimento começa por selecionar os pixels com um baixo valor de NDVI - característica do solo nu (Etapa 1), seguido de filtragem dos pixels candidatos que tenham um valor alto para TS (de acordo com o quantil de ordem p considerado) (Etapa 2) e excluindo os que apresentem valores de Rn-G extremos (Etapa 3). Finalmente, seleciona-se o pixel quente em um espaço de pixels relativamente homogêneos (Etapa 4).

A escolha do pixel frio segue um procedimento semelhante ao descrito para o pixel quente. Em primeiro lugar, os pixels candidatos são selecionados entre aqueles com NDVI negativo, correspondentes a corpos aquáticos (Etapa 1). Como a água possui um alto calor específico, a temperatura dos corpos d'água reage lentamente às mudanças nas condições meteorológicas, pelo que a temperatura da superfície deve estar próxima dos valores médios da TS dos corpos d'água (Etapa 2). Tal como no pixel quente, os pixels selecionados são aparados (Etapa 3) para remover os que apresentam valores de Rn-G mais extremos e os pixels vizinhos são analisados para

garantir que o pixel frio está localizado longe da borda de um corpo de água (Etapa 4).

Neste trabalho optou-se por testar cinco alternativas de seleção dos pixels de referência com base em variações na ordem p do quantil de temperatura de superfície considerado na Etapa 2, conforme valores descritos na Tabela 8.

Tabela 8 - Ordem do quantil utilizada para selecionar os pixels âncora na Etapa 2

Teste	pixel quente	pixel frio
1	0,85	0,5
2	0,95	0,5
3	0,99	0,5
4	0,99	0,2
5	0,99	0,8

3.3.3. Comparação entre os valores observados de ET e os estimados por SRO

Neste estudo, as análises foram sempre efetuadas na escala diária a partir da comparação dos valores de evapotranspiração observados pelo método das correlações turbulentas e os estimados pela técnica de SRO. Tal como referido no Capítulo II, as medições efetuadas ao nível da superfície podem apresentar escala espacial de visualização (*footprint*) diferente dos sensores orbitais. Além disso, para o sistema de correlações turbulentas, os *footprints* não são estáticos. Cada um dos valores observados representam uma área a barlavento dos sensores a qual é resultado das condições atmosféricas no momento da medição.

Häusler et al. (2018) realizaram uma análise simplificada do *footprint* (SCHUEPP et al., 1990) que permitiu avaliar a contribuição relativa dos fluxos provenientes das diferentes áreas dentro da parcela para o fluxo total medido. De acordo com os resultados destes autores, mais de 85% do LE medido pelo método das correlações turbulentas veio de uma área a barlavento a menos de 140 m do ponto de medição (torre).

Os cinco testes (Tabela 8) geram valores estimados para ETr por sensoriamento remoto para cada uma das datas estudadas e foram comparados com os respectivos valores ETr observados pelo sistema de correlações turbulentas. Um teste foi classificado como de melhor desempenho quando a comparação com os dados observados indicar declividade da reta de regressão linear mais próximo de 1, menores valores de RMSE e BIAS. Entretanto, um teste pode apresentar bom desempenho para uma data, mas apresentar valor global ruim para os parâmetros

que avaliam o teste. Optou-se por selecionar, em cada data estudada, o valor de ETr estimado por sensoriamento remoto que mais aproximou-se do valor numérico observado pelo sistema de correlações turbulentas. Esses valores de ETr foram chamados de melhores resultados. Numa seleção visual dos pixels âncoras (método tradicional), qualquer um dos pixels âncoras identificados pelos cinco testes poderia ser selecionado, pois todos eles satisfazem os critérios básicos de pixel quente, encontrar-se numa área desnuda, e de pixel frio, localizar-se numa superfície com água. Então, ao indicar os melhores resultados para todos os testes, se estar apresentando uma solução do que seria possível obter numa análise visual.

3.3.4. Análise de influências

i) Precipitação

No SEBAL admite-se que a evapotranspiração no pixel quente é igual a zero ($LE=0$), mas isso dependerá da quantidade de água disponível no solo. A precipitação é um dos principais elementos para dinâmica da água para solo. O pixel quente que será identificado sobre uma área de solo desnudo, definida pelo intervalo de NDVI entre 0,15 e 0,20, podendo a temperatura de superfície deste pixel ser influenciada por variações na umidade do solo. Como a temperatura de superfície dos pixels de referência é o principal elemento que diferenciará os cinco testes estudados, é importante avaliar se a precipitação provoca alguma influência na seleção adequada dos pixels.

Para avaliar a influência da precipitação sobre a evapotranspiração obtida por cada um dos testes utilizou-se os dados de precipitação disponibilizados pelo *Climate Hazards group Infrared Precipitation with Stations-CHIRPS* (FUNK et al., 2015; KATSANOS et al., 2016). O CHIRPS é um produto de precipitação quase global, de resolução espacial $0,05^\circ$ (aproximadamente 5 km de grade), desenvolvido para monitorar as mudanças ambientais da terra (FUNK et al., 2015). No presente estudo foram extraídos os totais pluviométricos dos produtos CHIRPS no intervalo de 30 dias antecedentes a passagem do sensor para todos os pixels quentes identificados nos cinco testes avaliados neste trabalho. Os totais pluviométricos para cada um dos pixels quentes dos cinco testes foram comparados com as diferenças entre os valores de ETr no campo e orbital (cinco testes).

ii) Direção dos ventos

A análise simplificada do *footprint* pode conter alguns erros na compatibilização das escalas de medição da torre e dos sensores orbitais. Neste estudo, foram analisadas as direções do vento para identificar a possibilidade de influência de áreas externas ao olival na mensuração da ET pelo sistema de correlações turbulentas.

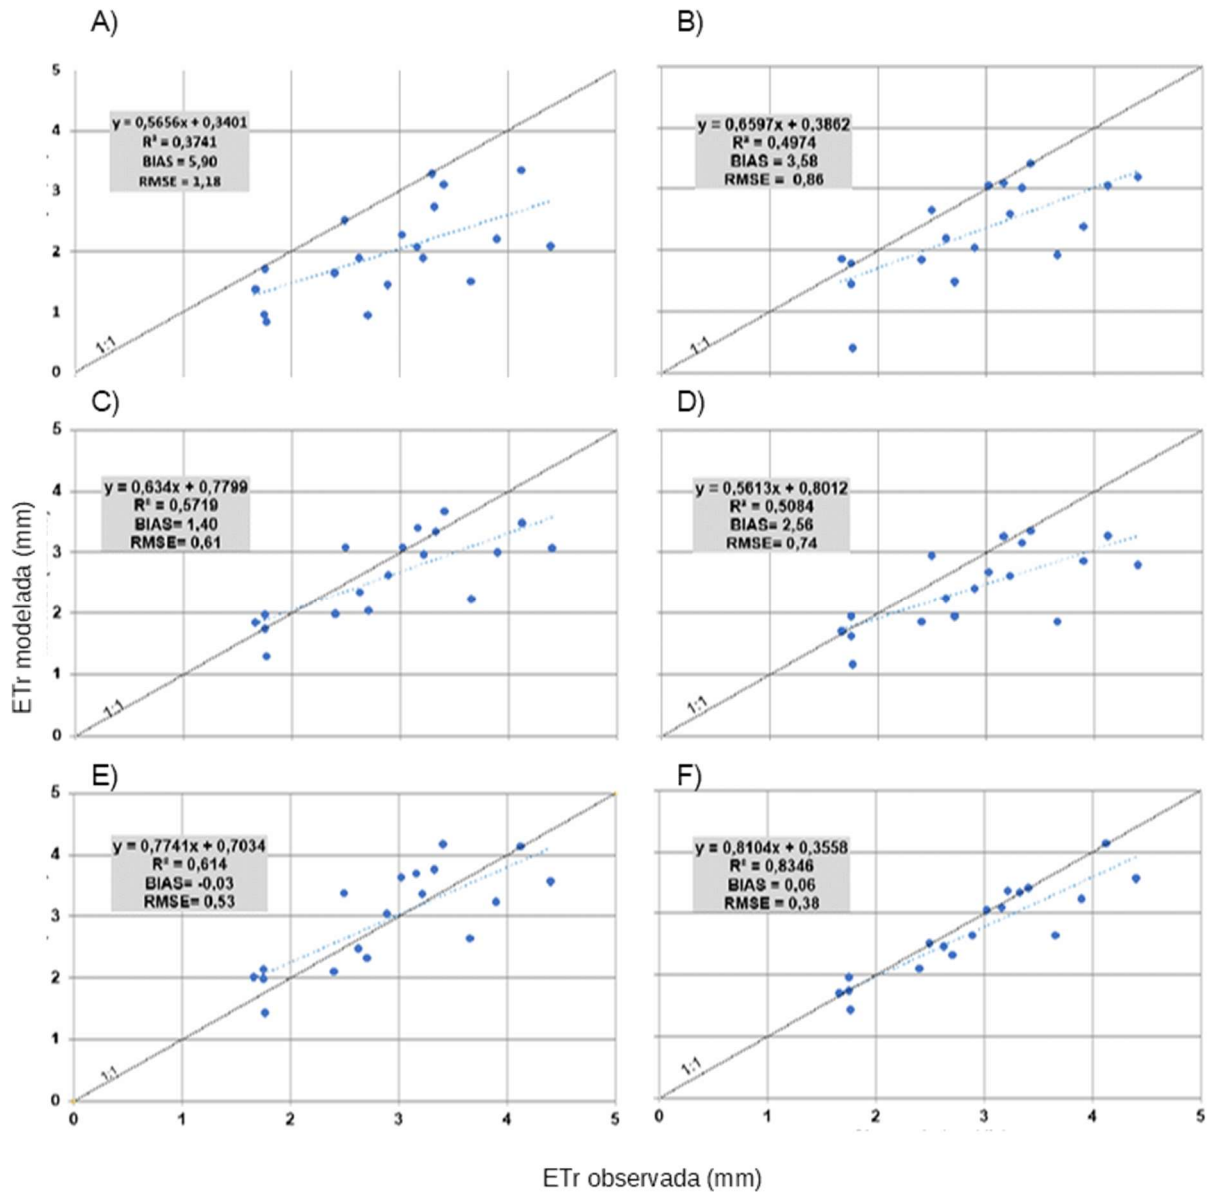
3.4. Resultados e discussão

Na Figura 6 são apresentados os resultados para os cinco testes propostos neste capítulo e um gráfico adicional com os melhores resultados para os cinco testes. Em cada gráfico estão mostrados os valores da equação da reta, R^2 , BIAS e RMSE. O teste 5 foi o que apresentou o melhor desempenho quando analisados a declividade da reta de regressão linear, RMSE e BIAS. Uma análise visual dos gráficos revela que a maior parte dos valores modelados foi menor que os observados, comportamento numericamente destacado no BIAS. Percebe-se que o teste 5 foi o único que não apresentou subestimação, sendo os testes 1, 2 e 4 os que apresentaram as maiores diferenças. A subestimação também foi observada no trabalho desenvolvido por Hausler et al. (2017) para mesma área de estudo, que realizou estimativas de evapotranspiração com o modelo *Simplified Two-Source Energy Balance* (STSEB) usando dados do satélite Landsat 5. No referido trabalho, a maior diferença foi observada para a imagem do dia 24/06/2011, com 0,6 mm/dia. Para o mesmo momento, o presente estudo obteve uma diferença 0,83 mm/dia entre o valor observado e modelado para teste 5. A tendência em subestimar não foi observada em Pôças et al. (2014) quando aplicaram o METRIC para uma área de olival super-intensivo na região portuguesa de clima mediterrânico, obtendo superestimação em dez dos doze momentos avaliados. A maior diferença entre os dados observados e modelados para o teste 5 foi de 1,01 mm/dia, em Pôças et al. (2014), chegou a 1,24 mm/dia.

Ao analisar os valores de RMSE para os cinco testes (Figura 6), percebe-se que o teste 5 apresentou, novamente, o melhor resultado entre os testes efetuados neste estudo. Para os parâmetros da equação da reta, observa-se que o teste 5 foi o que apresentou a inclinação e R^2 mais próximos de 1, indicando melhor desempenho.

Entretanto, este desempenho é inferior ao observado por Pôças et al. (2014) quando utilizaram o METRIC numa identificação manual/visual dos pixels âncoras.

Figura 6 - Valores de ET (mm) modelados (y - vertical) e observados (x - horizontal) para o teste 1 (A), teste 2 (B), teste 3 (C), teste 4 (D), teste 5 (E) e melhores resultados (F)



Há um número reduzido de estudos envolvendo métodos automáticos para estimativa da evapotranspiração. Esses estudos utilizam estratégias diferentes para avaliar o desempenho. Allen et al. (2013) analisaram o desempenho a partir dos valores de temperatura de superfície dos pixels âncoras obtidos por uma identificação manual/visual e automática. No entanto, a comparação com o valor de TS não representa uma avaliação coerente, visto que os valores modelados a partir da

identificação manual/visual também são passíveis de erros, conforme observado em Pôças et al. (2014). Biggs et al. (2016) utilizaram a fração evapotranspirativa para realizar as análises de desempenho do SEBAL com identificação automática dos pixels âncoras para dados Landsat, obtendo o erro médio de 14% para estimativas quando comparado ao obtido por técnicas de correlações turbulentas em área irrigadas de arroz e milho. Biggs et al. (2016) demonstraram que as estimativas de ET automáticas realizadas com os dados Landsat são superiores ao observado no produto evapotranspiração MODIS (MOD16), que obteve 50% de erro médio para mesmas áreas irrigadas de arroz e milho. Quando utilizado o teste 5 do método automático apresentado neste estudo o erro médio obteve desempenho bem superior (3%) ao identificado por Biggs et al. (2016). Métodos automáticos para identificação dos pixels âncoras também foram avaliados em Evans (2014). Os melhores métodos obtiveram BIAS entre 0.017 e 0.131. O desempenho apresentado pelo teste 5 do método automático de identificação dos pixels âncoras apresentados neste estudo demonstra desempenho superior ou equivalente aos estudos que usam abordagens similares. Entretanto, apesar do bom desempenho do teste 5, os valores modelados apresentaram pequenas oscilações, positivas e negativas, que podem ser resultantes de eventos que antecedem as medições (precipitação) ou na compatibilização das escalas de medição entre os sensores orbitais e de superfície.

A Tabela 9 apresenta as informações sobre os elementos que foram destacados com possibilidade de influenciar os valores de ET modelados (ET Mod) e observados (ET Obs). A velocidade e direção dos ventos podem ter contribuído para que as medições realizadas na torre tenham sofrido influência de áreas externas ao olival. Na Figura 5, observa-se a existência de um reservatório localizado a sul da torre e ao norte uma área com outro cultivo que pode passar períodos com o solo desnudo. Segundo Conceição et al. (2017) a direção dominante dos ventos é a norte/noroeste, mas para maioria dos dias monitorados neste estudo (Tabela 9) a direção média foi sul/sudoeste. Neste caso, o reservatório localizado ao sul da torre poderia estar contribuindo para aumentar os valores de ET observados no olival. No entanto, uma análise de footprint mais detalhada e com métodos mais precisos é necessária para avaliar as possíveis influências sobre as medições de evapotranspiração registradas pelo sistema de correlações turbulentas.

Tabela 9 - Informação sobre os fatores que podem influenciar a evapotranspiração observada (ET Obs) e modelada (ET Mod). TSpq T5 - valores de TS para o pixels quente do teste 5; TSpq melhor – valores de TS para o pixel quente para os testes que apresentaram melhor desempenho; VelMéd diária (m/s) – velocidade média diária do vento; DirVento média diária (Graus) - Direção média diária do vento; PreAcum (30 dias) (mm) – Precipitação acumulada nos período de 30 dias que antecede a passagem do sensor.

Nº	Data	ET Obs – ET Mod (mm)	TSpq T5 – TSpq melhor (°C)	VelMéd diária (m/s)	DirVento média diária (Graus)	PrecAcum (30 dias) (mm)
1	21/06/2010	-0.15	0.0	1.067393	SE	15.15
2	29/06/2010	0.67	0.0	1.411987	SE	18.76
3	07/07/2010	1.01	0.0	0.291541	SE	20.90
4	15/07/2010	-0.54	-1.8	2.659568	SSE	10.01
5	30/07/2010	-0.16	0.0	1.049789	E	2.14
6	15/06/2011	-0.61	-1.2	2.242381	SSE	88.28
7	24/06/2011	-0.01	0.0	0.353747	WSW	41.81
8	26/07/2011	0.83	0.0	1.806662	SE	1.94
9	18/08/2011	-0.77	-1.2	1.000381	SE	0.00
10	12/09/2011	-0.44	0.0	0.912327	SSE	23.78
11	19/09/2011	0.39	0.0	0.447692	SSW	25.93
12	06/10/2011	0.16	0.0	0.841703	SSE	2.16
13	21/10/2011	0.33	0.0	0.779378	SE	0.00
14	29/10/2011	0.29	0.0	0.541727	S	55.24
15	30/10/2011	-0.23	0.0	0.308756	SE	55.24
16	21/08/2012	-0.88	-1.7	0.804453	ESE	0.00
17	06/09/2012	-0.34	0.0	0.496258	S	0.00
18	13/09/2012	-0.39	0.0	1.363624	S	0.00

Para analisar a possível influência da precipitação sobre a seleção do pixel quente, e conseqüente determinação das taxas evapotranspirativas, são apresentados na Tabela 9 os valores da diferença entre Temperatura de Superfície (TS) para os pixels quentes identificados pelo teste 5 (Tspq T5) e a seleção dos valores dos pixels quentes que melhor representaram a evapotranspiração entre os cinco testes estudados (TSpq melhor) e os valores de precipitação acumuladas nos 30 dias que antecedem cada momento estudado (PrecAcum). Para simplificar as análises selecionam-se situações semelhantes e extremas nos valores de PrecAcum descritos na Tabela 9. Os dias 29 e 30/10/2011 apresentam os mesmos totais pluviométricos, mas com valores superestimando e subestimando o valor de ET

observado. No intervalo de trinta dias o maior total precipitado ocorreu para o dia 15/06/2011 e o menor total precipitado destacado nesta análise ocorreu no dia 18/08/2011. Os dois dias indicados apresentam superestimação do valor de ET, mesmo apresentando condição inversa antecedente à passagem do sensor na região. Essa análise da precipitação contraria o procedimento de automatização da seleção dos pixels de referência descrito em Allen et al. (2013), quando sugere-se que o refinamento da seleção do pixel quente possa ser realizado com a análise das precipitações antecedentes à passagem do sensor.

3.5. Conclusões

A seleção dos pixels âncoras, necessária nos algoritmos SEBAL e METRIC, é geralmente realizada a partir da interação humana (manual/visual). Neste trabalho, este procedimento foi substituído com sucesso por um processo automático de seleção desses pixels. Numa análise comparativa a outros estudos com abordagem semelhante, percebe-se que o método proposto (teste 5) obteve desempenho superior ou equivalente, evidenciando-se como uma proposta interessante para geração de extensas séries temporais de dados de evapotranspiração real. No entanto, algumas diferenças apresentadas entre os valores observados e modelados podem ser decorrentes de outros tipos de cobertura presentes na área externa ao olival. Para melhor avaliação da contribuição de outros tipos de cobertura do solo nas medições de evapotranspiração realizadas pelo sistema de correlações turbulentas são necessários métodos mais precisos para quantificar o footprint. A possível influência de fatores sazonais, como a precipitação, na seleção do pixel quente não ficou evidenciada pela análise dos dados realizada.

CAPÍTULO IV - SERVIÇO COMPARTILHADO DE ALTO DESEMPENHO PARA ESTIMAR A EVAPOTRANSPIRAÇÃO USANDO IMAGENS LANDSAT

4.1. Introdução

Décadas de aquisição de dados de sensoriamento remoto produziram enormes quantidades de dados com referências de espaço e tempo (HANSEN et al., 2013). Múltiplos sensores orbitais continuam adquirindo novos dados espaciais diariamente (SONGNIAN et al., 2016). Esta enorme coleção de dados pode ser explorada para extrair informações valiosas, atendendo às necessidades de uma grande e diversificada comunidade de usuários.

Em particular, usando algoritmos específicos para processar imagens provenientes de sensores orbitais, é possível monitorar continuamente fluxos de água e energia na superfície terrestre (THOMAS et al., 2012; CAMMALLERI et al., 2012; GAO et al., 2011). Na verdade, uma série de algoritmos foi proposta para estimar a evapotranspiração usando imagens de satélite (ZHANG et al., 2016; LIOU & KAR, 2014). Além das estimativas de evapotranspiração, esses algoritmos também podem gerar estimativas de albedo da superfície terrestre, índices de vegetação, temperatura da superfície terrestre, radiação líquida, fluxo de calor no solo e fluxo de calor sensível.

