



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

**SENSORIAMENTO REMOTO E MODELAGEM APLICADOS À ESTIMATIVA DE
SECA EM PERNAMBUCO**

JOSÉ DIORGENES ALVES OLIVEIRA

RECIFE

2021

JOSÉ DIORGENES ALVES OLIVEIRA

**SENSORIAMENTO REMOTO E MODELAGEM APLICADOS À ESTIMATIVA DE
SECA EM PERNAMBUCO**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola na Área de Concentração em Engenharia de Água e Solo, da Universidade Federal Rural de Pernambuco (UFRPE), como requisito para obtenção do título de Doutor em Engenharia Agrícola.

Orientadora: Prof^ª. Dr^ª. Suzana Maria Gico Lima Montenegro

RECIFE

2021

Dados Internacionais de Catalogação na Publicação
Universidade Federal Rural de Pernambuco
Sistema Integrado de Bibliotecas
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

O48s

Oliveira, José Diorgenes Alves
SENSORIAMENTO REMOTO E MODELAGEM APLICADOS À ESTIMATIVA DE SECA EM PERNAMBUCO
/ José Diorgenes Alves Oliveira. - 2021.
184 f. : il.

Orientadora: Suzana Maria Gico Lima Montenegro.
Inclui referências.

Tese (Doutorado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Engenharia Agrícola,
Recife, 2022.

1. Sensoriamento remoto. 2. Seca. 3. Pernambuco. I. Montenegro, Suzana Maria Gico Lima, orient. II. Título

CDD 630

JOSÉ DIORGENES ALVES OLIVEIRA

**SENSORIAMENTO REMOTO E MODELAGEM APLICADOS À ESTIMATIVA DE
SECA EM PERNAMBUCO**

Tese apresentada à Universidade Federal Rural de Pernambuco, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de Doutor em Engenharia Agrícola. Tese defendida e aprovada pela Banca Examinadora em: 29/06/2021

COMISSÃO JULGADORA

ORIENTADOR:

Profa. Dra. Suzana Maria Gico Lima Montenegro (UFRPE/DEAGRI)

BANCA EXAMINADORA

Prof. Dra. Ana Lúcia Bezerra Candeias (UFRPE/CTG)

Profa. Dra. Werônica Meira de Souza (UFRPE/UAG)

Profa. Dra. Josiclêda Domiciano Galvêncio (UFPE/Prodema)

Prof. Dr. Hernande Pereira da Silva (UFRPE/DEAGRI)

OFERECIMENTO/DEDICO

*Dedico esta, bem como todas as minhas demais
conquistas, a Deus, a minha mãe Cileide
Alves, e ao meu irmão José Fellipe.*

“Seus sonhos são as letras do livro que sua vida está escrevendo.”

(Paulo Coelho)

AGRADECIMENTOS

Primeiramente a Deus, por ter me dado uma família maravilhosa e amigos verdadeiros. Deus que me atribuiu missões e permitiu que tudo isso acontecesse, não apenas nesses anos como universitário, mas em todos os momentos, é o maior mestre que alguém pode conhecer.

Aos meus pais Cileide Alves de Almeida e Aluísio Lima de Oliveira, por minha vida, pelos exemplos de luta e de uma vida digna, com humildade e respeito ao próximo, por terem me apoiado em todos os momentos que precisei. Obrigado por tudo.

A meu irmão José Fellipe que me estimulou a chegar até esta etapa de minha vida.

Aos meus avós paternos, Francisco e Josefa e maternos, Adeildo e Severina por eles terem me dado pais tão maravilhosos, agradeço eternamente.

A Professora orientadora, Dra. Suzana Montenegro, pela paciência na orientação, incentivo e amizade. Por ser um exemplo de pessoa e de profissional, por compartilhar comigo sua experiência durante o curso.

Um agradecimento especial para a professora Dra. Ceres Duarte Guedes Cabral de Almeida, pelo incentivo e ajuda em todo o período de construção da tese. Não posso esquecer a sua grande contribuição para o meu crescimento como pesquisador, desde os tempos de mestrado. Eternamente grato por todo o apoio.

A Universidade Federal Rural de Pernambuco, especialmente ao Programa de Pós-Graduação em Engenharia Agrícola, pela oportunidade de realização do mestrado em Engenharia Agrícola. Aos professores e colegas do Programa de Pós-Graduação em Engenharia Agrícola pelos ensinamentos e amizade concedidos. À banca examinadora pela colaboração na versão final desse trabalho.

A todas as instituições que, de forma direta ou indireta, contribuíram com a construção desse documento, seja através da concessão de bolsas, auxílios ou dados. Um agradecimento especial à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), à Fundação de Amparo à Ciência e Tecnologia de Pernambuco (FACEPE) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

A todos que contribuíram direta ou indiretamente na elaboração deste trabalho.