Algoritmos para estimar a evapotranspiração têm sido amplamente utilizados em vários países e áreas sujeitas a diferentes condições climáticas (WAN et al., 2015; MU et al., 2011; ALLEN et al., 2011; TANG et al., 2009; ANDERSON et al., 2007; BASTIAANSSEN et al., 2002; CARLSON et al., 1995). Muitas aplicações utilizam os índices gerados por Sensoriamento Remoto Orbital (SRO) (MIRA et al., 2016; ZHU et al., 2016; WANG et al., 2016; WAGNER; WASKE, 2016; FRENCH et al., 2015). Por exemplo, os índices de vegetação produzidos, definidos como medidas unidimensionais, funcionam como indicadores de vegetação fotossinteticamente ativa (JI et al., 2011), pelo que, variações na cobertura do solo podem ser estimadas analisando suas tendências (WAGNER et al., 2013; JONG & BRUIN, 2012).

Apesar de seu uso amplo, as estimativas de evapotranspiração relatadas na literatura são frequentemente restritas a áreas reduzidas e/ou curtos períodos de tempo (NUMATA et al., 2017; SEMMENS et al., 2016; LIOU & KAR, 2014) e/ou baixa resolução espacial (ZHANG et al., 2016; LI et al., 2015; NUTINI et al., 2014). Este estado de coisas deve-se principalmente às altas demandas computacionais impostas pelas implementações dos algoritmos que estimam a evapotranspiração, quando eles

tomam como entrada várias décadas de imagens com resolução espacial média (por exemplo, resolução espacial de 30 metros) atualmente disponíveis.

Essas demandas computacionais envolvem muitos recursos, uma vez que as implementações dos algoritmos são geralmente intensivas tanto de CPU quanto de memória, e o arquivamento dos dados de saída gerados consome uma quantidade substancial de recursos de armazenamento (WANG et al., 2015; YANG et al., 2015; MA et al., 2015). Por exemplo, a implementação do *Surface Energy Balance Algorithm for Land* (SEBAL) (Capítulo III) requer pelo menos 28GB de memória principal, e leva entre 80 e 113 minutos para processar uma imagem de Landsat de 170 km x 185 km e 30 metros, usando 8 núcleos de CPU; o tamanho dos dados de saída gerados para cada uma dessas imagens, que compreendem, além da evapotranspiração, outras 8 variáveis, é da ordem de 1,8GB.

Além disso, há pouca cooperação entre usuários que buscam reutilizar os dados de saída gerados pelas execuções dos algoritmos realizados por outros. Devido às capacidades de computação locais restritas, um usuário normalmente processa dados de entrada que cobrem apenas a menor área possível, que permite a si mesmo produzir resultados úteis, e armazena os dados de saída em sua infraestrutura de processamento local.

O processamento de apenas pequenas áreas reduz as chances de dois usuários produzirem dados de saída que contemplem áreas de interesse mútuo. Além disso, o armazenamento fragmentado de dados de saída nos discos locais dos computadores pessoais dos usuários limita a visibilidade e a acessibilidade dos dados produzidos.

A reutilização é ainda mais prejudicada pela falta de uma cultura de armazenamento de informações de proveniência de dados associadas aos dados de saída gerados (SIMMHAN et al., 2005). Esse problema é exacerbado por muitas peculiaridades dos fluxos de trabalho tipicamente usados para gerar estimativas de evapotranspiração, incluindo: i) a sensibilidade dos algoritmos até mesmo a pequenas discrepâncias nas variáveis de entrada (LONG et al., 2011); ii) a necessidade de pré-processar a entrada - por exemplo, para detectar nuvens na imagem (HELMER & RUEFENACHT, 2005), permitindo a realização de diferentes procedimentos de pré-processamento; e, iii) o fato de partes de alguns algoritmos terem de ser especificamente descritos - por exemplo, a seleção de pixels âncoras (quente e frio) na imagem (BIGGS et al., 2016), exigida por certos algoritmos, permite que o mesmo

algoritmo possa ser implementado de diferentes maneiras. Tudo isso pode levar a dados de saída bastante diferentes para o processamento das mesmas imagens de entrada. Assim, sem um rastreamento preciso de como uma imagem de entrada específica foi processada, é improvável que os dados de saída associados possam ser úteis para outros usuários.

Finalmente, não apenas o fluxo de trabalho completo é explicitamente especificado, mas também é executado em grande parte de forma assistida pelo usuário. Por exemplo, é comum que o download de dados de entrada, seu pré-processamento e até mesmo a execução de partes do próprio algoritmo - ex. a seleção de pixels âncora (quente e frio) em alguns dos algoritmos disponíveis - é feita com a intervenção direta do usuário executando o fluxo de trabalho. Avanços recentes propuseram formas de automatizar a seleção dos pixels âncoras (BIGGS et al., 2016; FENG, 2015; MORTON et al., 2013; ALLEN et al., 2013; LONG et al., 2011; e Capítulo III), mas a automação completa de todo o fluxo de trabalho vai muito além disso.

O objetivo deste capítulo é descrever, demonstrar e avaliar o desempenho de um serviço que fornece automação completa de todo o fluxo de trabalho usado para estimar a evapotranspiração a partir de dados de entrada fornecidos pela família de satélites Landsat.

O serviço de infraestrutura de computação em nuvem fornece suporte consistente para a execução paralela dos algoritmos envolvidos, agilizando o processamento de imagens de resolução espacial média (30 metros), abrangendo longas séries temporais (mais de 4 décadas). Além disso, fornece suporte para a coleta automática de dados de proveniência precisos e o arquivamento seguro e confiável dos dados de saída gerados e seus metadados associados, facilitando compartilhamento de dados. O conteúdo estendido deste capítulo foi apresentado ao periódico *Environmental Modelling & Software*¹ e encontra-se em fase de revisão.

4.2. Material e métodos

¹ Cunha, J.; Pereira, T. E.; Pereira, E.; Rufino, I.; Galvão, C.; Valente, F.; Brasileiro, F. A High-Throughput Cooperative Service to Estimate Evapotranspiration Using Landsat Imagery. *Environmental Modelling & Software* (em revisão).

O serviço que é apresentado neste capítulo foi desenvolvido no âmbito do projeto *European Union - Brazil Cloud Connect* (<http://www.eubrazilcloudconnect.eu/>) que prevê processamentos que ocorrem em segundo plano e em tempo real. O sistema Serviço Automático de Processamento do SEBAL (SAPS) utiliza processamentos que ocorrem em segundo plano para aquisição de dados meteorológicos e imagens de satélite e execução do algoritmo SEBAL (BASTIAANSSEN, 2000). A interação com os usuários para seleção de área e período de interesse, assim como download de dados processados, ocorre em processamento em tempo real. As imagens do satélite Landsat são obtidas diretamente do repositório de imagens da USGS (Serviço Geológico Americano) por meio de um serviço computacional (*Application Programming Interface* - API) desenvolvido especificamente para transferência de dados. Utilizam-se imagens dos satélites LANDSAT 5, 7 e 8, que apresentam resolução espacial de 30 metros e temporal de 16 dias. Apesar da grande capacidade de processamento prevista para o sistema, neste capítulo será apresentado uma aplicação para todo o conjunto Landsat disponível para a órbita/ponto 215/065, reunindo 670 imagens, no semiárido paraibano.

As informações sobre o clima, necessárias para a aplicação do algoritmo SEBAL, são selecionadas com base na localização das imagens de satélite e horário da passagem do sensor na região de interesse. São necessários dados sobre a velocidade do vento, temperatura e umidade do ar. Os dados climáticos utilizados nesta aplicação são obtidos por meio de uma API (<https://www7.ncdc.noaa.gov/rest/>) desenvolvida pela Administração Oceânica e Atmosférica Americana (National Oceanic and Atmospheric Administration, NOAA).

A aplicação do SEBAL, tradicionalmente, envolve a interação com o usuário para identificação dos pixels âncoras. Neste estudo, serão utilizados os procedimentos relatados no Capítulo III, na configuração que apresentou melhor desempenho.

4.2.1. Arquitetura do sistema SAPS

O sistema SAPS usado neste estudo foi desenvolvido pelo grupo de pesquisadores do Laboratório de Sistemas Distribuídos em parceria com o grupo do Laboratório de Hidráulica, ambos da UFCG. O autor desta tese integra o grupo do Laboratório de Hidráulica e participou ativamente das discussões para construção do sistema. O sistema SAPS usa recursos de computação de uma federação de

provedores de IaaS (*Infrastructure as a Service*) para execução de todo o fluxo de trabalho do algoritmo SEBAL. Essa federação é formada pela agregação dos recursos ociosos disponíveis em cada provedor membro da federação. Provedores IaaS geralmente mantêm uma fração de seus recursos computacionais ociosos para lidar com variações da demanda por seus recursos bem como para tratar falhas temporárias na infraestrutura. Do ponto de vista de um provedor, juntar-se a uma federação é bastante conveniente por uma razão simples: é possível ter acesso a um conjunto de recursos computacionais maior do que os recursos locais.

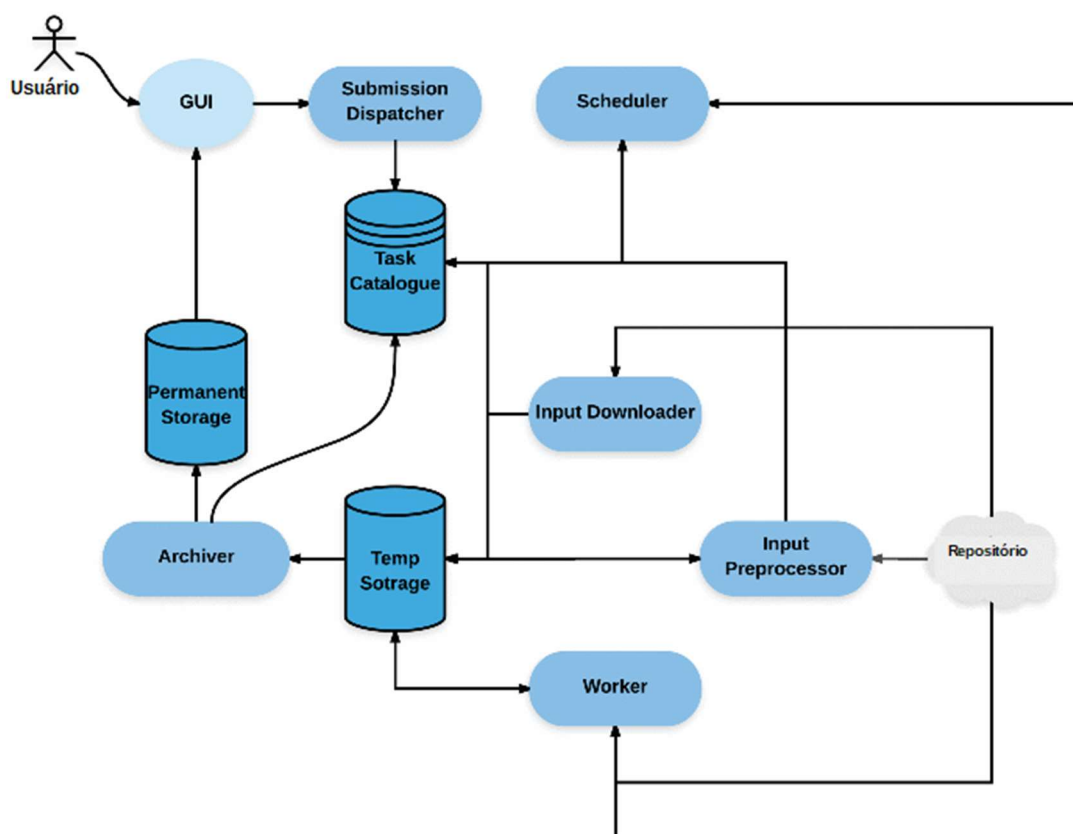
Nesta seção, são descritos em linhas gerais os componentes presentes na arquitetura do sistema SAPS, ilustrada na Figura 7. Todos esses componentes são implantados em máquinas virtuais providas por recursos da federação. Além desses componentes, o SAPS utiliza o *middleware* Fogbow (BARROS et al., 2015) para alocar e acessar os recursos federados. Toda a arquitetura do sistema SAPS foi desenvolvida utilizando a linguagem de programação JAVA. As funções de mudanças de projeção geográfica, recorte espacial e álgebra de bandas espectrais ligadas a execução algoritmo SEBAL utilizaram a linguagem de programação R.

O usuário interage com o sistema através de um componente de interface de usuário gráfico (*Graphical User Interface - GUI*) que serve como *front-end* (etapa inicial) para o componente *Submission Dispatcher*. Através da GUI, o usuário pode especificar a região de interesse que pode abranger mais de uma imagem (cena) Landsat, o período de tempo que se deseja processar, bem como a versão do software para executar os três estágios do fluxo de trabalho para calcular a evapotranspiração: *download* dos dados climáticos e orbitais, pré-processamento (identificação de nuvens) e execução do algoritmo SEBAL.

Com esses dados, o componente GUI cria um ou mais pedidos de processamento e os envia para o *Submission Dispatcher*, um após o outro. Cada pedido criado corresponde ao processamento de uma única cena (para uma localização específica no espaço e no tempo). Ao receber um pedido, o *Submission Dispatcher* verifica primeiro a consistência do pedido. Se o pedido não passar nesta verificação, uma mensagem de erro será retornada para o componente GUI. Caso contrário, o *Submission Dispatcher* cria uma tarefa associada à solicitação no banco de dados do *Service Catalog* e retorna a identificação da tarefa para o componente

GUI. A GUI pode mais tarde usar essa identificação de tarefa para consultar o *Service Catalog* para o *status* da solicitação associada.

Figura 7- Componentes do sistema SAPS

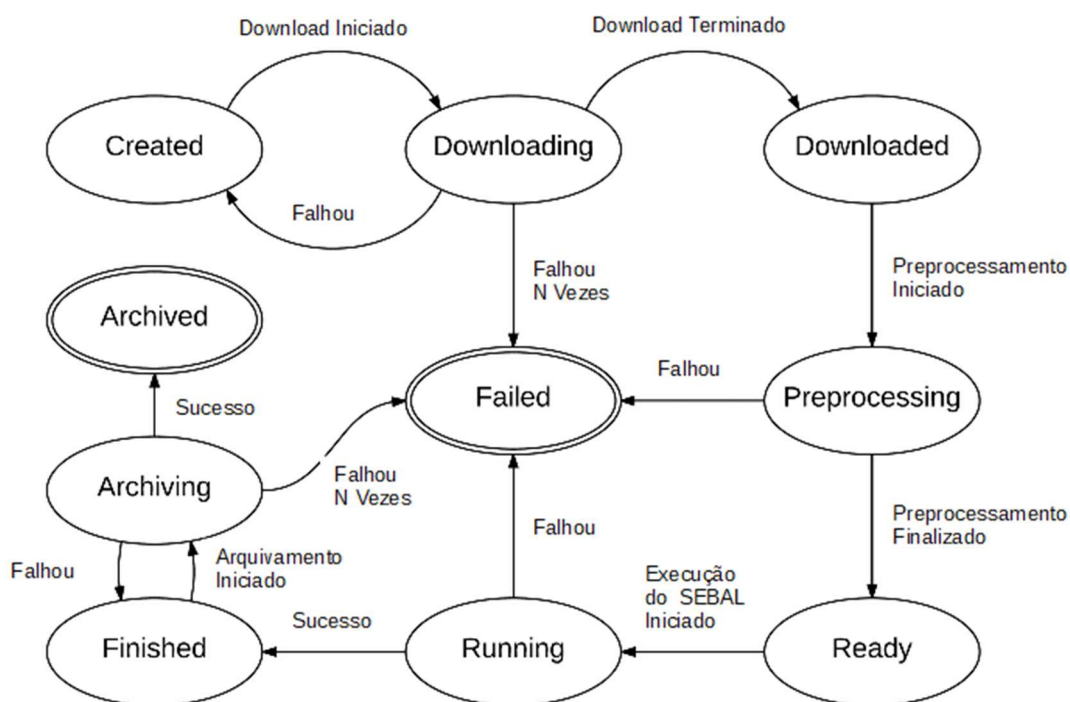


Fonte: Cunha et al. (2018A)

O *Submission Dispatcher* é responsável por atribuir prioridades às tarefas, garantindo que as tarefas de diferentes usuários sejam processadas de forma justa. As tarefas também têm um estado associado e é usado para indicar qual componente deve atuar em seguida no processamento da tarefa, sempre seguindo a prioridade estabelecida pelo *Submission Dispatcher*. Assim, o banco de dados do *Service Catalog* funciona como um canal de comunicação entre todos os componentes do serviço. Isso requer que um mecanismo de sincronização esteja no lugar, de modo a evitar inconsistências causadas por condições de aumento de demanda quando vários componentes acessam o banco de dados ao mesmo tempo. Figura 8 apresenta os diferentes estados que podem ser associados a uma tarefa e os eventos que desencadeiam transições de estado.

As tarefas adicionadas ao *Service Catalog* pelo *Submission Dispatcher* têm seu estado inicial configurado para criada (*Created*). O componente *Input Downloader* continua a verificar o *Service Catalog*, procurando tarefas no estado *Created*. Ao encontrar essas tarefas, o *Input Downloader* define o estado da prioridade máxima para descarregando (*Downloading*). Quando todos os dados de entrada foram baixados, o *Input Downloader* define o estado da tarefa para *Downloaded*. Se ocorrer um erro durante o download dos dados de entrada, o estado da tarefa é configurado de volta para *Created*, para que o *download* possa ser repetido por um número fixo de vezes; se o *download* falhar muitas vezes, o estado da tarefa é definido como falha (*Failed*).

Figura 8 - Estado das tarefas de trabalho



Fonte: Cunha et al. (2018A)

O *Input Preprocessor* é responsável pelo processamento de tarefas no estado *Downloaded*. Ao detectar tarefas neste estado, o *Input Preprocessor* define o estado da prioridade mais alta para *Preprocessing* e inicia o pré-processamento dos dados que foram previamente baixados. Quando os dados de entrada são pré-processados com sucesso, o *Input Preprocessor* define o estado da tarefa como *Ready*. Caso contrário, se ocorrer uma falha durante o pré-processamento, o estado da tarefa será definido para *Failed*.

O componente *Scheduler* é responsável por gerenciar o processamento real de uma tarefa. Faz isso com o suporte de um componente *Worker*. Sempre que o *Scheduler* detecta que há tarefas no estado *Ready*, ele transita a tarefa de maior prioridade neste estado para o estado *Running* e instrui o *Worker* a processá-lo, para iniciar a execução da implementação do algoritmo SEBAL, consumindo os dados de entrada pré-processados associados à tarefa. O *Scheduler* então monitora esse processamento. Isso garante que as execuções bem-sucedidas tornem as tarefas correspondentes à transição para o estado *Finished*, enquanto que os malsucedidos os levam à transição para o estado *Failed*.

Finalmente, o componente *Archiver* coleta os dados e os metadados gerados por tarefas cujo processamento tenha sido concluído ou falhado com sucesso. Sempre que o *Archiver* detecta que as tarefas inseriram o estado *Finished* ou *Failed*, ele altera o estado da tarefa de prioridade mais alta para *Archiving* e inicia o procedimento de arquivamento.

Os dados e metadados associados são copiados do armazenamento temporário para o armazenamento permanente, onde eles são feitos de forma segura e confiável para os usuários. Naturalmente, a implementação do serviço deve definir uma visão comum sobre onde os dados e os metadados devem ser armazenados, de modo que o *Archiver* possa buscá-los do *Temporary Storage* para o *Permanent Storage*, a partir do qual eles podem ser acessados posteriormente pela GUI.

Após a conclusão, se a operação for bem-sucedida, o estado da tarefa é definido como *Archived*. Caso contrário, o estado é configurado de volta ao estado em que a tarefa foi antes de se transferir para *Archiving*, de modo que uma nova tentativa de arquivar seus dados de saída seja testada. Quando o *Archiver* transita uma tarefa para o estado final *Archived*, ele remove os dados não mais necessários armazenados no armazenamento temporário, de modo a liberar espaço para novas tarefas serem processadas.

Falhas permanentes no arquivamento dos resultados das tarefas podem fazer com que o sistema pare de processar novas tarefas, caso o armazenamento temporário de todos os sites de processamento seja preenchido. O administrador do serviço deve ter cuidado para que tais falhas sejam devidamente reparadas. Assim, todas as tarefas criadas acabarão no estado final *Archived*. Os dados e metadados

associados a tarefas que foram arquivadas podem ser consumidos pelos usuários do serviço através do componente GUI.

O paralelismo de dados é conseguido simplesmente criando várias instâncias do componente *Worker*, cada uma executando em uma máquina virtual (VM) separada que é criada sob demanda. Essencialmente, o *Scheduler* interage com o serviço da nuvem para criar uma nova VM para cada nova tarefa que chegue ao estado *Ready*. Uma VM recém-criada inicia uma cópia do componente *Worker* no momento da inicialização e é instruída pelo *Scheduler* para processar a tarefa apropriada. A VM que executa um *Worker* que concluiu a execução de uma tarefa pode ser lançada pelo *Scheduler*, se nenhuma tarefa precisa ser executada ou pode ser reutilizada para executar outras tarefas.

4.2.2. Avaliação do sistema SAPS

O processamento das 670 imagens da órbita/ponto 215/065 dos satélites da família Landsat, entre os anos de 1985 e 2015, ocorreu utilizando uma estrutura de 10 *Workers*, configurados com 8 CPUs, 28Gb de memória principal, 140 Gb de armazenamento.

Para avaliar a eficiência da paralelização, utilizou-se uma execução do SEBAL em um *desktop* com CPU (intel i7 7700 8 cores), 32 Gb de memória principal e dois discos rígidos (120GB SSD e 500GB HDD). Nas duas implementações (SAPS e *desktop*) os programas computacionais precisavam executar todo o fluxo de tarefas para 10 imagens do satélite Landsat 5, partindo do *download* de dados orbitais e climáticos até a geração de nove arquivos de saída de dados do processamento SEBAL. Entre todos os produtos gerados nas diferentes etapas de cálculo do algoritmo SEBAL, foram selecionados como saída de dados três índices de vegetação, albedo e temperatura de superfície, saldo de radiação, fluxo de calor no solo, fração evapotranspirativa e evapotranspiração.

4.2.3. Demonstração dos dados gerados pelo sistema SAPS

Neste capítulo são apresentadas as taxas evapotranspirativas para 10 tipos de cobertura do solo na região semiárida brasileira para o período entre os anos de 1985 e 2015. A metodologia apresentada em Chaves et al. (2008) para classificação da cobertura do solo na região do bioma Caatinga foi utilizada para identificar as classes

de cobertura do solo descritas na Tabela 10. As visitas de campo para coleta de informações para as classificações aconteceram em 29 e 30 de setembro de 2016. Foi considerado um valor mínimo de área de 300 m x 300 m para classificar cada tipo do solo. As coordenadas geográficas foram utilizadas para extração das informações nas 670 imagens processadas, cada extração refere-se a uma área de 120 metros de buffer e as composições temporais mensais foram produzidas para facilitar a apresentação dos dados.

Tabela 10 - Classes de cobertura do solo e sua localização geográfica

Tipos de cobertura do solo	Longitude	Latitude
1- Corpo d'água	-36.9023	-7.67310
2- Solo exposto	-37.0286	-7.80495
3- Subarbustiva muito rala	-36.9492	-7.73516
4- Subarbustiva arbustiva rala	-37.1356	-7.58643
5- Arbustiva subarbórea rala	-36.9885	-7.67242
6- Arbustiva subarbórea aberta	-36.9384	-7.66839
7- Subarbórea arbórea aberta	-36.9475	-7.67858
8- Arbórea subarbórea aberta	-36.9550	-7.74929
9- Arbórea subarbórea densa	-37.1346	-7.58979
10-Arbórea subarbórea muito densa	-36.8807	-7.67848

4.3. Resultados

O sistema SAPS permitiu uma rápida execução das 670 imagens Landsat avaliadas neste estudo. Os testes realizados com 10 *Workers* revelaram que o sistema tem capacidade média para processar 3,76 tarefas por hora. Para efeitos de comparação, a execução no *desktop* tem capacidade de gerar entre 0,61 e 0,71 tarefas por hora. Assim, a aceleração alcançada no cenário avaliado variou de 5,3 a 6,2. No entanto, notou-se que a infraestrutura de nuvem usada no experimento era bem pequena, considerando as instalações típicas da nuvem. O tempo médio de processamento por cena para o serviço foi de aproximadamente 2 horas, o que levaria a uma taxa de transferência média ideal de aproximadamente 5 tarefas/h, para uma nuvem com capacidade de 10 VMs. A redução de aproximadamente 25% na taxa média de execução das tarefas, em comparação a taxa ideal, está relacionada a toda a automação da execução do fluxo de trabalho, bem como às particularidades do desenho do experimento. A pequena escala do experimento induz uma considerável

sobrecarga para o sistema paralelo, que é normalmente menos significativo em um sistema de produção sujeito a uma carga sustentada.

Quando se analisa em unidade de máquina (VM e Desktop), percebe-se que a execução em desktop foi mais eficiente, com uma diferença de cerca de 1 hora para executar todo fluxo de trabalho de uma imagem Landsat 5. Entretanto, deve-se levar em consideração as facilidades que o SAPS oferece. As tarefas executadas no *desktop* necessitam que um usuário inicie o download de dados e monitore o desenvolvimento da atividade. No SAPS todo gerenciamento e inicialização de novas tarefas é realizado pelo sistema computacional o que permite a execução mais eficiente e ainda garante o gerenciamento dos processos com o registro da proveniência dos dados gerados.

Os dez tipos de cobertura do solo selecionados para apresentar as séries históricas de evapotranspiração são utilizados neste estudo apenas em caráter demonstrativo (Figura 9). As classes de cobertura do solo investigadas revelam apenas a situação observada em campo para um período próximo ao que foi realizada a visita de campo. Então, é possível que ao longo do período que corresponde à série temporal os locais examinados tenham passado por outros tipos de cobertura do solo.

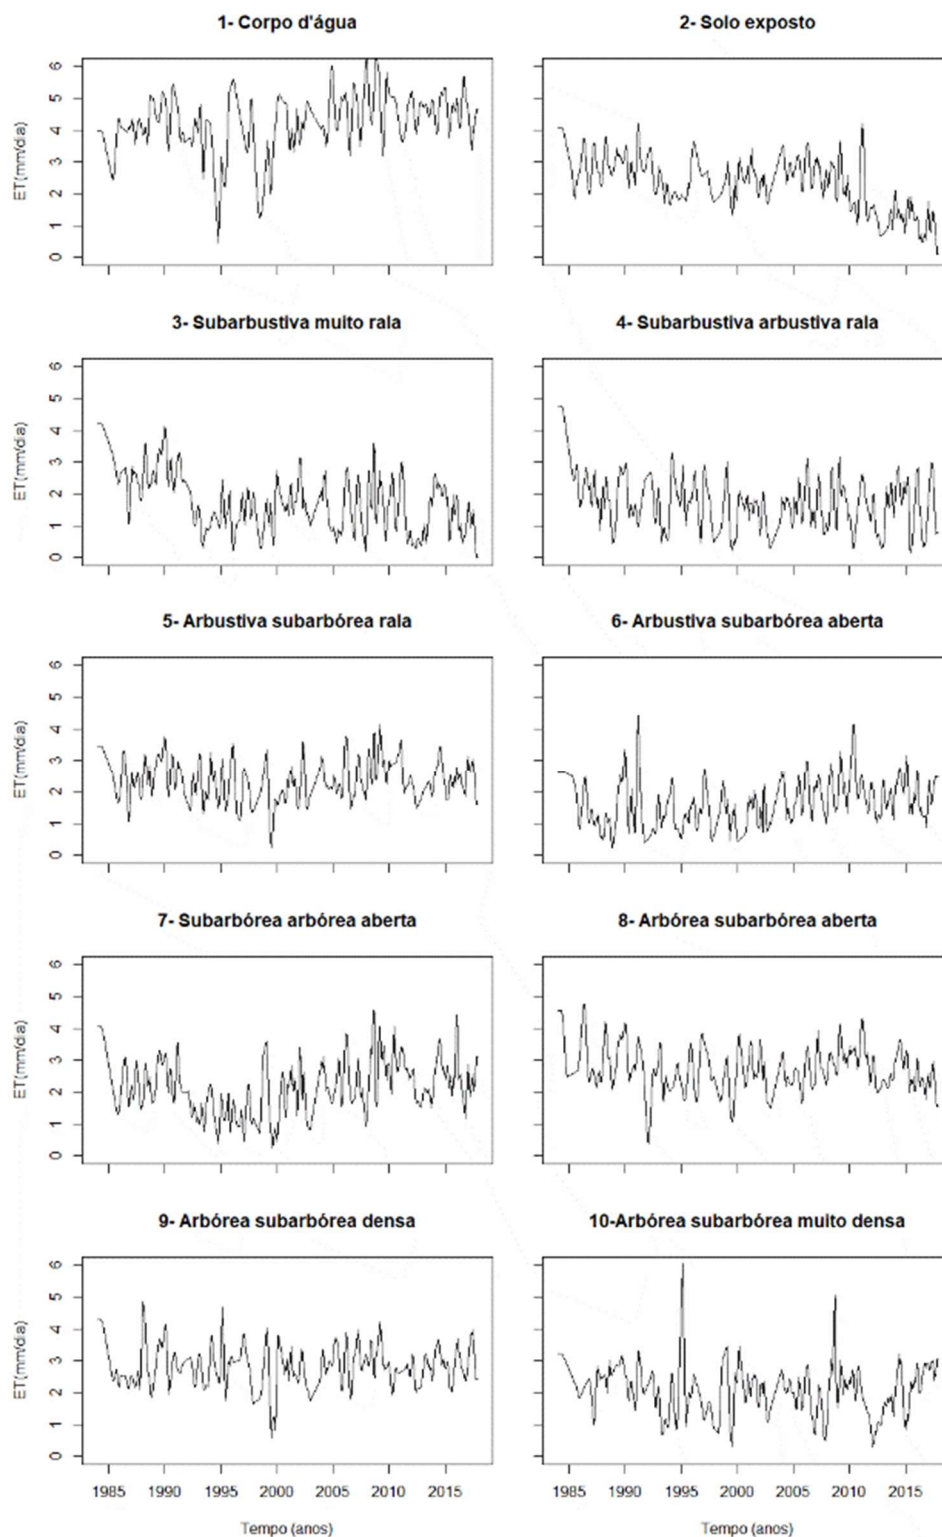
Na Figura 9 é possível observar a evapotranspiração nos locais classificados conforme a Tabela 10. No entanto, a apresentação da série de evapotranspiração para um período superior a 30 anos tem a intenção de demonstrar o potencial da ferramenta para geração de novos conjuntos de dados que possam ser utilizadas no monitoramento ambiental.

4.4. Discussão

O Google Earth Engine (GEE) (Google Earth Engine Team, 2015) tem liderado aplicações usando dados de sensoriamento remoto para estudos ambientais. No GEE é possível acessar diversos sensores orbitais, incluindo imagens Landsat. Essa plataforma também fornece recursos de computação para o processamento desses dados. Os usuários podem escrever seus próprios programas usando o API fornecida pela plataforma, e executar esses programas em paralelo na *cloud* do Google. Um consórcio formado pela Universidade da Nebraska, Lincoln, *Desert Research Institute*

e *University of Idaho* implementou uma versão do METRIC que opera no GEE (ALLEN et al., 2015).

Figura 9 - Taxas evapotranspirativas para dez classes de cobertura dos solos na região do bioma Caatinga



Embora a abordagem do GEE simplifique o processamento do fluxo de trabalho, uma vez que não há necessidade de *download* dos dados de entrada, e também mitigue as limitações computacionais dos usuários, não favorece uma partilha de programas mais coordenada e os resultados gerados por diferentes usuários. Isso deve ser feito de forma *ad hoc* pelos próprios usuários. Além disso, não há suporte para o gerenciamento das informações de metadados associadas, sendo difícil rastrear a proveniência. Implementações existentes do algoritmo não podem ser facilmente reutilizadas na plataforma, uma vez que os programas precisam ser codificados usando a API do GEE. Mais importante ainda, os usuários estão sujeitos às condições do serviço impostas pelo Google, que nem sempre pode atender às suas expectativas. Por exemplo, os termos do serviço gratuito fornecido incluem cláusulas como "O Google pode rescindir este Contrato por sua conveniência em qualquer momento sem responsabilidade para com o Cliente" (<https://earthengine.google.com/terms/>, acessado em agosto de 2017).

Em contraste, o serviço que se propõe neste Capítulo segue uma abordagem inovadora baseada na cooperação de instâncias autônomas de serviços de escala local/regional. Cada uma dessas instâncias fornece serviços a uma comunidade de usuários que normalmente pertencem a um grupo único ou pequeno de instituições parceiras e com interesse focado em áreas geográficas particulares, por exemplo, a região semiárida brasileira, a região mediterrânea, etc.

O serviço é altamente configurável, permitindo a execução simultânea de diferentes versões personalizadas dos algoritmos utilizados para estimar a evapotranspiração, que simplesmente precisam se adequar a um contrato comum de dados de saída e formato de metadados. Além disso, usando recursos de computação compartilhados entre seus usuários locais, não só aumenta a capacidade computacional disponível para esses usuários, mas também aumenta a eficiência com que esses recursos são usados. Isso, juntamente com o foco em áreas de escala regional, torna viável processar séries longas de imagens de satélite em uma resolução espacial mais alta, dentro de uma escala de tempo razoável.

4.5. Conclusões

A utilização do sistema SAPS permitiu um processo mais rápido e confiável de construção das séries temporais de produtos gerados pelo algoritmo SEBAL, no caso

presente, 670 imagens foram geradas. Ferramentas e algoritmos para processamento de grandes massas de dados de imagens de satélite através de computação em nuvem permitem expandir a capacidade de análise de dados de mudança de uso e cobertura do solo atualmente disponível às comunidades de recursos hídricos e meio ambiente.

CAPÍTULO V - USO DE SÉRIES HISTÓRICAS MENSAIS LANDSAT NA IDENTIFICAÇÃO DO PERÍODO DAS REMOÇÕES NA COBERTURA DO VEGETAL NO BIOMA CAATINGA

5.1. Introdução

Distinguir entre a remoção completa da vegetação por ação humana e os efeitos que a variabilidade da precipitação na vegetação é um dos principais desafios no estudo de florestas tropicais sazonais secas (Yang et al., 2016; Wessels et al., 2007). Nessas áreas, a produção vegetal está fortemente relacionada às médias anuais de precipitação (HEIN et al., 2011). Os impactos causados por ações humanas são muitas vezes mascarados pela variabilidade climática, especialmente após longos períodos de seca (WESSELS et al., 2007; ZHANG et al., 2014). Caatinga é um bioma que tem ambas as características, caracterizada por uma floresta seca heterogênea (RODAL et al., 2008) e semi-decídua (BRITO et al., 2012; ALBUQUERQUE et al., 2012). A Caatinga encontra-se numa região semiárida com alta variabilidade temporal e espacial da precipitação (SILVA, 2004) e a sua fenologia é impulsionada por padrões de precipitação a curto prazo (LIMA; RODAL, 2010). Além das características biofísicas, a LCC em Caatinga é fortemente influenciada pela maneira humana de usar (e viver) o solo (ANDRADE-SILVA et al., 2012; ARAÚJO et al., 2007, 2010; OLIVEIRA et al., 2013; SANTOS; TABARELLI, 2002).

Os dados das séries temporais de sensoriamento remoto são frequentemente usados para distinguir entre os efeitos da variabilidade climática e antropogênica nas LCC em regiões semiáridas (ANYAMBA et al., 2014; DEVRIES et al., 2015; EVANS; GEERKEN, 2004; HIGGINBOTTOM; SYMEONAKIS, 2014; IBRAHIM et al., 2015; LEROUX et al., 2017; VERBESSELT et al., 2016). Neste sentido, duas técnicas podem ser destacadas devido à sua eficácia quando aplicadas em áreas semiáridas: o método das rupturas na sazonalidade e tendência (*Breaks For Additive Season and Trend* - BFAST, DEVRIES et al., 2015; DUTRIEUX et al., 2015; VERBESSELT et al. 2012) e a análise da tendência residual (Residual Trend - RESTREND, EVANS; GEERKEN, 2004; LI et al., 2016; WESSELS et al., 2012).

O BFAST pode identificar o comportamento sazonal e os pontos de rupturas nas séries temporais, que são dois elementos essenciais para distinguir os efeitos da variabilidade climática e antrópicos na cobertura do solo em regiões semiáridas. No entanto, Dutrieux et al. (2015) obtiveram uma melhoria significativa na identificação

dos períodos de LCC (pontos de ruptura) através do BFAST quando utilizaram regressores externos, pois permitiu eliminar de forma mais eficiente os efeitos climáticos sazonais. De fato, os pontos de ruptura em uma série temporal podem ser resultado de efeitos climáticos no valor da variável em causa, como foi observado por JONG et al. (2012) no Índice de Vegetação de Diferença Normalizada (*Normalized Difference Vegetation Index* - NDVI). A técnica RESTREND utiliza regressão linear entre o NDVI e a precipitação para eliminar a influência do clima na cobertura do solo, utilizando o resíduo desta regressão para detectar mudanças. Apesar de ser um método bem conhecido com um fundo teórico sólido para a detecção de níveis realistas de degradação do solo induzida pelo homem, a técnica RESTREND requer procedimentos analíticos mais sensíveis capazes de lidar com a variabilidade e tendência interanuais de precipitação (WESSELS et al., 2012).

O método da segmentação da série temporal e da tendência residual (*Time Series Segmentation and Residual Trend* - TSS RESTREND, BURRELL et al., 2017) foi desenvolvido para superar as limitações identificadas nas técnicas BFAST e RESTREND, levando em conta os efeitos climáticos sazonais e a identificação e remoção de pontos de ruptura devido à variabilidade da chuva. TSS RESTREND usa o procedimento de identificação de pontos de ruptura do BFAST associado ao filtro de efeitos climáticos sazonais do RESTREND e acrescenta o teste CHOW (CHOW, 1960) para considerar apenas o ponto de ruptura mais significativo em cada pixel de uma série temporal. Ao incorporar mecanismos relevantes e reduzir as limitações identificadas nas duas metodologias mais importantes, o método TSS RESTREND apresenta um alto potencial de sucesso em uma análise da cobertura do solo em um ambiente semiárido. É uma abordagem recente e que ainda não foi validada para as diferentes regiões semiáridas. Burrell et al. (2017) descrevem uma aplicação do método TSS RESTREND para áreas com registros de incêndios na Austrália.

No entanto, há um ponto crítico na análise de LCC em uma região semiárida: distinguir entre a remoção completa da vegetação por ação humana e os efeitos que a variabilidade da precipitação na vegetação. Dependendo do conjunto de dados usado, este desafio pode ser maior. A maioria dos estudos que utilizam séries temporais superiores a 30 anos usa os índices de vegetação em baixa resolução espacial, entre 1 a 8 km (LEROUX et al., 2017). Este nível de observação não é, contudo, compatível com a escala de ação humana. Habitualmente, as alterações

provocadas pelo homem só são visíveis utilizando uma resolução espacial superior (LAMBIN et al., 2003; STROPPIANA et al., 2012).

Os conjuntos de dados Landsat são uma das fontes mais valiosas de observação do solo devido aos mais de 30 anos de dados em média resolução espacial que cobrem uma faixa espectral vantajosa (infravermelho visível, próximo, médio e térmico). A qualidade das imagens Landsat foi melhorada nos últimos anos (WULDER et al., 2016), permitindo que os usuários tenham acesso aos dados de reflectância de superfície (JU; MASEK, 2016). Os dados Landsat também podem fornecer índices de vegetação e outras variáveis que usam diferentes faixas do espectro eletromagnético, como o albedo de superfície (0.3 μm – 3 μm). O albedo de superfície (*Surface Albedo* - SA) pode ser um indicador mais preciso de LCC induzida pela ação humana em comparação com a abordagem tradicional dos índices de vegetação. Este indicador (SA) é sensível às variações fenológicas sazonais (WANG et al., 2017) e a mudanças nas propriedades do solo provavelmente causadas por práticas de manejo humano (CAI et al., 2016, SHUAI et al., 2011, WANG et al., 2016). Apesar da capacidade reconhecida da SA para mostrar LCC (GOVAERTS; LATTANZIO, 2007), não é comum usar séries temporais do SA para distinguir entre os efeitos da variabilidade climática e as mudanças antrópicas na cobertura terrestre na floresta seca sazonal.

Nossa hipótese neste capítulo é que um índice baseado no SA poderia ser um melhor indicador para LCC no bioma Caatinga que os índices de vegetação (NDVI e EVI), que tradicionalmente são usados para detectar mudanças na cobertura do solo. Neste estudo, utilizou-se a técnica TSS RESTREND para uma série temporal Landsat de 31 anos e os resultados foram comparados com observação de campo em uma área experimental no bioma Caatinga.

O objetivo deste capítulo é determinar a(s) melhor(es) variável(eis) para representar remoção completa da cobertura vegetal do Bioma Caatinga. Acredita-se que este estudo poderá suportar melhores procedimentos de monitoramento e decisões de gestão do solo nesse ambiente, que está sofrendo uma intensa degradação.

Os assuntos abordados neste capítulo são frutos de um trabalho de cooperação internacional realizado no período de sanduíche do autor da tese. Uma versão deste capítulo foi submetida à edição especial *Time Series Analysis with High Spatial*

Resolution Imagery do periódico *Remote Sensing Environment*² e já teve o abstract aprovado; a versão completa encontra-se em processo de análise.

5.2. Área de estudo

A maior parte das florestas tropicais sazonais secas ocorre em manchas isoladas e a única grande área contígua é o bioma da Caatinga (LINARES-PALOMINO et al., 2011). As Unidades de Conservação (UCs) são a principal designação de uso do solo para conservação ambiental no Brasil (PACHECO et al., 2018). Para estimar a extensão do território do bioma Caatinga coberto por Unidades de Conservação, utilizou-se o Cadastro Nacional de Unidades de Conservação (CNUC) que mostra um inventário completo de todos os biomas brasileiros. De acordo com o CNUC (2017) para a Caatinga, apenas 7,7% (64,031 km²) de toda a área (827,934 km²) são classificados como UCs (1,3% de áreas de proteção restrita mais 6,4% de áreas de uso sustentável).

A Caatinga é conhecida como o bioma brasileiro mais negligenciado em diversos aspectos, devido a centenas de anos de uso inadequado e insustentável de solos e recursos naturais (CASTELLETTI et al., 2004; MORO et al., 2016). Ao longo das últimas décadas, as áreas de vegetação nativa foram gradualmente substituídas por culturas agrícolas, gado ou foram atingidas por áreas urbanas (OLIVEIRA et al., 2012; FIASCHI; PIANNI, 2009; SIVAKUMAR, 2007; CASTELLETTI et al., 2004; LEAL et al. 2005, QUEIROZ, 2006; PEREIRA et al., 2013; LE POLAIN DE WAROUX; LAMBIN, 2012; APGAUA et al., 2013).

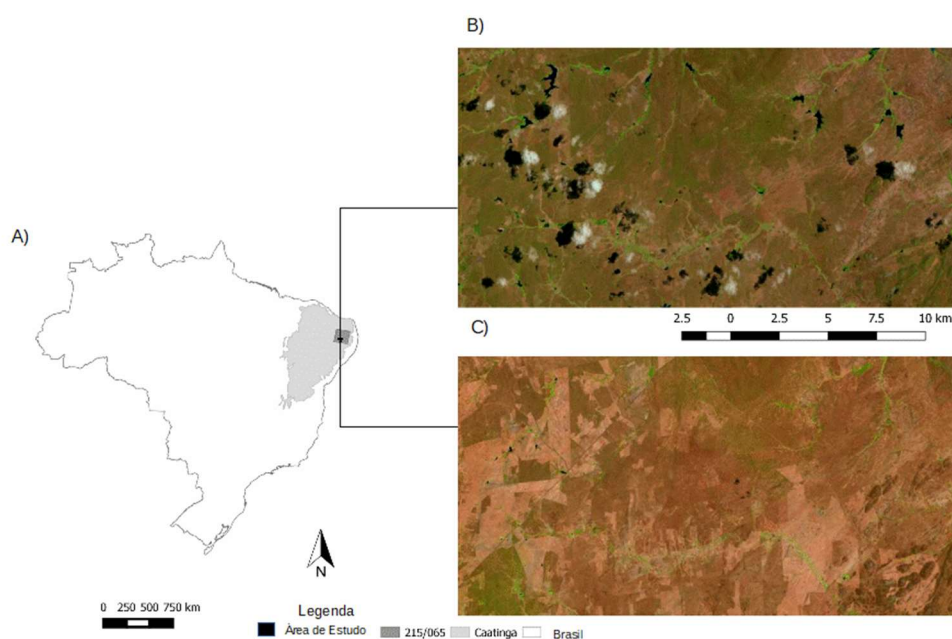
A Figura 10A mostra a localização geográfica da área de estudo. A área está localizada dentro da cena Landsat 215/065 (órbita/ponto), entre os limites de quatro municípios (Monteiro, Prata, Sumé e Camalaú) do estado da Paraíba. A pecuária é uma das principais atividades econômicas nesta região. A Figura 10B mostra duas imagens Landsat obtidas no período inicial e final deste estudo, sendo possível perceber algumas das alterações ocorridas ao longo do tempo.

A precipitação média anual é de 538 mm e a temperatura média anual é de 23°C (<https://pt.climate-data.org>). A Figura 11 mostra o Standardised Precipitation-

² Cunha, J.; Rufino, I.; Erasmi, S.; Galvão, C.; Nóbrega, R.; Valente, F. Surface albedo as a proxy of land-cover change in seasonal dry forests: Evidences from the Brazilian Caatinga biome. *Remote Sensing of Environment* (em revisão).

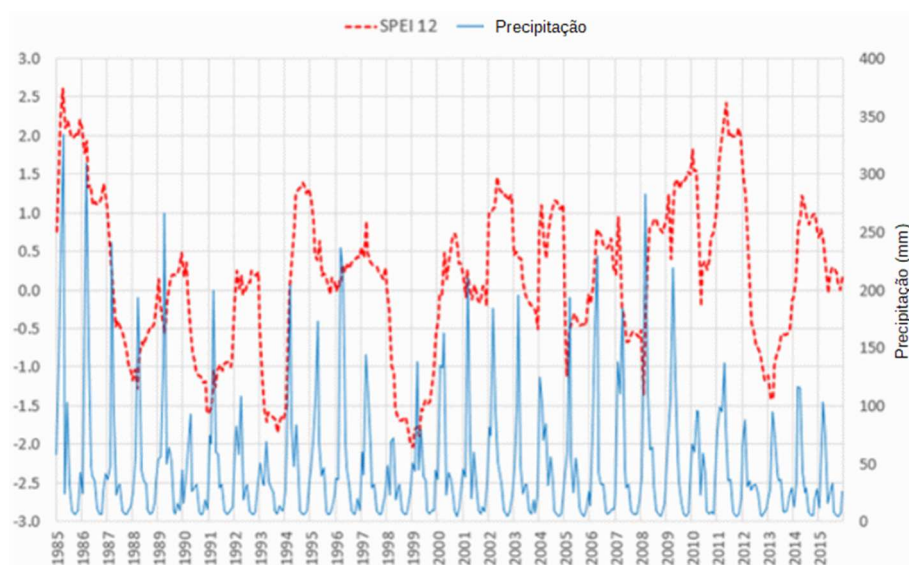
Evapotranspiration Index (SPEI) de 12 meses e a precipitação para o período e a área estudados. Conforme observado, a região apresenta alternância entre períodos secos e úmidos de diferentes intensidades. Os dados de SPEI e precipitação estão disponíveis por Beguería et al. (2017) e CHIRPS (FUNK et al., 2015), respectivamente.

Figura 10 - Localização do bioma Caatinga, cena Landsat utilizada e área de estudo (Xmin: -37.07; Xmax: -36,84; Ymin: -7,86; Ymax: -7,74) em (A), Imagem de 07/10/1984 representando a situação inicial estudada (B) e Imagem de 27/09/2015 representando



Fonte: Cunha et al (2018B)

Figura 11 - SPEI e a precipitação para as coordenadas geográficas x:-36,75, y:-7,75



Fonte: Cunha et al (2018B)

5.3. Material e Métodos

5.3.1. Dados

i) Landsat *Surface Reflectance*

A família de satélites Landsat tem adquirido imagens espaciais da superfície terrestre há mais de 40 anos. Esta coleção é a mais longa e contínua com dados orbitais em média resolução temporal disponível gratuitamente. Os dados de refletância da superfície (SR) do Landsat são gerados por dois algoritmos diferentes dependendo do sensor de medição: os dados Landsat 5 TM e 7 ETM *surface reflectance*, são obtidos usando o software LEDAPS (Masek et al., 2012; USGS, 2017b), enquanto os dados Landsat 8 OLI *surface reflectance*, são processados usando o algoritmo LaSRC (USGS, 2016).

Para garantir a qualidade dos dados SR utilizados, a banda pixel_qa dos arquivos associados Landsat Surface Reflectance Quality Assessment foi analisada. Apenas pixels classificados como "claros" (valores 66 e 130 em arquivos Landsat 5 e 7, respectivamente ou 322 e 386 em Landsat 8), foram considerados de boa qualidade e foram utilizados nas análises desenvolvidas neste trabalho.

ii) RapidEye

As imagens RapidEye cobrem um período recente, a partir de 2009. Os conjuntos de dados RapidEye são entregues em quadrículas de 25 × 25 km² na resolução espacial de 5 metros e 5 faixas espectrais. Estes conjuntos de dados foram fornecidos pelo Ministério do Meio Ambiente (MMA) que disponibilizam essas informações no período de 2012 a 2015. Neste trabalho, utilizou-se as quadrículas 2435424 e 2435524 para cobrir toda a área de estudo.

iii) Precipitação

Os dados de precipitação utilizados neste trabalho foram apresentados no Capítulo III. Conforme especificado, CHIRPS é um produto de precipitação quase global, de resolução espacial (0,05 °, aproximadamente 5 km de grade) desenvolvido para monitorar as mudanças ambientais da Terra. Neste trabalho, utilizou-se os dados agregados mensais de outubro de 1983 a dezembro de 2015.

5.3.2. Índices espectrais

A identificação da LCC foi realizada usando o Índice de Vegetação de Diferença Normalizada (NDVI) (TUCKER, 1979), o Índice de Vegetação Melhorado (EVI) (HUETE et al., 2002, 1997) e o Índice de Albedo de Superfície (*Surface Albedo Index* - SAI), este último, um novo índice baseado no albedo de superfície (SA) (SHUAI et al., 2014; WANG et al., 2016). Para cada imagem Landsat, foram calculados NDVI, EVI e SA utilizando as Equações 16, 17 e 1 (Capítulo II).

$$NDVI = \frac{\rho_{NIR} - \rho_{red}}{\rho_{NIR} + \rho_{red}} \quad (16)$$

$$EVI = 2.5 \times \frac{\rho_{NIR} - \rho_{red}}{\rho_{NIR} + 6 \times \rho_{red} - 7.5 \times \rho_{blue} + 1} \quad (17)$$

onde ρ representa a refletância de superfície para as bandas indicadas (ver Tabela 1).

O novo índice SAI foi calculado a partir da Equação 18. Este índice, normalizado pelo valor de máximo albedo de superfície da série temporal analisada ($\max(SA)$), apresenta um comportamento e uma gama de valores idêntica aos outros índices de vegetação utilizados.

$$SAI = 1 - SA/\max(SA) \quad (18)$$

Para a análise que envolve um único momento de observação, a presença de nuvens e sombra de nuvens em muitos pixels pode tornar impossível a visualização, parcial ou totalmente, da área de estudo. Para superar esse problema, Holben (1986) apresentou uma técnica para a composição temporal da informação proveniente de sensores orbitais. Este método geralmente é chamado de composição de máximo valor (*Maximum-Value Composite* - MVC), pois a imagem composta sazonal é criada usando o máximo valor da variável para cada pixel, em cada período (Flood, 2013). Embora esta técnica tenha sido inicialmente usada apenas para NDVI com imagens do sensor AVHRR, ela foi aplicada com sucesso em outros sensores orbitais e índices (por exemplo, HUETE et al., 2002). Flood (2013) mostrou que o medoide (um análogo multidimensional da mediana) é uma medida melhor para produzir composições temporais representativas. Com base nesses resultados, reduziram-se as séries temporais de NDVI, EVI e SAI para composições mensais, calculando a mediana de

cada variável em cada pixel. Os valores indisponíveis (*Not Available* - NA) nas séries temporais mensais de alguns pixels foram preenchidos por interpolação linear.

Para reduzir o ruído causado pela contaminação da nuvem e pela variabilidade atmosférica, o filtro Savitzky-Golay também foi usado para suavizar as séries temporais associadas a cada pixel (CHEN et al., 2004; SAVITZKY; GOLAY, 1964). Um filtro linear com uma janela de suavização de meia largura de cinco meses foi aplicado a cada uma das séries temporais dos três índices (NDVI, EVI e SAI) em todos os pixels da área de estudo.

5.3.3. TSS RESTREND

O método de Time Series Segmentation and Residual Trend method (TSS-RESTREND), proposto por Burrell et al. (2017), combina a técnica de Residual Trend (RESTREND) (Evans e Geerken, 2004) e as Breaks For Additive Seasonal and Trend (BFAST) (Verbesselt et al., 2012, 2010), permitindo uma melhor e mais precisa detecção de mudanças nos ecossistemas. A análise de tendência é uma técnica comumente aplicada em diferentes áreas científicas para estudar a variação média de algumas variáveis ao longo do tempo ou espaço (por exemplo, Alley, 1988; Lindquist, 2004). No entanto, antes da sua aplicação, é frequentemente necessário remover a influência de uma variável exógena, seja por métodos paramétricos (por exemplo, regressão) ou não paramétricos (por exemplo, LOWESS), para reduzir a variabilidade da variável estudada (Helsel e Hirsch, 2002; Schertz et al., 1991). Em sensoriamento remoto, um procedimento similar foi aplicado para a análise da cobertura do solo. O método RESTREND analisa as tendências temporais em Resíduos da Relação de Precipitação-Vegetação (Vegetation Precipitation Relationship-VPR) de uma regressão linear do NDVI sobre a precipitação acumulada ao longo de um período de tempo (Evans e Geerken, 2004). Em Burrell et al. (2017), a VPR é obtida para dois conjuntos de informações, série temporais completa NDVI (Complete Time Series-CTS) e NDVI máximo anual. Em ambos os casos, a regressão linear é realizada a partir da melhor precipitação Acumulada (Optimal Precipitation Accumulated-OPA), e é calculada com base em um pixel por um algoritmo, combinando diferentes períodos de acumulação e defasagens. O par que leva aos coeficientes de correlação mais altos entre o OPA e $NDVI_{CTS}$ e o $NDVI_{máximo\ anual}$ é usado para estabelecer o VPR ótimo.

O método TSS RESTREND usa VPR anual para excluir pixels que não atendem aos critérios estabelecidos para usar o método RESTREND (Li et al., 2016; Wessels et al., 2012) e aplica o BFAST ao VPR_{CTS} residual para os pixels restantes. A aplicação do método BFAST (Verbesselt et al., 2010) retorna uma lista de possíveis pontos de ruptura que serão analisados mais tarde na etapa do teste de Chow (Chow, 1960) para determinar se existe um ponto de interrupção significativo. Ao identificar um ponto de interrupção significativo pelo teste de Chow, o método TSS RESTREND calcula o período (ano) de cada alteração identificada. Para mais detalhes sobre o método TSS-RESTREND, veja Burrell et al. (2017).

No presente estudo, o método TSS-RESTREND foi aplicado usando o pacote TSS.RESTREND para o software R. Alguns ajustes foram necessários para processar arquivos raster e executar o programa automaticamente. Embora este método seja usualmente aplicado a dados de NDVI (Li et al., 2016), no presente trabalho também foram aplicadas às outras duas variáveis espectrais em estudo, EVI e ISA, através das séries temporais de composição mensal (372 meses). O OAP foi calculado usando os dados de precipitação CHIRPS, para períodos de acumulação de 1-12 meses e tempos de atraso de 0-3 meses, resultando num aumento de 15 meses no início da série de precipitação.

É habitual limitar/excluir no processo de análise de alterações de cobertura do solo pixels que não tenham certas características. Por exemplo, em Dutrieux et al. (2015) foi utilizada uma máscara floresta/não-floresta como forma de excluir pixels não florestados do processo. Na proposta do método TSS RESTREND (BURRELL et al., 2017), as áreas agrícolas foram removidas do processo de análise. Estas práticas são justificadas quer pelos objetivos específicos dos estudos ou porque as técnicas utilizadas não são adequadas a esse tipo de cobertura do solo. Na área de estudo deste trabalho, a principal atividade econômica é a pecuária e a pouca agricultura de subsistência existente se baseia no aproveitamento das chuvas. Como não foi verificada a presença de atividades agrícolas irrigadas, optou-se por processar todos os pixels presentes na área de estudo.

5.3.4. Procedimentos usados para avaliação do desempenho das variáveis espectrais utilizadas

A aplicação do método TSS RESTREND para cada um dos 400 mil pixels contidos na área de estudo retorna um conjunto de informações sobre o comportamento das séries temporais para cada índice estudado. Entre todas as informações disponíveis através da aplicação do método TSS RESTREND, escolheu-se o tempo/período da mudança para avaliar o desempenho dos índices no monitoramento da remoção completa da vegetação. Uma validação espaço-temporal é essencial para avaliar o desempenho de qualquer nova metodologia. Neste estudo, construiu-se um conjunto de dados de validação, realizando uma interpretação visual de um conjunto de imagens do Google Earth (<http://earth.google.com/>) combinado com a análise de uma imagem RapidEye para detectar a alteração dos pixels associados.

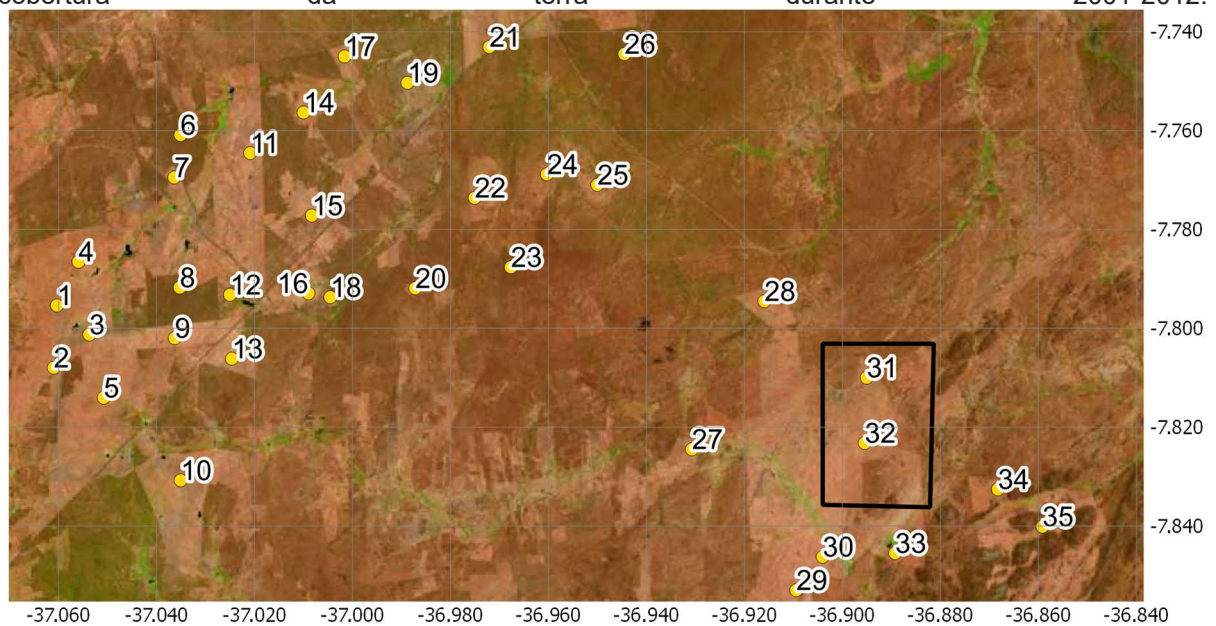
Uma análise visual detalhada da imagem RapidEye para um período mais recente (2015) da área estudada permitiu a identificação de várias áreas onde a cobertura do solo original mudou pela remoção completa da vegetação para solo exposto. As imagens do Google Earth foram examinadas para determinar o ano exato da mudança (vegetada para solo exposto). Além disso, áreas que não tiveram impacto humano e mantiveram sua cobertura vegetal original também foram escolhidas. Observações de campo (outubro de 2017) também foram feitas para confirmar o estado de vegetado/alterado para solo exposto de todos esses lugares.

As observações sobre o período de remoção da cobertura vegetal foram feitas para avaliar os índices utilizados (SAI, EVI e NDVI) para duas situações: 1- 35 áreas-alvo (Figura 12), 31 com substituição da vegetação para solo exposto no período de 1985 -2015 e 4 com vegetação preservada; e 2 - uma região para mostrar em detalhes o processo de substituição da cobertura vegetal por solo exposto.


O desempenho do método TSS-RESTREND aplicado às séries temporais dos três índices utilizados (NDVI, EVI e SAI) foi avaliado nos níveis temporal e espacial. Para cada uma das 35 áreas-alvo selecionadas, um pixel central foi escolhido e o valor médio de cada índice foi calculado em um buffer de 120 m em torno desse pixel, para cada imagem e mês/ano. O ano observado de mudança foi comparado com a saída do método e os resultados foram classificados em três classes: "Detecção correta" quando a diferença absoluta entre o ano da LCC modelada e o verdadeiro ano da LCC

for menor que dois anos; ou "Detecção errada" quando a diferença for superior a dois anos; ou "Não detectado" quando o método TSS-RESTREND não detectou nenhuma mudança de tendência significativa na série temporal do índice utilizado, mas um processo de degradação do solo realmente ocorreu. Para as quatro áreas-alvo preservadas, o resultado foi atribuído "Detecção correta" se nenhum ponto de interrupção significativo foi detectado pelo método e "Detecção errada" caso contrário.

Figura 12 - Localização do conjunto de dados de validação na área de estudo: os números marcam as 35 áreas alvo e o polígono da região que experimentou um processo sequencial de mudança da cobertura da terra durante 2001-2012.



Legend



Fonte: Cunha et al (2018B)

A análise espacial dos resultados foi feita por comparação visual entre a série temporal de imagens do Google Earth da área de estudo e os mapas com o ano de detecção da LCC pelo método TSS-RESTREND aplicado aos diferentes índices espectrais utilizados nesta pesquisa. Uma pequena região foi também selecionada para ilustrar de forma detalhada o processo de fragmentação da retirada da cobertura do vegetal. Essas áreas foram delimitadas por polígonos que reúnem alterações de um mesmo período. Para facilitar uma análise visual das alterações, os polígonos foram sobrepostos aos *rasters* dos períodos alterados (*output* TSS RESTREND) e imagens do visível. Além disso, algumas informações estatísticas foram calculadas

para os pixels que estavam sobrepostos especialmente aos polígonos identificados, permitindo uma comparação com o efetivo período de remoção da cobertura vegetal. Uma análise de variabilidade relativa também foi realizada para cada índice, usando-se a mediana dos pixels presentes em cada polígono para construção da série temporal e posterior cálculo do coeficiente de variação entre as séries temporais que representam cada uma das porções alteradas.

5.4. Resultados

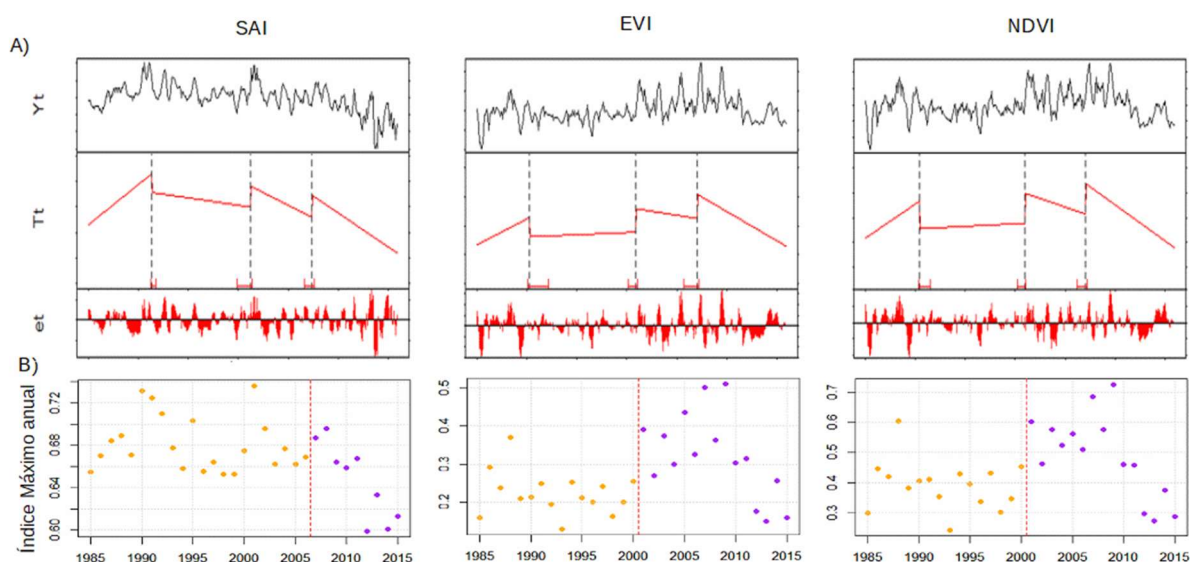
Para o período entre janeiro de 1985 e dezembro de 2015, foram identificadas 670 imagens capturadas pelos sensores a bordo dos satélites Landsat, 390 pelo sensor TM, 233 por ETM + e 47 pela OLI. Cada imagem capturada por esses sensores e disponibilizada pela USGS através do produto Landsat SR contém 17 arquivos com informações sobre as diferentes faixas espectrais dos sensores, qualidade de dados e metadados, resultando em 11.390 arquivos usados neste estudo. A série temporal de precipitação teve um aumento de 15 meses no início do período de estudo, resultando em uma análise de 387 arquivos. O período adicional no início da série é um requisito do método TSS RESTREND para o cálculo da precipitação acumulada ideal.

Como exemplo da aplicação do método TSS RESTREND, apresenta-se o resultado obtido para um pixel da área de estudo (Figura 13). A análise da série VPR-residual (Figura 13A) mostrou que tipicamente NDVI e EVI têm um comportamento muito semelhante, enquanto que o índice SAI mostra um comportamento diferente. Todos os índices mostram quatro pontos de ruptura com os mesmos períodos de ocorrência. As diferenças ocorrem na seleção do ponto de ruptura mais significativo (teste Chow) que indicou o mesmo ano para EVI e NDVI e um ano diferente para o SAI.

Google Earth, imagens de RapidEye e observações *in situ* (a partir de outubro de 2017) foram usadas para observar as condições de preservação/degradação (LCC) ao longo do tempo nas 35 áreas-alvo; esta informação é indicada na Figura 14A como "Observação". Além disso, o período de ocorrência da LCC obtido através do método TSS RESTREND para cada um dos índices usados (SAI, EVI e NDVI) é também apresentado nesta Figura. Quatro áreas foram consideradas como "Inalterada" (6, 8, 23 e 26) pois não foi observado *in situ* LCC nessas áreas-alvo. Ao

resultado do método TSS RESTREND foi atribuída a classificação "Inalterada" quando este procedimento não identifica pontos de ruptura significativos para o período de estudo. Ao usar SAI, as áreas 6, 8 e 23 tiveram como resultado "Inalterada", pelo que essas áreas foram classificadas como "detecção correta" (Fig. 14B). O NDVI alcançou desempenho semelhante ao SAI, identificando as áreas 6, 23 e 26 como "Inalterada". O pior desempenho foi observado para o EVI, só registrando corretamente as áreas 23 e 26 como "Inalterada".


Figura 12 - Resposta do TSS-RESTREND para o pixel nas coordenadas geográficas -36.85912, -7.84013. A) identificação do ponto de ruptura do BFAST; Y_t é índice VPR-residual, T_t é o componente de tendência e e_t é o BFAST residual; e B) Índice máximo anual vs. tempo



Relativamente às 31 áreas-alvo em que foi observada LCC, vinte e cinco (81%) foram consideradas "detecções corretas" quando utilizado o índice SAI, enquanto os índices EVI e NDVI tiveram somente sete (19%) e oito (26%) "detecções corretas", respectivamente (Figura 14B). A classificação "não detectada" foi observada dezoito vezes (58%) para EVI e dez vezes (32%) para NDVI. Quando se utilizou o NDVI e EVI, não foi possível observar um padrão temporal para o baixo desempenho nas estimativas do período de LCC pelo método TSS RESTREND. Quando analisa-se a "detecção errada" para todas as 35 áreas alvos, o índice SAI indica que quatro áreas (11%) foram mal classificadas (Fig. 14B). O padrão temporal para áreas alvo que apresentaram baixo desempenho para o SAI é bem definido, duas áreas foram classificadas como "não detectadas" pelo SAI, registrando sua mudança nos primeiros cinco anos da série (até 1990) e nos últimos cinco anos da série (após 2010). Para

detecção errada, uma área (12) apresentou alteração nos primeiros cinco anos da série e outras duas áreas (22 e 28) no final da série temporal estudada. Já para índices EVI e NDVI, houve nove (26%) e quatorze (40%) áreas alvo com detecções erradas, respectivamente, para todas as áreas-alvo estudadas.

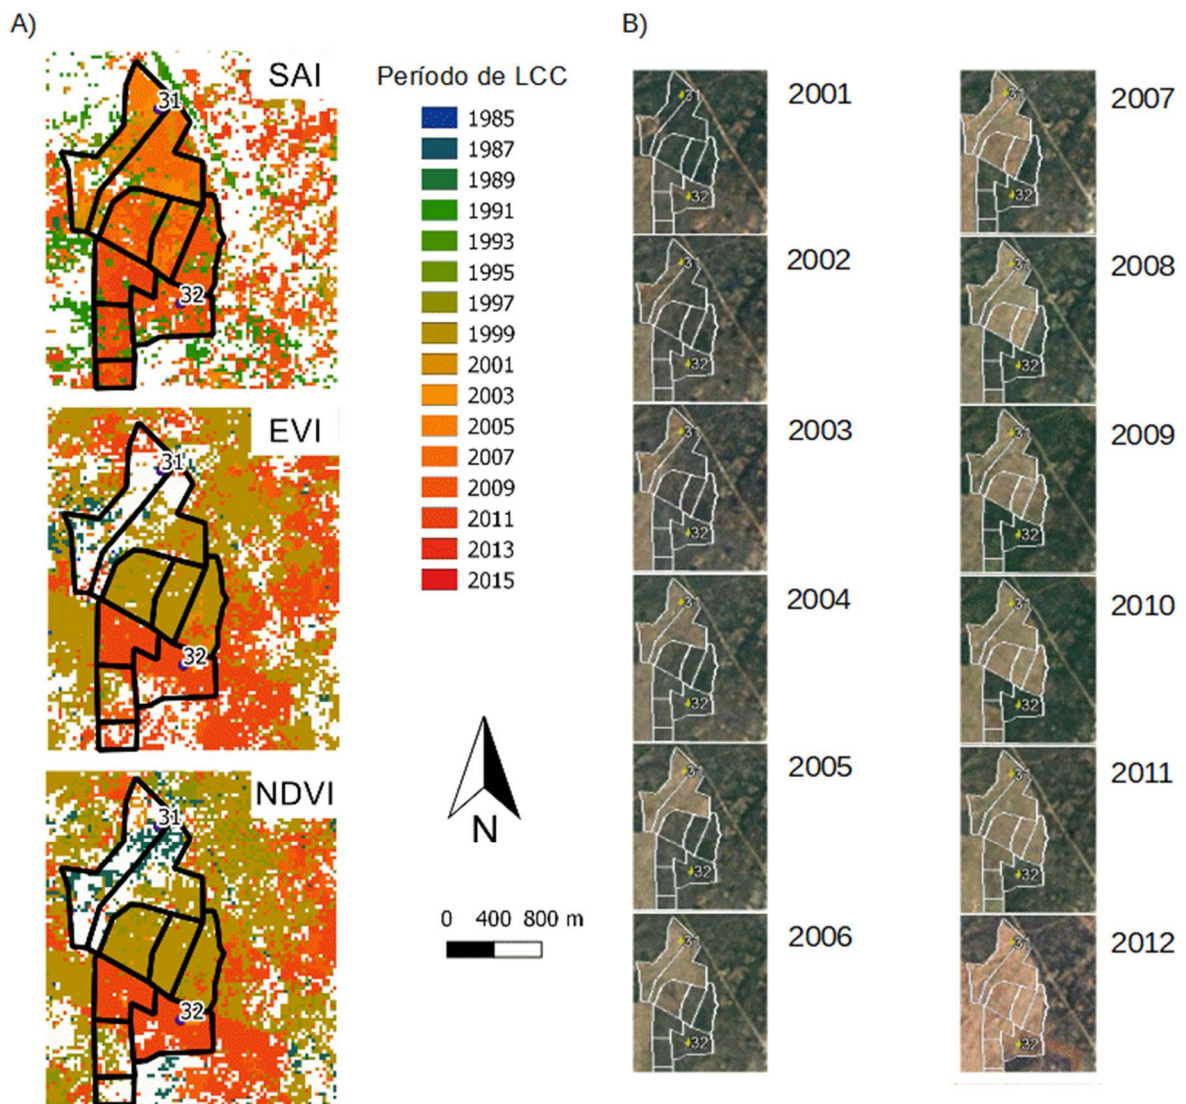
Figura 13 - Período observado e modelado, SAI, EVI e NDVI para áreas-alvo: A) Descrição e B) Classificação



Para avaliar mais em pormenor o desempenho dos três índices, analisou-se uma região (Figura 15) que incluiu duas áreas-alvo que apresentaram desempenhos distintos: detecção correta apenas para o índice SAI (área-alvo 31) e detecção correta para todos os índices (área-alvo 32). Esta região contém 8.300 pixels (7,5 km²) e apresentou as principais mudanças na cobertura do solo entre 2003 e 2012 (Figura 15B). As mudanças na cobertura do solo nesta região ocorreram de forma fragmentada como mostrado na Figura 15B. As principais alterações foram divididas em nove parcelas, de acordo com os diferentes períodos de intervenção (Figura 15B).

A capacidade de distinguir pixels alterados de inalterados é evidente ao usar o índice SAI (Figura 15) no método TSS RESTREND. Os índices EVI e NDVI indicam que praticamente todas as regiões foram alteradas. Por outro lado, alguns pixels considerados pelo método como não sofrendo alterações são inseridos em uma área que, de fato, mudou. A área-alvo 32 foi classificada como "detecção correta" para todos os índices (Figura 14B), mas observa-se um conjunto de pixels com o período de mudança indicado por EVI e NDVI extrapolando os limites do polígono com o período efetivo de LCC (Figura 15).

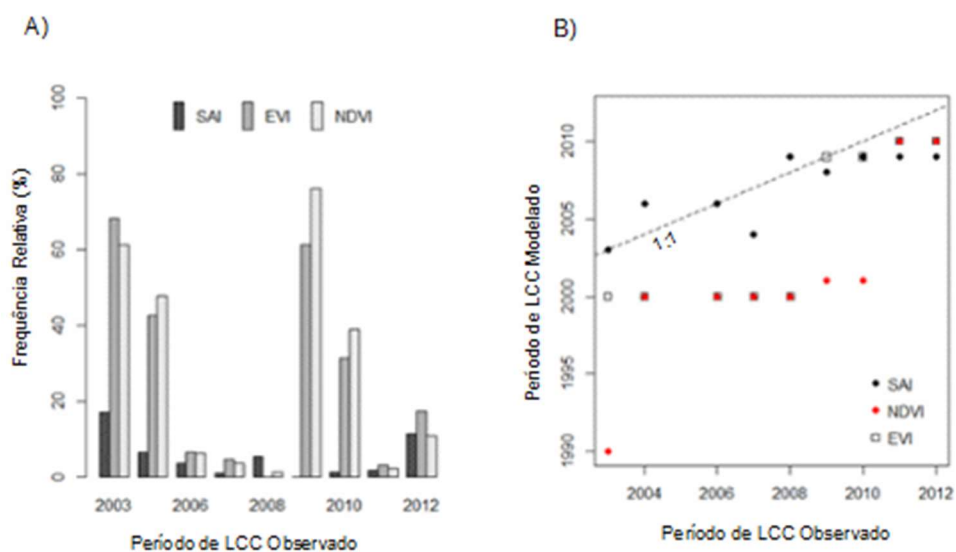
Figura 14 - Período de LCC - TSS RESTREND para SAI, EVI e NDVI (A) e Imagens do Google Earth, sobrepostas aos Polígonos de LCC observado



Fonte: Cunha et al (2018B)

A Figura 16 mostra os resultados da aplicação do método TSS RESTREND para as 9 parcelas onde os períodos de LCC foram observados em anos diferentes: porcentagem dos pixels em que não foram detectados LCC (16A) e a mediana do ano em que o método detectou LCC para os restantes pixels (16B). Os índices EVI e NDVI registraram um alto número de pixels em que o método não detectou LCC (Figura 16A). Além disso, o SAI apresentou valores médianos mais próximos dos valores observados (Figura 16B). O melhor desempenho do EVI e NDVI foi observado para as parcelas que tiveram alteração nos anos de 2011 e 2012. Entretanto, um grande número de observações realizadas por EVI e NDVI indicam como período de LCC anos que tiveram eventos de seca mais graves (Figura 11).

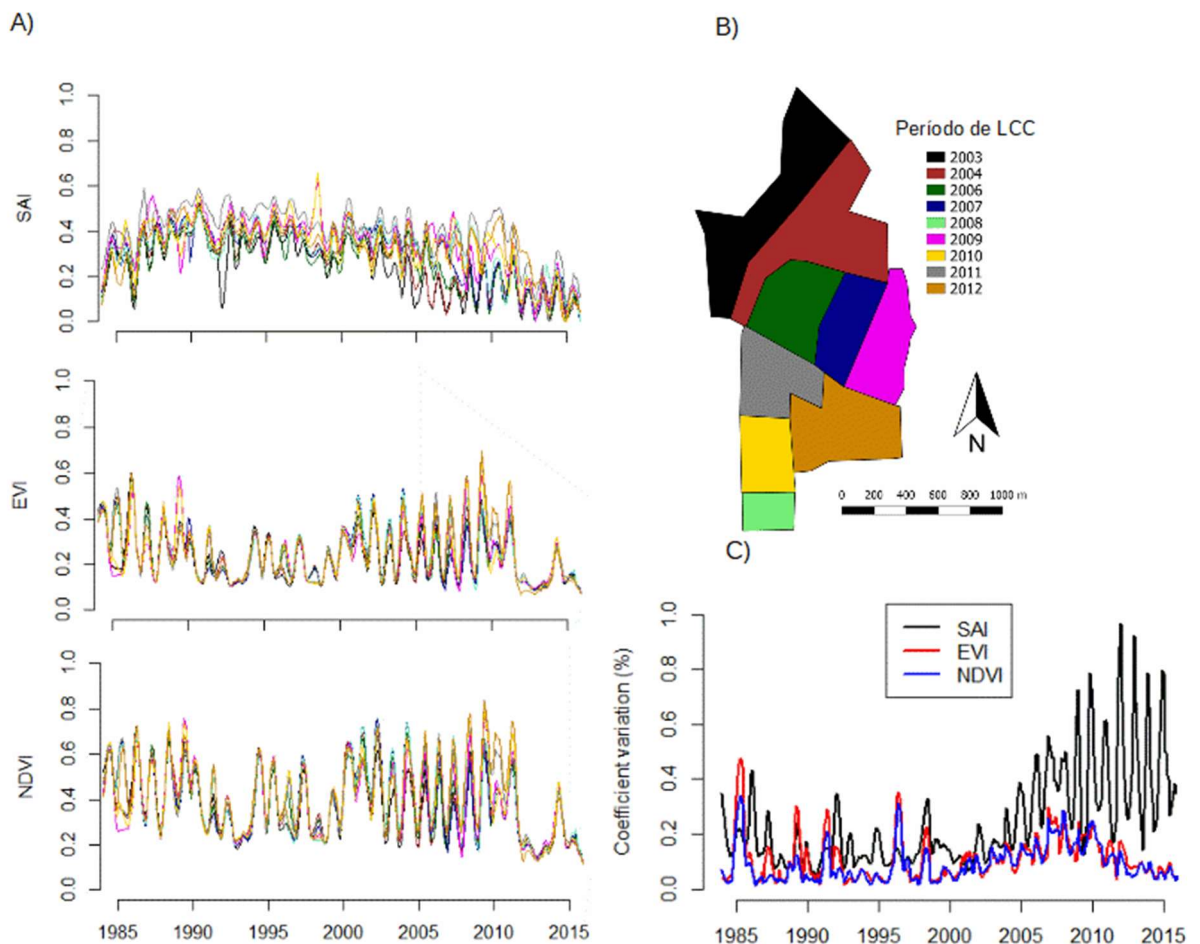
Figura 15 - LCC observada nas diferentes parcelas da região selecionada, em comparação com os resultados obtidos com o método TSS RESTREND para os três índices estudados: A) porcentagem do número total de pixels em cada parcela onde LCC não foi detectado; B) mediana do ano em que foi detectada LCC.



As mudanças na cobertura do solo podem modificar a amplitude e a frequência das séries temporais dos índices estudados, uma vez que cada variação representa um período de alteração de um determinado fragmento de solo. Espera-se que os índices de maior sensibilidade à LCC apresentem um maior coeficiente de variação nos períodos em que houve uma mudança efetiva. À medida que as nove séries apresentavam diferentes períodos de mudança, espera-se que apresentem variações significativas entre as séries temporais de cada índice estudado (1 a 9). Apesar da maior amplitude do sinal, o NDVI apresenta comportamento semelhante ao EVI, com pouca distinção entre as diferentes séries temporais. Quanto ao índice SAI, os

distúrbios são mais visíveis na série e têm um maior coeficiente de variação nos momentos em que as intervenções foram registradas (Figura 17C).

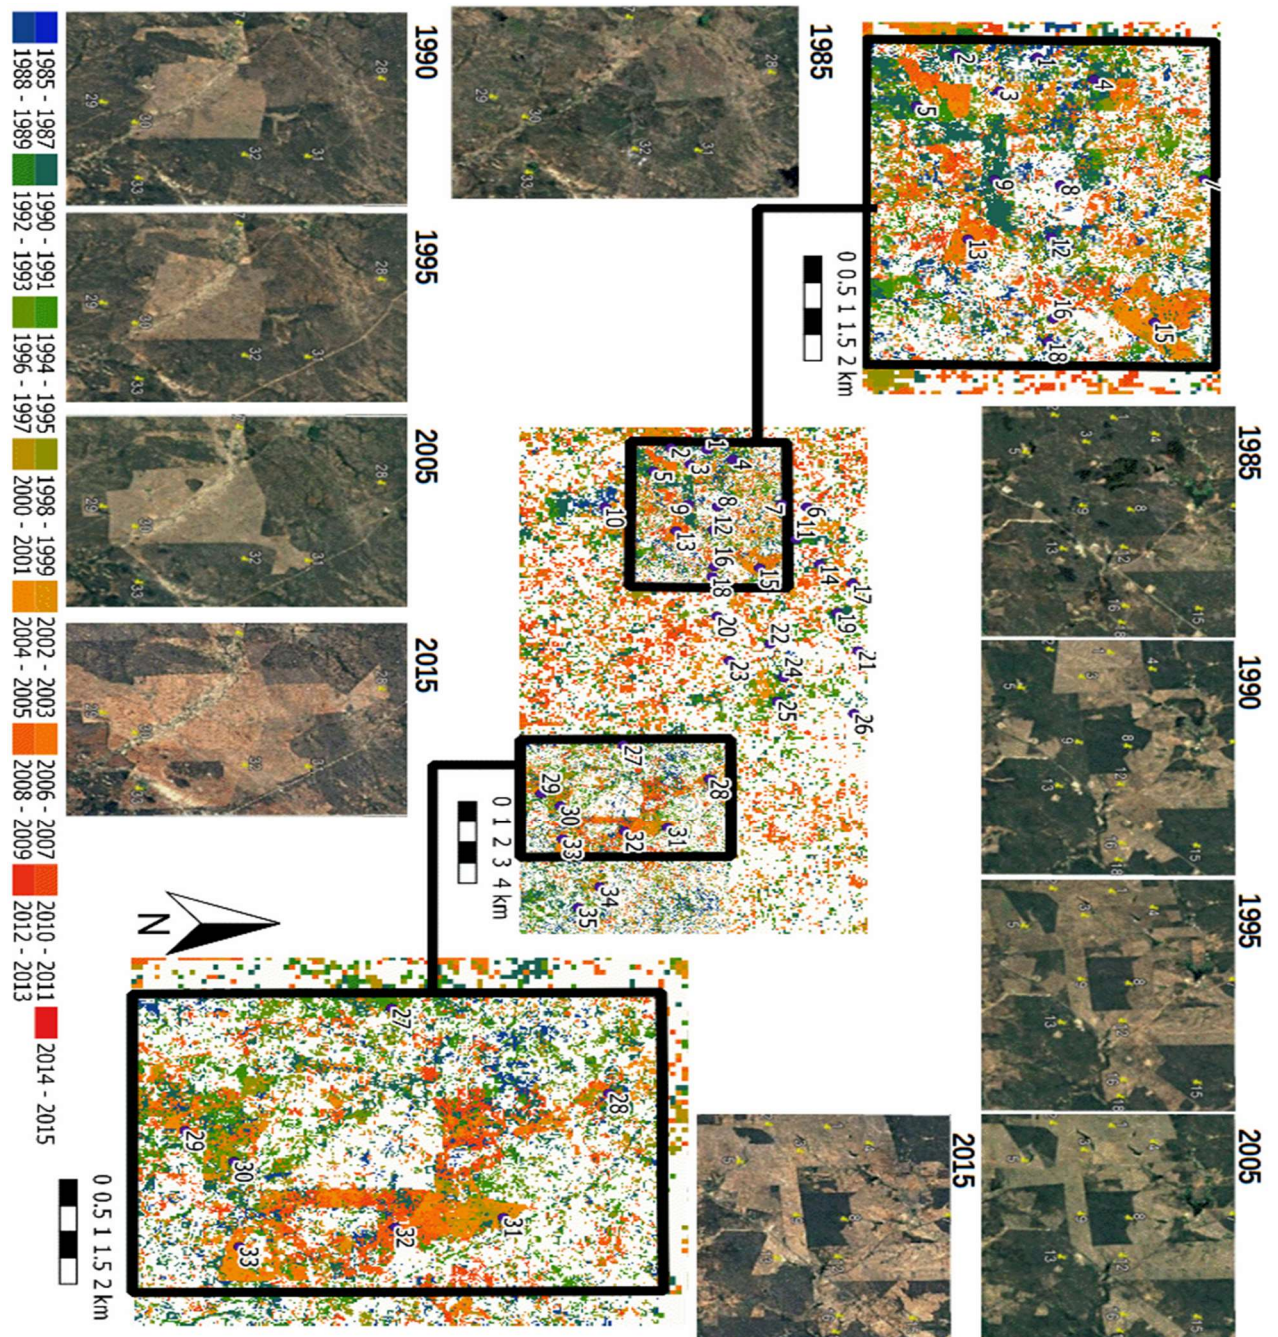
Figura 16 - Séries temporais dos índices SAI, EVI e NDVI (A), período observado de LCC (B) e coeficiente de variação para cada um dos índices entre os nove polígonos LCC (C)



Durante todas as análises anteriores para identificar o período de mudança, o SAI foi o que apresentou o melhor desempenho quando comparado aos índices EVI e NDVI. Na imagem central da Figura 18, apenas o resultado do processamento do algoritmo TSS RESTREND para o índice SAI é observado, sendo possível visualizar os momentos identificados como alterados em todos os pixels da área de estudo. Ao comparar mudanças reais e modeladas (Figura 14B), o desempenho do índice SAI é baixo para os anos iniciais e finais da série temporal (1985-1990 e 2010-2015). Esta limitação também foi visualizada na análise espacial para toda a área estudada, sendo melhor descrita nos polígonos destacados na Figura 18. No polígono esquerdo, tem-se que a região entre as áreas-alvo 2, 3 e 4 foram alteradas antes de 1990 e a

metodologia aplicada não identificou claramente essas mudanças. Um caso semelhante ocorreu na região entre as áreas-alvo 27 e 30, destacadas no polígono direito. Ao fazer uma análise visual entre o mapa com a legenda indicando os momentos de alteração modelados e as imagens, percebe-se uma coerência entre a informação, tanto para identificar quando ocorreu ou não houve mudança na cobertura do solo.

Figura 17 - Período de LCC quando utilizado o índice SAI no método TSS RESTREND para toda a área de estudo



Fonte: Cunha et al. (2018B)

5.5. Discussão

Durante os primeiros anos da série estudada (1985-1998), apenas o satélite Landsat 5 estava em operação, o que resultou em um número menor ou igual a duas imagens mensais. A partir de 1999, o satélite Landsat 7 passou também a fornecer informações, o que permitiu um maior número de imagens mensais com a operação simultânea dos satélites Landsat 5 e 7 continuamente até o ano de 2011, quando houve a interrupção do fornecimento de dados do satélite Landsat 5. A condição de dois satélites em órbita é restabelecida com a operação contínua de Landsat 7 e 8 no ano de 2013.

Flood (2013) não recomenda o uso de menos de três imagens para a composição temporal mensal de imagens. No entanto, apesar das variações na disponibilidade de imagens e no uso de diferentes sensores ao longo do período estudado, não foi observada relação entre esses fatores e as limitações na determinação do período de LCC. Conforme observado anteriormente, houve um bom desempenho para o período central (1990-2011), onde existe uma disponibilidade variada de informações orbitais. Além disso, as limitações observadas ocorrem tanto no início como no final da série temporal (1985-1990 e 2011-2015), que apresentam menor e maior disponibilidade, respectivamente.

A análise de séries temporais com imagens de média resolução espacial (Landsat) permitiu a identificação e comparação com os alvos da superfície do período em que ocorreu LCC, permitindo uma avaliação efetiva da aplicação do método TSS RESTREND, especialmente, em uma região que apresenta cobertura de solo fragmentada e heterogênea. De acordo com o que foi observado neste trabalho, o índice SAI foi o que apresentou melhor desempenho na modelação do período de LCC (Figuras 14, 15 e 16). No entanto, a análise dos resultados permitiu identificar um baixo desempenho para os anos iniciais e finais da série temporal (1985-1990 e 2011-2015). Esta é a principal limitação apresentada pelo método TSS RESTREND quando aplicado com o novo índice SAI.

Em alguns casos, o período de LCC ocorre sequencialmente para os anos secos (antes ou depois). Neste caso, é comum que haja alguma imprecisão para o método na determinação do período de mudança que pode ser atribuído ao momento de maior severidade detectada, por isso, foi considerado como “detecção correta” uma variação menor que dois anos.

O NDVI tem sido a variável mais utilizada nos estudos que buscam distinguir os efeitos da variabilidade do clima e antrópicos nas mudanças na cobertura do solo (LEROUX et al., 2017). O EVI é mais resistente à influência dos aerossóis atmosféricos que o NDVI. Isto é conseguido através da correção do canal vermelho usando a banda azul que é mais sensível ao efeito do aerossol (HUETE et al., 2002). Como tal, o EVI tem melhor monitoramento da vegetação através da dissociação do sinal de fundo do dossel e a redução das influências atmosféricas (HUETE et al., 2002).

Contudo, ambos os índices apresentaram um baixo desempenho no monitoramento das mudanças na cobertura do solo no presente estudo, mesmo o EVI se apresentando como uma medida mais adequada do verde da vegetação do que o NDVI. De acordo com Jones & Vaughan (2010), os valores de NDVI para solo exposto e grama seca são os mesmos (Figura 19), a diferença entre as bandas espectrais NIR e Red é estável (XU et al., 2014). Esse comportamento não permite distinguir entre mudanças de origem antrópica e as resultantes da variabilidade climática, mesmo após o uso de métodos como TSS TRSTREND que visa eliminar a influência sazonal.

Nas florestas tropicais sazonais secas, a relação entre índices de vegetação e variações fenológicas é indiscutível. Os valores de NDVI são influenciados pela precipitação de curto e longo prazo nas variações foliares (Figura 19). Nessas áreas, as folhas das plantas caem substancialmente durante o período seco e esse fenômeno pode confundir as análises para distinguir entre mudanças de origem antrópica e efeitos naturais da variabilidade climática quando somente os índices de vegetação são utilizados. Conforme observado nos resultados, os índices de vegetação apresentaram baixo desempenho para determinar o período de LCC no presente estudo. O NDVI apresentou o pior desempenho, com 55% das áreas-alvo analisadas classificadas como de “detecção errada” no período analisado. A maioria das detecções realizadas por este índice foram para anos historicamente secos ou imediatamente antes dos anos secos (Figura 11). Por outro lado, um alto número das áreas analisados através do EVI foram classificados como “não detectados” (58%), o que significa que não foi identificado um ponto de ruptura na série temporal desse índice, tornando impossível indicar o período de LCC.

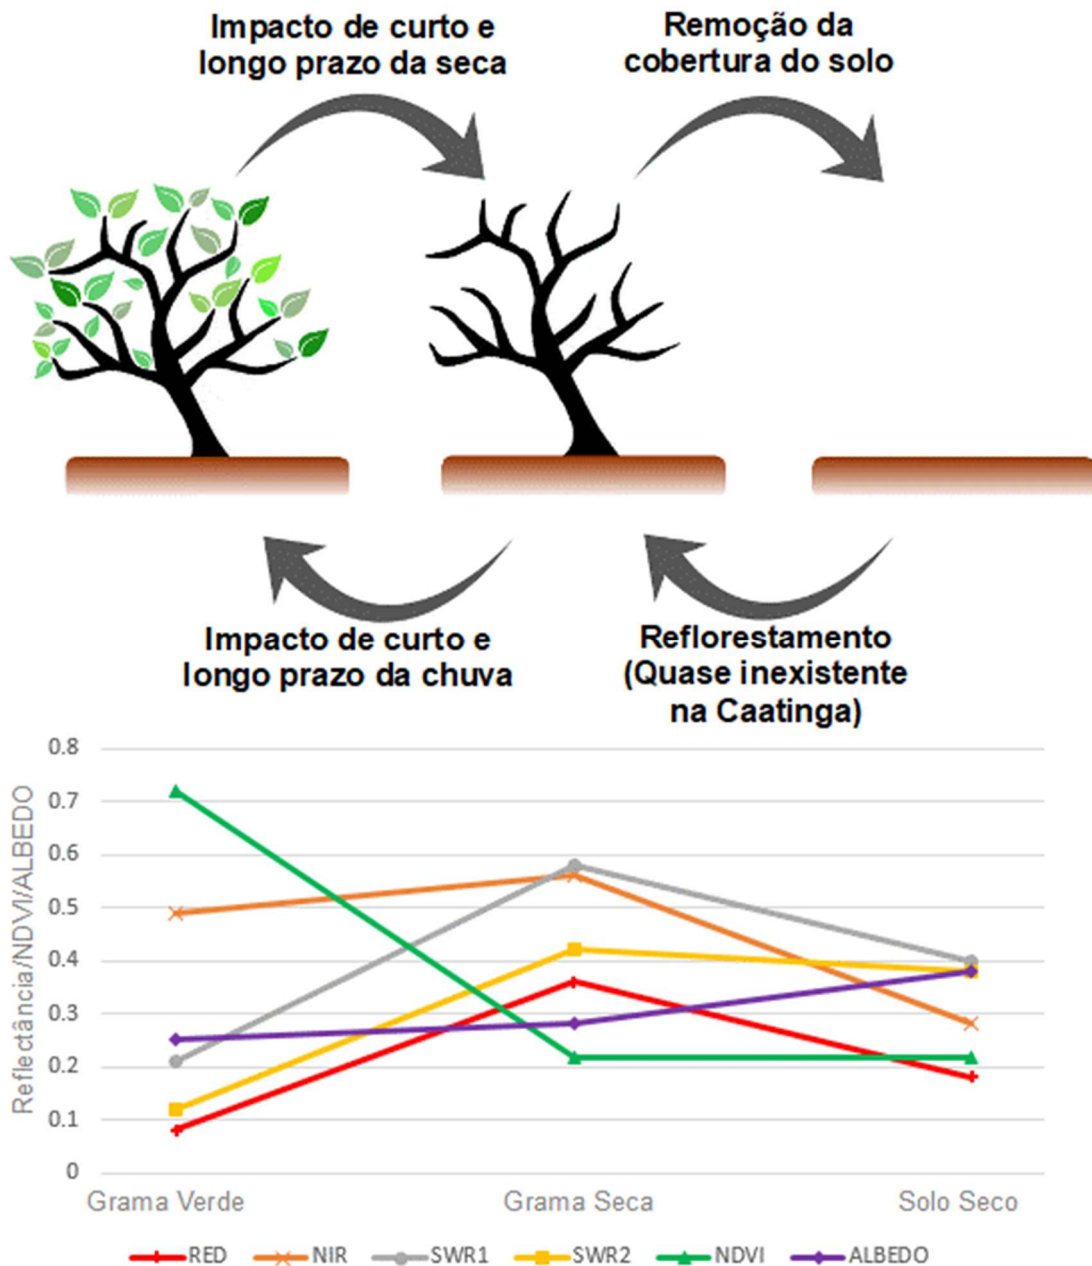
O albedo de superfície (SA) permite o monitoramento do alvo em outras bandas do espectro eletromagnético, que não são observadas pelos índices de vegetação

(NDVI e EVI). Esta condição permite uma maior sensibilidade às mudanças envolvendo mais aspectos do que a perda de folhas (material verde). Todo o sistema solo-planta-atmosfera é alterado em uma ação de desmatamento: além da perda de folhas, há uma remoção de madeira, exposição do solo aos efeitos da radiação, chuva e vento que juntos modificarão as características do solo. Este conjunto de modificações pode ser mais adequadamente detectado ao usar o albedo de superfície. No entanto, o albedo de superfície tem uma relação inversa com o índice de vegetação (VI); enquanto nos VIs os valores mais elevados representam áreas mais vegetadas, no SA esta situação corresponde a valores mais baixos e vice-versa. Apesar da ampla faixa espectral coberta pelo albedo de superfície de banda larga, este indicador apresenta uma pequena taxa de variação de valores para distinguir os alvos mais comuns presentes em uma área natural, como a variação entre o solo seco, grama seca e verde (Figura 19). O índice agora apresentado (SAI) foi desenvolvido de modo a ter um comportamento semelhante aos índices de vegetação e maior sensibilidade.

Os estudos desenvolvidos por Idso et al. (1975) e Fimbres (1996) demonstram a influência da umidade do solo no SA, podendo apresentar variações substanciais entre o solo seco e úmido. A condição de umidade do solo sugere atenção na aplicação do albedo de superfície na análise das mudanças na cobertura do solo. Na região de estudo, os solos apresentam baixa capacidade de acumulação de água. Em uma ação para remover a cobertura do solo, essa capacidade de acumulação de água será reduzida, fazendo com que o SA ocupe valores mais altos. Nos solos com maior profundidade e que se beneficiam das reservas subterrâneas de água, o uso desta metodologia pode apresentar menor desempenho.

DeVries et al. (2015) identificaram que os índices que utilizam as bandas espectrais SWIR são mais sensíveis às mudanças, especialmente o índice *Tasseled Cap Wetness* (TCW). O índice TCW apresenta as mesmas bandas espectrais usadas para calcular o albedo de superfície, o que corrobora com os resultados encontrados neste estudo. A banda espectral SWIR 2 fornece meios robustos para estimar a extensão do solo exposto e as coberturas vegetais em regiões áridas e semi-áridas (Asner e Lobell, 2000). As bandas espectrais SWIR 1 e SWIR 2 discriminam o teor de umidade do solo e vegetação, essas bandas espectrais estão presentes entre as informações utilizadas no cálculo da SA.

Figura 18 - Comportamento da reflectância em diferentes faixas espectrais, NDVI e SA para Grama verde, Grama seca e solo seco



Fonte: Cunha et al. (2018B)

5.6. Conclusões

O TSS-RESTREND é adequado para detectar LCC na Caatinga, uma vez que pode suprimir os pontos de interrupção sazonais e seleccionar aquele com maior impacto. Os resultados mostram que, quando utilizado o índice SAI, o método TSS RESTREND é capaz de distinguir entre cobertura do solo "alterada" e "inalterada" com uma alta precisão, com 80% das estimativas classificadas como "Detecção correta".

Os índices EVI e NDVI têm desempenho semelhante entre si, mas com baixa capacidade para detectar corretamente o momento em que ocorreu uma alteração na cobertura do solo. De forma mais específica, o NDVI apresentou um elevado 40% de detecções erradas e o EVI teve 58% (18 de 31 possíveis) das observações classificadas como não detectadas.

Por a área estudo ser muito fragmentada, a análise é mais precisa devido à resolução espacial apropriada das imagens Landsat. Os períodos na série inicial e final da série mostraram o pior desempenho e, portanto, as longas séries temporais foram importantes para fornecer evidências às nossas conclusões.

O menor desempenho na aplicação do método TSS RESTREND quando utilizados os índices EVI e NDVI na detecção das mudanças da cobertura do solo no bioma da Caatinga é explicado pelas suas altas sensibilidades às variações da cobertura de folhas, como resultado de condições sazonais ou seca extrema. As mudanças na cobertura do solo afetam todo o sistema solo-planta-atmosfera, como remoção de biomassa e mudanças nas propriedades do solo, bem como no microclima, devido à exposição direta à radiação, precipitação e vento. A este respeito, o SAI é suposto ser mais sensível às alterações artificiais da superfície terrestre, devido à sua capacidade de capturar uma maior quantidade de feedback ambiental.

CAPÍTULO VI – CONCLUSÕES GERAIS

A análise das alterações da cobertura do solo requer a utilização de variáveis que possam ter boa representação dos processos ambientais, especialmente, em um ambiente de alta sazonalidade climática como a região do bioma Caatinga. Neste trabalho, as variáveis albedo de superfície e evapotranspiração real diária obtidas por sensores orbitais foram avaliadas para verificar a capacidade de mensuração. As duas variáveis apresentaram bom desempenho quando comparados aos dados obtidos por instrumentação de campo. A avaliação do albedo de superfície reuniu um número maior de momentos e ambientes analisados. Quando utilizado o conjunto de dados Landsat SR, utilizou um menor número de procedimentos e não necessitou de dados meteorológicos por parte do usuário para sua construção.

A automação dos procedimentos para obtenção das variáveis geradas pela aplicação do algoritmo SEBAL, vão além das etapas usuais do seu fluxo de trabalho. São necessários a construção de procedimentos para trabalhar com bancos de dados externos e a garantia da proveniência dos dados. Felizmente, as instituições internacionais que controlam os dados necessários têm disponibilizado aplicativos para facilitar a comunicação e o desenvolvimento de aplicações que requerem extensas séries de dados. Os sistemas computacionais utilizados no desenvolvimento deste trabalho (computação em nuvem e paralelização) permitiram um rápido processo de construção das séries temporais e facilitam o gerenciamento para determinar a origem de cada dado processado. No entanto, os pesquisadores que necessitam trabalhar com grande volume de dados devem estar preparados para trabalhar com rotinas computacionais e interagir com profissionais da área da computação. O aumento da disponibilidade de novos dados gera outras demandas, pois é necessário construir novas rotinas e recursos computacionais que permitam explorar de forma apropriada este novo recurso.

A hipótese proposta nesta tese foi atendida a partir da análise realizada no capítulo V. A aplicação do método TSS RESTREND e o albedo de superfície possibilitou a identificação do ano (período) de cada alteração induzida pelo homem. O albedo de superfície que já havia apresentado bom desempenho na comparação com a instrumentação de campo (Capítulo II), apresentou também uma alta acurácia na indicação do ano (período) em que ocorreu cada remoção da cobertura vegetal

observada. A substituição da cobertura do vegetada por solo exposto é uma mudança da cobertura solo que apresenta características específicas, o ponto de ruptura da ação de desmatamento não é recorrente em séries de comprimento inferior a 30 anos, alterações ocorrerem em porções (área) e as áreas alteradas apresentam forma regular. Essas características são específicas de mudanças da cobertura do solo de origem antrópica, sendo possível compará-las ao output do método TSS RESTREND e avaliação dos pixels (áreas) que indicam remoção da cobertura vegetal. A maior resolução espacial das séries Landsat permitiu uma boa identificação dos alvos alterados, facilitando a sua avaliação.

Outras variáveis ambientais derivadas do balanço de energia podem ser utilizadas na avaliação dos processos de alteração na cobertura do solo em áreas semiáridas. Essas variáveis podem ser ainda mais robustas que o albedo de superfície neste processo de representação das variações biofísicas da cobertura do solo, mas para sua aplicação é preciso uma melhor avaliação das informações providas por SRO. Entretanto, essa avaliação apresenta algumas dificuldades que precisam ser transpostas, a maior parte dos experimentos que mensuram parâmetros do balanço de energia não são configurados para análises conjuntas de SRO.

A escala espacial, temporal e o período de abrangência são fatores importantes para uma correta compatibilização e estabelecimento de métricas para análise. No entanto, as medições de evapotranspiração real realizadas pelos equipamentos de correlações turbulentas são aceitas com as mais confiáveis pela comunidade científica, mas para realizar medições confiáveis precisam trabalhar numa resolução temporal de trinta minutos o que é incompatível com as medições instantâneas fornecidas por SRO. O requisito temporal é uma demanda do analisador de gases do sistema de correlações turbulentas, mas todos os outros instrumentos são configurados para trabalhar na mesma escala temporal de medição. Para se obter uma relação na mesma escala temporal, recorre-se a comparação com dados diários, mas aumentam-se as fontes de incertezas provenientes do *upscaling* temporal dos dados orbitais. Para reduzir as incertezas sobre as medições realizadas pelos equipamentos de correlações turbulentas, os experimentos são, normalmente, instalados em áreas agrícolas homogêneas, com disponibilidade hídrica, espaçamento e altura da plantação bem definido. Essa situação espacial é bem distinta da área alvo deste estudo que apresenta cobertura do solo heterogênea.

Equipamentos como o cintilômetro apresentam maior compatibilidade em espaço e tempo para comparação com as informações obtidas por SRO, pois podem realizar medidas de componentes do balanço de energia em superfícies heterogêneas, abrangendo grandes áreas e resolução temporal de até um minuto. Essas características permitirão uma melhor avaliação dos componentes do balanço de energia e no futuro pode-se ter outras variáveis sendo utilizadas no monitoramento dos processos de alteração da cobertura do solo em áreas semiáridas.

REFERÊNCIAS

- AB'SÁBER, A. N. Os domínios de natureza no Brasil: potencialidades paisagísticas. **Atelié editorial**, 2003.
- ALADOS, C. L.; PUIGDEFÁBREGAS, J.; MARTÍNEZ-FERNÁNDEZ, J. Ecological and socio-economical thresholds of land and plant-community degradation in semi-arid Mediterranean areas of southeastern Spain. **Journal of Arid Environments**, v. 75, n. 12, p. 1368-1376, 2011.
- ALBUQUERQUE, U.P et al. Caatinga Revisited: Ecology and Conservation of an Important Seasonal Dry Forest, *The Scientific World Journal*. 2012.
- ALLEN, BURNETT, KRAMBER, HUNTINGTON, KJAERGAARD, KILIC, KELLY, AND TREZZA. Automated calibration of the metric-landsat evapotranspiration process. **JAWRA Journal of the American Water Resources Association**, v. 49, pp. 563–576, 2013.
- ALLEN, R. G.; TREZZA, R.; TASUMI, M. Surface energy balance algorithms for land. Advance training and user's manual, version 1.0. Kimberly: The Idaho Department of Water Resources, 2002.
- ALLEN, C. MORTON, B. KAMBLE, A. KILIC, J. HUNTINGTON, D. THAU, N. GORELICK, T. ERICKSON, R. MOORE, R. TREZZA, et al. Eeflux: A landsatbased evapotranspiration mapping tool on the google earth engine. In 2015 **ASABE/IA Irrigation Symposium: Emerging Technologies for Sustainable Irrigation-A Tribute to the Career of Terry Howell, Sr. Conference Proceedings**, pages 1–11. American Society of Agricultural and Biological Engineers, 2015.
- ALLEN, IRMAK, TREZZA, HENDRICKX, BASTIAANSSEN, AND KJAERGAARD. Satellite-based ET estimation in agriculture using SEBAL and METRIC. **Hydrological Processes**, v. 25, p. 4011–4027, 2011.
- ALLEN, R. G.; TASUMI, M.; TREZZA, R. Satellite-based energy balance for mapping evapotranspiration with internalized calibration (METRIC) - Model. **Journal of Irrigation and Drainage Engineering**, v.133, p.380-394, 2007.
- ALLEN, R.; TASUMI, MORSE, TREZZA, WRIGHT, BASTIAANSSEN, KRAMBER, LORITE, AND ROBISON. Satellite-based energy balance for Mapping Evapotranspiration with Internalized Calibration (METRIC) - Applications. **Journal of irrigation and drainage engineering**, v. 133, p. 395–406, 2007.
- ALLEN, TASUMI, TREZZA. Satellite-based energy balance for Mapping Evapotranspiration with Internalized Calibration (METRIC) – model. **Journal of irrigation and drainage engineering**, v. 133, p. 380–394, 2007.
- ALLEY, W. M. Using exogenous variables in testing for monotonic trends in hydrologic time series. *Water Resources Research*, v. 24, n. 11, p. 1955–1961, 1988.
- ANDRADE-SILVA, A. C. R. et al. Spatial-Temporal Variation in Orchid Bee Communities (Hymenoptera: Apidae) in Remnants of Arboreal Caatinga in the Chapada Diamantina Region, State of Bahia, Brazil. **Neotropical Entomology**, v. 41, n. 4, p. 296–305, 2012.

- ANYAMBA, A.; SMALL, J. L.; TUCKER, C. J.; PAK, E. W. Assaf et al. Thirty-two years of Sahelian zone growing season non-stationary NDVI3g patterns and trends. **Remote Sensing**, v. 6, n. 4, p. 3101-3122, 2014.
- ARAÚJO, E. L.; CASTRO, C. C.; ALBUQUERQUE, U. P. Dynamics of Brazilian Caatinga – A Review Concerning the Plants, Environment and People. **Functional Ecosystems and Communities**, v. 1, n. October 2015, p. 15–28, 2007.
- ARAÚJO, V. F. P.; BANDEIRA, A. G.; VASCONCELLOS, A. Abundance and stratification of soil macroarthropods in a Caatinga Forest in Northeast Brazil. **Brazilian journal of biology = Revista brasleira de biologia**, v. 70, n. 3 Suppl, p. 737–46, 2010.
- ASNER, G. P.; LOBELL, D. B. A Biogeophysical Approach for Automated SWIR Unmixing of Soils and Vegetation. **Remote Sensing of Environment**, v. 74, p. 99-112, 2000.
- BASTIAANSEN, W. G. M. SEBAL – Based sensible and latent heat fluxes in the irrigated Gediz basin, Turkey. **Journal of Hydrology**, v.229, p.87-100, 2000.
- BASTIAANSEN, W. G. M.; MENENTI, M.; FEDDES, R. A.; HOLTSLAG, A. A. M. A remote sensing surface energy balance algorithm for land (SEBAL) 1. Formulation. **Journal of Hydrology**, v.212-213, p.198-212, 1998.
- BASTIAANSEN, W.G.M.; H. PELGRUM, J. WANG, Y. MA, J.F. MORENO, G.J. ROERINK, AND T. VAN DER WAL. A remote sensing surface energy balance algorithm for land (SEBAL).2.Validation. **Journal of Hydrology**, 212213:213–229, December 1998.
- BASTIAANSEN, W.G.M.; M. MENENTI, R.A. FEDDES, AND A.A.M. HOLTSLAG. A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. **Journal of Hydrology**, 212-213:198–212, December 1998.
- BASTIAANSEN, W.G.M.; M.-UD-D.AHMAD, AND Y.CHEMIN. Satellite surveillance of evaporative depletion across the Indus Basin. **Water Resources Research**, 38(12):9, December 2002.
- BIGGS, T.W.; M. MARSHALL, AND A. MESSINA. Mapping daily and seasonal evapotranspiration from irrigated crops using global climate grids and satellite imagery: Automation and methods comparison. **Water Resources Research**, 52(9):7311–7326, 2016.
- BRITO, A. F.; PRESLEY, S. J.; SANTOS, G. M. M. Temporal and trophic niche overlap in a guild of flower-visiting ants in a seasonal semi-arid tropical environment. **Journal of Arid Environments**, v. 87, p. 161-167. 2012.
- BURRELL, A. L.; EVANS, J. P.; LIU, Y. Detecting dryland degradation using Time Series Segmentation and Residual Trend analysis (TSS-RESTREND). **Remote Sensing of Environment**, 2017.
- CAI, H. et al. Consideration of land use change-induced surface albedo effects in life-cycle analysis of biofuels. **Energy & Environmental Science**, v. 9, p. 2855–2867, 2016.
- CAMMALLERI, C. M. C. ANDERSON, G. CIRAULO, G. D'URSO, W.P. KUSTAS,

- G.LA LOGGIA, AND M.MINACAPILLI. Applications of a remote sensing-based two source energy balance algorithm for mapping surface fluxes without in situ air temperature observations. **Remote Sensing of Environment**, 124: 502–515, 2012.
- CARLSON, T.N.; W.J. CAPEHART, AND R.R. GILLIES. A new look at the simplified method for remote sensing of daily evapotranspiration. **Remote Sensing of Environment**, 54(2):161–167, 1995.
- CHANDER, G. et al. Remote Sensing of Environment Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. **Remote Sensing of Environment**, v. 113, n. 5, p. 893–903, 2009.
- CHEN, J. et al. A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky-Golay filter. **Remote Sensing of Environment**, v. 91, n. 3–4, p. 332–344, 2004.
- CONCEIÇÃO, N., TEZZA, L., HÄUSLER, M., LOURENÇO, S., PACHECO, C.A., FERREIRA, M.I. Three years of monitoring evapotranspiration components and crop and stress coefficients in a deficit irrigated intensive olive orchard. **Agricultural Water Management**, v. 191, p. 138–152, 2017
- COSTA E SILVA F., CORREIA A.C., PIAYDA A., DUBBERT M., REBMANN C., CUNTZ M., WERNER C., DAVID J.S., PEREIRA J.S. Effects of an extremely dry winter on net ecosystem carbon exchange and tree phenology at a cork oak woodland. **Agricultural and Forest Meteorology**, v. 204: p. 48–57, 2015.
- Cunha, J.; Pereira, T. E.; Pereira, E.; Rufino, I.; Galvão, C.; Valente, F.; Brasileiro, F. A High-Throughput Cooperative Service to Estimate Evapotranspiration Using Landsat Imagery. **Environmental Modelling & Software** (em revisão). 2018A
- Cunha, J.; Rufino, I.; Erasmi, S.; Galvão, C.; Nóbrega, R.; Valente, F. Land cover changes in the Caatinga – a Brazilian seasonal dry forest: indicators from Landsat time series (1985–2015). **Remote Sensing of Environment** (em revisão). 2018B
- D'ODORICO, P.; BHATTACHAN, A.; DAVIS, K. F.; RAVI, S.; RUNYAN, C. W. Global desertification: drivers and feedbacks. **Advances in Water Resources**, v. 51, p. 326–344, 2013.
- DEVRIES, B. et al. Robust monitoring of small-scale forest disturbances in a tropical montane forest using Landsat time series. **Remote Sensing of Environment**, 2015.
- DUGUAY, C. R.; LEDREW, E. F. Estimating surface reflectance and albedo from Landsat-5 Thematic Mapper over rugged terrain. **Photogrammetric Engineering and Remote Sensing**, v.58, p.551–558, 1992.
- DUTRIEUX, L. P. et al. Monitoring forest cover loss using multiple data streams, a case study of a tropical dry forest in Bolivia. **ISPRS Journal of Photogrammetry and Remote Sensing**, 2015.
- ERASMI, S. et al. Vegetation greenness in northeastern Brazil and its relation to ENSO warm events. **Remote Sensing**, v. 6, n. 4, p. 3041–3058, 2014.
- ERASMI, S.; SCHUCKNECHT, A.; BARBOSA, M. P.; MATSCHULLAT, J. Vegetation

- greenness in northeastern brazil and its relation to ENSO warm events. **Remote Sensing**, v. 6, n. 4, p. 3041-3058, 2014.
- ER-RAKI,S.; A.CHEHBOUNI, AND B.DUCHEMIN. Combining satellite remote sensing data with the fao-56 dual approach for water use mapping in irrigated wheat fields of a semi-arid region. **Remote Sensing**, 2(1):375–387, 2010.
- EVANS, A. H. Remote sensing of evapotranspiration using automated calibration: Development and testing in the state of Florida. **PhD thesis**, Florida Atlantic University, 2014.
- EVANS, J.; GEERKEN, R. Discrimination between climate and human-induced dryland degradation. **Journal of Arid Environments**, v. 57, n. 4, p. 535–554, 2004.
- EVANS, J.; GEERKEN, R. Discrimination between climate and human-induced dryland degradation. **Journal of Arid Environments**, v. 57, n. 4, p. 535-554, 2004.
- FENG, L. Sensitivity Analysis of Hot/Cold Pixel Selection in SEBAL Model for ET Estimation. **PhD thesis**, Virginia Tech, 2015.
- FENSHOLT, R.; LANGANKE, T.; RASMUSSEN, K.; REENBERG, A.; PRINCE, S. D.; TUCKER, C.; EPSTEIN, H asmus et al. Greenness in semi-arid areas across the globe 1981–2007—an Earth Observing Satellite based analysis of trends and drivers. **Remote sensing of Environment**, v. 121, p. 144-158, 2012.
- FENSHOLT, R.; RASMUSSEN, K.; KASPERSEN, P.; HUBER, S.; HORION, S.; SWINNEN, E. asmus et al. Assessing land degradation/recovery in the African Sahel from long-term earth observation based primary productivity and precipitation relationships. **Remote Sensing**, v. 5, n. 2, p. 664-686, 2013.
- FIMBRES, A. Soil Albedo in Relation to Soil Color , Moisture and Roughness . in the Graduate College. 2017.
- FLOOD, N. Seasonal composite landsat TM/ETM+ Images using the medoid (a multi-dimensional median). **Remote Sensing**, v. 5, n. 12, p. 6481–6500, 2013.
- FOLEY, J. A.; DEFRIES, R.; ASNER, G. P.; BARFORD, C.; BONAN, G.; CARPENTER, S. R.; HELKOWSKI, J. H et al. Global consequences of land use. **Science**, v. 309, n. 5734, p. 570-574, 2005.
- FRENCH, A.N.; D.J. HUNSAKER, AND K.R. THORp. Remote sensing of evapotranspiration over cotton using the tseb and metric energy balance models. **Remote Sensing of Environment**, 158:281–294, 2015.
- FUNK, C. et al. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Scientific Data**, v. 2, p. 150066, 2015.
- GAO, Z.Q; C.S.LIU, W.GAO, AND N.-B.CHANG. A couple dremote sensing and the Surface Energy Balance with Topography Algorithm (SEBTA) to estimate actual evapotranspiration over heterogeneous terrain. **Hydrology and Earth System Sciences**, 15(1):119–139, January 2011.
- GARRISON, J. D.; ADLER, G. P. Estimation of precipitable water over the direct and diffuse components. **Solar Energy**, v. 44, n. 4, p. 225–241, 1990.

- GOOGLE EARTH ENGINE TEAM. Google earth engine: A planetary-scale geo-spatial analysis platform. <https://earthengine.google.com>, 12 2015.
- HANSEN, M.C.; P.V. POTAPOV, R. MOORE, M. HANCHER, S.A. TURUBANOVA, A. TYUKAVINA, D. THAU, S.V. STEHMAN, S.J. GOETZ, T.R. LOVELAND, A. KOMMAREDDY, A. EGOROV, L. CHINI, C.O. JUSTICE, AND J.R.G. TOWNSHEND. High-Resolution Global Maps of 21st-Century Forest Cover Change. **Science**, 342(6160):850–853, November 2013.
- HÄUSLER, M., CONCEIÇÃO, N., TEZZA, L., SÁNCHEZ, J.M., CAMPAGNOLO, M., HÄUSLER, A.J., SILVA, J.M.N., WARNEKE, T., HEYGSTER, G., FERREIRA, M.I. Estimation and partitioning of actual daily evapotranspiration at an intensive olive grove using the STSEB model based on remote sensing. **Agricultural Water Management**, v. 201, p. 188-198, 2018.
- HEIN, L. et al. Desertification in the Sahel: Towards better accounting for ecosystem dynamics in the interpretation of remote sensing images. **Journal of Arid Environments**, v. 75, n. 11, p. 1164–1172, 2011.
- HEIN, L.; DE RIDDER, N.; HIERNAX, P.; LEEMANS, R.; DE WIT, A.; SCHAEPMAN, M et al. Desertification in the Sahel: Towards better accounting for ecosystem dynamics in the interpretation of remote sensing images. **Journal of Arid Environments**, v. 75, n. 11, p. 1164-1172, 2011.
- HELMER, E.H. AND B. RUEFENACHT. Cloud-free satellite image mosaics with regression trees and histogram matching. **Photogrammetric Engineering & Remote Sensing**, 71(9):1079–1089, 2005. ISSN 0099-1112.
- HELSEL, D. R.; HIRSCH, R. M. Trend Analysis. Statistical Methods in Water Resources Techniques of Water Resources Investigations, Book 4, chapter A3, p. 323–355, 2002.
- HIGGINBOTTOM, T. P.; SYMEONAKIS, E. Assessing land degradation and desertification using vegetation index data: Current frameworks and future directions. **Remote Sensing**, v. 6, n. 10, p. 9552–9575, 2014.
- HIGGINBOTTOM, T. P.; SYMEONAKIS, E. Assessing land degradation and desertification using vegetation index data: current frameworks and future directions. **Remote Sensing**, v. 6, n. 10, p. 9552-9575, 2014.
- HOLBEN, B. N. Characteristics of maximum-value composite images from temporal AVHRR data. **International Journal of Remote Sensing**, v. 7, n. 11, p. 1417–1434, 1986.
- HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 195–213, 2002.
- HUETE, A. R. et al. A comparison of vegetation indices over a Global set of TM images for EO -MODIS. **Remote Sensing of Environment**, v. 59, n. Table 1, p. 440–451, 1997.
- HUNSAKER, D.J.; E.M. BARNES, T.R. CLARKE, G.J. FITZGERALD, AND P.J. PINTER JR. Cotton irrigation scheduling using remotely-sensed and fao-56 basal crop coefficients. **Transactions of the ASAE**, 48(4):1395–1407, 2005.

- IBRAHIM, Y. Z. et al. Land degradation assessment using residual trend analysis of GIMMS NDVI3g, soil moisture and rainfall in Sub-Saharan West Africa from 1982 to 2012. **Remote Sensing**, v. 7, n. 5, p. 5471–5494, 2015.
- IBRAHIM, Y. Z., BALZTER, H., KADUK, J., & TUCKER, C. J. Land degradation assessment using residual trend analysis of GIMMS NDVI3g, soil moisture and rainfall in Sub-Saharan west Africa from 1982 to 2012. **Remote Sensing**, v. 7, n. 5, p. 5471-5494, 2015.
- JI, L.; L. ZHANG, B.K. WYLIE, AND J. ROVER. On the terminology of the spectral vegetation index (NIR - SWIR)/(NIR + SWIR). **International Journal of Remote Sensing**, 32(21):6901–6909, 2011.
- JIMÉNEZ-BELLO, M.A. J.R. CASTEL, L. TESTI, AND D.S. INTRIGLIOLO. Assessment of a remote sensing energy balance methodology (SEBAL) using different interpolation methods to determine evapotranspiration in a citrus orchard. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, 8(4):1465–1477, 2015.
- JONG AND S. DE BRUIN. Linear trends in seasonal vegetation time series and the modifiable temporal unit problem. **Biogeosciences**, 9(1): 71–77, 2012.
- JU, J.; MASEK, J. G. The vegetation greenness trend in Canada and US Alaska from 1984-2012 Landsat data. **Remote Sensing of Environment**, 2016.
- KARLSON, M.; OSTWALD, M. Remote sensing of vegetation in the Sudano-Sahelian zone: A literature review from 1975 to 2014, **Journal of Arid Environments**, 2016.
- KATSANOS, D.; RETALIS, A.; MICHAELIDES, S. Validation of a high-resolution precipitation database (CHIRPS) over Cyprus for a 30-year period. **Atmospheric Research**, v. 169, p. 459–464, 2016.
- KUSTAS, W.P. Estimates of evapotranspiration with a one-and two-layer model of heat transfer over partial canopy cover. **Journal of Applied Meteorology**, 29(8):704–715, 1990.
- LAMBIN, E. F.; GEIST, H. J.; LEPERS, E. Dynamics of land use and land cover change in tropical regions. **Annual Review of Environment and Resources**, v. 28, n. 1, p. 205–241, 2003.
- LAMBIN, Eric F.; GEIST, Helmut J.; LEPERS, Erika. Dynamics of land-use and land-cover change in tropical regions. **Annual review of environment and resources**, v. 28, n. 1, p. 205-241, 2003.
- LEAL, I. R. et al. Changing the Course of Biodiversity Conservation in the Caatinga of Northeastern Brazil/Cambiando el Curso de la Conservación de Biodiversidad en la Caatinga del Noreste de Brasil. **Conservation Biology**, v. 19, n. 3, p. 701–706, 2005.
- LEAL, I. R.; TABARELLI, M.; SILVA J. M. C. Ecologia e conservação da caatinga: uma introdução ao desafio. **Associação Caatinga**. p. 13-17, 2006
- LEROUX, L. et al. Driving forces of recent vegetation changes in the Sahel: Lessons learned from regional and local level analyses. **Remote Sensing of Environment**, v. 191, p. 38–54, 2017.

- LI, A.; W. ZHAO, AND W. DENG. A quantitative inspection on spatiotemporal variation of remote sensing-based estimates of land surface evapotranspiration in south asia. **RemoteSensing**,7(4):4726–4752, 2015.
- LI, F. AND T.J. LYONS. Remote estimation of regional evapotranspiration. **Environmental Modelling & Software**, 17(1):61–75, 2002.
- LI, J.; HUMPHREY, M.; AGARWAL, D.; JACKSON, K.; VAN INGEN, C.; RYU, Yie, et al. Escience in the cloud: A modis satellite data reprojection and reduction pipeline in the windows azure platform. Parallel & Distributed Processing (IPDPS), 2010 **IEEE International Symposium on**. IEEE, 2010.
- LI, S; S.DRAGICEVIC, F. A. CASTRO, M.SESTER, S.WINTER, A.COLTEKIN, C.PETTIT, B. JIANG, J. HAWORTH, A. STEIN, AND T. CHENG. Geospatial big data handling theory and methods: A review and research challenges. **ISPRS Journal of Photogrammetry and Remote Sensing**, 115:119 – 133, 2016.
- LI, X. B. et al. Human-induced vegetation degradation and response of soil nitrogen storage in typical steppes in Inner Mongolia, China. **Journal of Arid Environments**, 2016.
- LI, X., WANG, H., WANG, J., & GAO, Z. Land degradation dynamic in the first decade of twenty-first century in the Beijing–Tianjin dust and sandstorm source region. **Environmental Earth Sciences**, v. 74, n. 5, p. 4317-4325, 2015.
- LIANG, S. et al. Validating MODIS land surface reflectance and albedo products: Methods and preliminary results. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 149–162, 2002.
- LIANG, S. Narrowband to broadband conversions of land surface albedo I Algorithms. *Remote Sensing of Environment*, v.76, p.213-238, 2000.
- LIMA, A. L. A.; RODAL, M. J. N. Phenology and wood density of plants growing in the semi-arid region of northeastern Brazil. **Journal of Arid Environments**, v. 74, p. 1363-1372. 2010.
- LINARES-PALOMINO, R.; OLIVEIRA-FILHO, A. T.; PENNINGTON, R. T. Neotropical Seasonally Dry Forests: Diversity, Endemism, and Biogeography of Woody Plants. **Seasonally Dry Tropical Forests**. p. 3–21, 2011.
- LINDQUIST, M. J. Capital-skill complementarity and inequality over the business cycle. **Review of Economic Dynamics**, v. 7, n. 3, p. 519–540, 2004.
- LIU, Y.-A. AND S.K.KAR. Evapotranspiration estimation with remote sensing and various surface energy balance algorithms –a review. **Energies**, 7 (5):2821–2849, 2014.
- LONG, D.; V.P. SINGH, AND Z.-L. LI. How sensitive is sebal to changes in input variables, domain size and satellite sensor? **Journal of Geophysical Research: Atmospheres**, 116(D21), 2011.
- MA, Y.; H. WU, L. WANG, B. HUANG, R. RANJAN, A. ZOMAYA, AND W. JIE. Remote sensing big data computing: Challenges and opportunities. **Future Generation Computer Systems**, 51:47–60, 2015.
- MA, Y.; WU, H.; WANG, L.; HUANG, B.; RANJAN, R.; ZOMAYA, A.; JIE, W. Remote sensing big data computing: Challenges and opportunities. **Future Generation**

- Computer Systems**, v. 51, p. 47-60, 2015.
- MASEK, J. G. et al. A Landsat Surface Reflectance Dataset. v. 3, n. 1, p. 68–72, 2006.
- MASEK, J. G.; VERMOTE, E. F.; SALEOUS, N. E.; WOLFE, R.; HALL, F. G.; HUENNRICH, K. F.; GAO, F.; KUTLER, J., LIM, T. A Landsat Surface Reflectance Dataset for North America, 1990-2000. *IEEE Geoscience and Remote Sensing Letters*, v.3, p.68-72, 2006.
- MASEK, J.; VERMOTE, E.; GAO, F. Landsat ecosystem disturbance adaptive processing system (LEDAPS) algorithm description. **U.S. Geological Survey Open File Report** 2013, 17 p.
- MEA. Millennium Ecosystem Assessment, Ecosystems and Human Well-Being: Desertification Synthesis. Washington DC: World Resource Institute; 2005.
- MIRA, M; A.OLIOSO, B.GALLEGO-ELVIRA, D.COURAULT, S.GARRIGUES, O.MARLOIE, O. HAGOLLE, P. GUILLEVIC, AND G. BOULET. Uncertainty assessment of surface net radiation derived from landsat images. **Remote Sensing of Environment**, 175:251–270, 2016.
- MORO, M. F. et al. A Phytogeographical Metaanalysis of the Semiarid Caatinga Domain in Brazil. **The Botanical Review**, 2016.
- MORTON, C.G; J.L. HUNTINGTON, G.M. POHLL, R. ALLEN, K.C. MCGWIRE, AND S.D. BASSETT. Assessing calibration uncertainty and automation for estimating evapotranspiration from agricultural areas using metric. **JAWRA Journal of the American Water Resources Association**, 49(3):549–562, 2013. ISSN 1752-1688.
- MU, Q.; M. ZHAO, AND S.W. RUNNING. Improvements to a modis global terrestrial evapotranspiration algorithm. **Remote Sensing of Environment**, 115(8):1781–1800, 2011.
- NORMAN, J.M.; W.P. KUSTAS, AND K.S. HUMES. Source approach for estimating soil and vegetation energy fluxes in observations of directional radiometric surface temperature. **Agricultural and Forest Meteorology**, 77(3-4):263–293, 1995.
- NUMATA, I.; K. KHAND, J. KJAERGAARD, M.A. COCHRANE, AND S.S. SILVA. Evaluation of landsat-based metric modeling to provide high-spatial resolution evapotranspiration estimates for Amazonian forests. **Remote Sensing**, 9(1):46, 2017.
- NUTINI, F.; M. BOSCHETTI, G. CANDIANI, S. BOCCHI, AND P.A. BRIVIO. Evaporative fraction as an indicator of moisture condition and water stress status in semi-arid range land ecosystems. **RemoteSensing**,6(7):6300–6323, 2014.
- OLIVEIRA, D. G. et al. O Efeito de borda Influencia a estrutura da comunidade vegetal em uma floresta tropical Seca. **Revista Árvore**, p. 311–320, 2013.
- OLIVEIRA, P. T. B.; TROVÃO, D. M. D. B. M.; CARVALHO, E. C. D.; SOUZA, B. C.; FERREIRA, L. M. R. et al. Florística e fitossociologia de quatro remanescentes vegetacionais em áreas de serra no Cariri Paraibano. **Revista Caatinga**, v. 22, n. 4, p. 169-178, 2009.

- PAÇO, T.A.; I. PÔÇAS, M. CUNHA, J.C. SILVESTRE, F.L. SANTOS, P. PAREDES, AND L.S. PEREIRA. Evapotranspiration and crop coefficients for a super intensive olive orchard. an application of simdualkc and metric models using ground and satellite observations. **Journal of Hydrology**,519:2067– 2080, 2014.
- RODAL, M.; BARBOSA, M.; THOMAS, W. Do the seasonal forests in northeastern Brazil represent a single floristic unit? **Brazilian Journal of Biology**, v. 68, n. 3, p. 467–475, 2008.
- ROERINK, G.J.; Z. SU, AND M. MENENTI. S-SEBI: A simple remote sensing algorithm to estimate the surface energy balance. **Physics and Chemistry of the Earth, PartB: Hydrology, Oceans and Atmosphere**,25(2):147–157, 2000.
- ROMÁN, M. O. et al. The MODIS (Collection V005) BRDF/albedo product: Assessment of spatial representativeness over forested landscapes. **Remote Sensing of Environment**, v. 113, n. 11, p. 2476–2498, 2009.
- SALES, M. C. L. Evolução dos Estudos de Desertificação no Nordeste Brasileiro. GEOUSP - Espaço e Tempo, São Paulo, Nº 14, pp. 9-19, 2003.
- SANTOS, A M.; TABARELLI, M. Distance from roads and cities as a predictor of habitat loss and fragmentation in the caatinga vegetation of Brazil. **Brazilian journal of biology = Revista brasleira de biologia**, v. 62, n. 4B, p. 897–905, 2002.
- SANTOS, C. et al. Obtaining of Environmental Parameters in the Semiarid Region of Paraíba by MODIS Data. **Revista Brasileira Meteorologia**, v.32, p. 633–647, 2017
- SANTOS, R. M. et al. Identity and relationships of the Arboreal Caatinga among other floristic units of seasonally dry tropical forests (SDTFs) of north-eastern and Central Brazil. . 2012.
- SAVITZKY, A.; GOLAY, M. J. E. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. **Analytical Chemistry**, v. 36, n. 8, p. 1627–1639, 1964.
- SCHAAF, C. B. et al. First operational BRDF, albedo nadir reflectance products from MODIS. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 135–148, 2002.
- SCHERTZ, T.; ALEXANDER, R.; OHE, D. The computer program Estimate Trend (ESTREND), a system for the Detection of Trends in Water-quality data. p. 1–63, 1991.
- SCHUCKNECHT, A. et al. Assessing vegetation variability and trends in north-eastern Brazil using AVHRR and MODIS NDVI time series. **European Journal of Remote Sensing**, v. 46, n. 1, p. 40–59, 2013.
- SEBASTIÀ, M. T. ; BELLO, F.; PUIG, L.; TAULL, M. et al. Grazing as a factor structuring grasslands in the Pyrenees. **Applied Vegetation Science**, v. 11, n. 2, p. 215-222, 2008.
- SEMMENS, K.A; M.C.ANDERSON, W.P.KUSTAS, F.GAO, J.G.ALfIERI, L.MC KEE, J.H. PRUEGER, C.R. HAIN, C. CAMMALLERI, Y. YANG, et al. Monitoring daily evapotranspiration over two California vine yard susing landsat8 in a multi-

- sensor data fusion approach. **Remote Sensing of Environment**, 185: 155–170, 2016.
- SHUAI, Y. et al. An algorithm for the retrieval of 30-m snow-free albedo from Landsat surface reflectance and MODIS BRDF. **Remote Sensing of Environment**, v. 115, n. 9, p. 2204–2216, 2011.
- SHUAI, Y. et al. An approach for the long-term 30-m land surface snow-free albedo retrieval from historic Landsat surface reflectance and MODIS-based a priori anisotropy knowledge. **Remote Sensing of Environment**, v. 152, p. 467–479, 2014.
- SILVA, B. B. DA; BRAGA, A. C.; BRAGA, C. C.; OLIVEIRA, L. M. M. DE; MONTENEGRO, S. M. G. L.; BARBOSA JUNIOR, B. Procedures for calculation of the albedo with OLI-Landsat 8 images: Application to the Brazilian semi-arid. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.20, p.3-8, 2016.
- SILVA, B. B. DA; LOPES, G. M.; AZEVEDO, P. V. DE. Determinação do albedo de áreas irrigadas com base em imagens Landsat 5 TM. **Revista Brasileira de Agrometeorologia**, v.13, p.201-211, 2005.
- SILVA, R. M. A. Entre o combate à seca e a convivência com o semi-árido: transições paradigmáticas e sustentabilidade do desenvolvimento. 2006.
- SIMMHAN, Y.L.; B. PLALE, AND D. GANNON. A survey of data provenance in e-science. **SIGMOD Rec.**, 34(3):31–36, September 2005.
- STOREY J.C., SCARAMUZZA P., SCHMIDT G. Landsat 7 scan line corrector-off gap filled product development. **PECORA 16 Conference Proceedings**, Sioux Falls, South Dakota, pp. 23-27, 2005.
- STROPPIANA, D. et al. A method for extracting burned areas from Landsat TM/ETM+ images by soft aggregation of multiple Spectral Indices and a region growing algorithm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 69, p. 88–102, 2012.
- STROPPIANA, D; BORDOGNA, G.; CARRARA, P.; BOSCHETTI, M.; BOSCHETTI, L.; BRIVIO, P. A. et al. A method for extracting burned areas from Landsat TM/ETM+ images by soft aggregation of multiple Spectral Indices and a region growing algorithm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 69, p. 88-102, 2012.
- SU, Z. The surface energy balance system (SEBS) for estimation of turbulent heat fluxes. **Hydrology and Earth System Sciences**, 6(1):85–100, 2002.
- TANG, Q.; S. PETERSON, R.H. CUENCA, Y. HAGIMOTO, AND D.P. Lettenmaier. Satellite-based near-real-time estimation of irrigated crop water consumption. **Journal of Geophysical Research: Atmospheres**, 114(D5):n/a–n/a, 2009.
- TEIXEIRA, A.H.C; W.G.M.BASTIAANSEN, M.-UD-D.AHMAD, AND M.G.BOS. Reviewing SEBAL input parameters for assessing evapotranspiration and water productivity for the low-middle São Francisco river basin, Brazil: Part a: Calibration and validation. **Agricultural and Forest Meteorology**, 149(3):462–476, 2009.
- TREZZA, Ricardo; ALLEN, Richard G.; TASUMI, Masahiro. Estimation of actual

- evapotranspiration along the Middle Rio Grande of New Mexico using MODIS and landsat imagery with the METRIC model. **Remote Sensing**, v. 5, n. 10, p. 5397-5423, 2013.
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.
- VERBESSELT, J. et al. Detecting trend and seasonal changes in satellite image time series. *Remote Sensing of Environment*, 2010.
- VERBESSELT, J. et al. Remotely sensed resilience of tropical forests. **Nature Climate Change**, 2016.
- VERBESSELT, J.; ZEILEIS, A.; HEROLD, M. Near real-time disturbance detection using satellite image time series. **Remote Sensing of Environment**, 2012.
- VERMOTE, E.; JUSTICE, C.; MARTIN, C.; FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v.185, p.46-56, 2016.
- VERMOTE, E.F., KOTCHENOVA, S.Y., 2008. Atmospheric correction for the monitoring of land surfaces. **Journal of Geophysical Research**, v.113, p.1-12, 2008.
- WALTER et al, T.; ENVIRONMENTAL, R. E. THE ASCE STANDARDIZED REFERENCE Task **Committee on Standardization of Reference Evapotranspiration**. 2005.
- WAN, Z.; K. ZHANG, X. XUE, Z. HONG, Y. HONG, AND J.J. GOURLEY. Water balance-based actual evapotranspiration reconstruction from ground and satellite observations over the conterminous United States. **Water Resources Research**, 51(8):6485–6499, 2015. ISSN 1944-7973.
- WANG, X. Z.; ZHANGA, H. M.; ZHAO, J. H.; LIN, Q. H.; ZHOU, Y. C.; LI, J. et al. An Interactive Web-Based Analysis Framework for Remote Sensing Cloud Computing. *ISPRS Annals of Photogrammetry*, **Remote Sensing and Spatial Information Sciences**, v. 1, p. 43-50, 2015.
- WANG, X.Z.; H.M. ZHANG, J.H. ZHAO, Q.H. LIN, Y.C. ZHOU, AND J.H. LI. An interactive web-based analysis framework for remote sensing cloud computing. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, 4:W2, 2015.
- WANG, Z. et al. Monitoring land surface albedo and vegetation dynamics using high spatial and temporal resolution synthetic time series from Landsat and the MODIS BRDF/NBAR/albedo product. **International Journal of Applied Earth Observation and Geoinformation**, 2017.
- WANG, Z. et al. Remote Sensing of Environment Early spring post-fire snow albedo dynamics in high latitude boreal forests using Landsat-8 OLI data. **Remote Sensing of Environment**, v. 185, p. 71–83, 2016.
- WANG, Z., SCHAAF, C. B., SUN, Q., KIM, J., ERB, A. M., GAO, F., ... & MASEK, J. G. Monitoring land surface albedo and vegetation dynamics using high spatial and temporal resolution synthetic time series from Landsat and the MODIS BRDF/NBAR/albedo product. **International Journal of Applied Earth**

- Observation and Geoinformation**, vol. 59, p. 104-117, 2017.
- WANG, Z.; A. M ERB, C.B. SCHAAF, Q. SUN, Y. LIU, Y. YANG, Y. SHUAI, K.A. Casey, and M.O. Román. Early spring post-fire snow albedo dynamics in high latitude boreal forests using landsat-8 oli data. **Remote Sensing of Environment**, 185:71–83, 2016.
- WESSELS, K. J.; PRINCE, S. D.; MALHERBE, J.; SMALL, J.; FROST, P. E.; VANZYL, D et al. Can human-induced land degradation be distinguished from the effects of rainfall variability? A case study in South Africa. **Journal of Arid Environments**, v. 68, n. 2, p. 271-297, 2007.
- WESSELS, K. J.; VAN DEN BERGH, F.; SCHOLE, R. J. Limits to detectability of land degradation by trend analysis of vegetation index data. **Remote Sensing of Environment**, v. 125, p. 10-22, 2012.
- WULDER, M. A. et al. The global Landsat archive: Status, consolidation, and direction. **Remote Sensing of Environment**, v. 185, p. 271–283, 2016.
- XU, D. et al. Remote Sensing of Environment Measuring the dead component of mixed grassland with Landsat imagery. **Remote Sensing of Environment**, v. 142, p. 33–43, 2014.
- YANG, C.; SUN, M.; LIU, K.; HUANG, Q.; LI, Z.; GUI, Z.; LOSTRITTO, P. haowei et al. Contemporary computing technologies for processing big spatiotemporal data. In: **Space-Time Integration in Geography and GIScience**. Springer Netherlands, p. 327-351, 2015.
- YANG, X.; Q. ZHOU, AND M. MELVILLE. Estimating local sugarcane evapotranspiration using landsat tm image and a vitt concept. **International Journal of Remote Sensing**, 18(2):453–459, 1997.
- YANG, X.; Q. ZHOU, AND M.D. MELVILLE. Estimating local sugarcane evapotranspiration using landsat tm imagery. **Proceeding of 8th Australian Remote Sensing Conference**, 2:262–269, 1996.
- ZHANG, J.; NIU, J.; BAO, T.; BUYANTUYEV, A.; ZHANG, Q.; DONG, J.; ZHANG, JING, X. Human induced dryland degradation in Ordos Plateau, China, revealed by multilevel statistical modeling of normalized difference vegetation index and rainfall time-series. **Journal of Arid Land**, v. 6, n. 2, p. 219-229, 2014.
- ZHANG, K.; J.S. KIMBALL, AND S.W. RUNNING. A review of remote sensing based actual evapotranspiration estimation. *Wiley Interdisciplinary Reviews: Water*, 3(6):834–853, 2016.
- ZHONG, Q., Li, Y.H. Satellite observation of surface albedo over the Qinghai-Xizang plateau region. **Adv. Atmos. Sci.** 5, 57–65, 1988.
- ZHU, Z. AND C.E. WOODCOCK. Object-based cloud and cloud shadow detection in landsat imagery. **Remote Sensing of Environment**, 118:83–94, 2012.
- ZHU, Z.; Y. FU, C.E. WOODCOCK, P. OLOFSSON, J.E. VOGELMANN, C. HOLDEN, M. WANG, S. DAI, AND Y. YU. Including land cover change in analysis of greenness trends using all available landsat 5, 7, and 8 images: A case study from Guangzhou, china (2000–2014). **Remote Sensing of Environment**, 185:243–257, 2016.