RESUMO GERAL

SENSORIAMENTO REMOTO E MODELAGEM APLICADOS À ESTIMATIVA DE SECA EM PERNAMBUCO

O Estado de Pernambuco, localizado no Nordeste do Brasil, possui boa parte do seu território inserido na região semiárida, que vêm sofrendo com as irregularidades das chuvas e consequentemente, com o fenômeno das secas afetando diretamente a segurança hídrica. A escassez de informações que subsidiem os prognósticos a curto, médio e longo prazo, dificulta a gestão eficiente dos recursos hídricos. Diante disso, este estudo teve como objetivo avaliar e estimar a eficiência de dados de sensores remotos e modelos climáticos no monitoramento de eventos de seca no Estado de Pernambuco. Para isso, dados do algoritmo SM2RAIN foram validados para utilizá-los no cálculo de anomalias de precipitação em Pernambuco, em diferentes períodos. Já os dados de umidade do solo do Soil Moisture and Ocean Salinity (SMOS) com uma resolução espacial de 1 km, também foram validados em todo Estado para estimativa do índice de seca SWDI (Soil Water Deficit Index), para o período de 2015 a 2019. Outra análise desse estudo focou em avaliar o impacto das mudanças climáticas nas ocorrências de futuras secas, utilizando os índices SPI (Índice de Precipitação Padronizado), SPEI (Índice de Precipitação e Evapotranspiração Padronizado) e SSMI (Índice de Umidade do Solo Padronizado), por dados futuros de modelos climáticos e o modelo hidrológico SWAT, na bacia hidrográfica do rio Pajeú, localizada na região semiárida de Pernambuco. Os resultados mostraram que o SM2RAIN e o SMOS-L4 tiveram ótimas correlações com os dados *in situ*, mostrando um grande potencial para estimar e monitorar a precipitação e umidade do solo, podendo ainda serem utilizados para avaliar a seca, através de mapas de anomalia ou por índices como o SWDI, em uma determinada região. Em relação aos eventos futuros de seca na bacia do semiárido pernambucano, os índices de seca foram capazes de mostrar, de forma espacial e temporal, que a bacia sofrerá com a seca até o fim do século, principalmente nas últimas décadas, e a região sul da bacia está mais susceptível em sofrer com as mudanças climáticas, em todos os cenários de emissão de gases do efeito estufa.

Palavras-chave: índices de seca, precipitação, recursos hídricos, umidade do solo.

GENERAL ABSTRACT

REMOTE SENSING AND CLIMATE APPLIED TO THE DROUGHT ESTIMATE IN PERNAMBUCO

The State of Pernambuco, located in the Northeast of Brazil, has a large part of its territory inserted in the semi-arid region, which has been suffering from the irregularities of the rains and, consequently, with the phenomenon of droughts directly affecting water security. The scarcity of information that supports short, medium and long-term prognosis makes it difficult to manage water resources efficiently. Therefore, this study aimed to evaluate and estimate the efficiency of data from remote sensors and climate models in monitoring drought events in the State of Pernambuco. For this, data from the SM2RAIN algorithm were validated to use them in the calculation of precipitation anomalies in Pernambuco, in different periods. Soil Moisture and Ocean Salinity (SMOS) soil moisture data, with a resolution of 1 km, were also validated throughout the State to estimate the SWDI (Soil Water Deficit Index) drought index, for the period of 2015 to 2019. Another analysis of this study focused on assessing the impact of climate change on future drought events, using the SPI (Standardized Precipitation Index), SPEI (Standardized Precipitation and Evapotranspiration Index) and SSMI (Standardized Soil Moisture Index), by through future data from climate models and the SWAT hydrological model, in the hydrographic basin of the Pajeú River, located in the semi-arid region of Pernambuco. The results showed that SM2RAIN and SMOS-L4 had excellent correlations with the data in situ, showing a great potential to estimate and monitor the precipitation and soil moisture, and it can also be used to assess the drought, through anomaly maps or by indexes like SWDI, in a given region. In relation to future drought events in the Pernambuco semiarid basin, drought rates were able to show, in a spatial and temporal way, that the basin will suffer from drought until the end of the century, especially in the last decades, and the southern region. The basin is more likely to suffer from climate change, in all scenarios of greenhouse gas emissions.

Keywords: drought index, precipitation, water resources, soil moisture.

LISTA DE FIGURAS

Figura 1 - Representação esquemática da equação do balanço hídrico do solo e fluxos usados no algoritmo SM2RAIN.	32
Figura 2 - Mapa de localização do Estado de Pernambuco e das mesorregiões, com destaque para a localização das estações INMET.	50
Figura 3. Diagramas de dispersão dos dados de precipitação do SM2RAIN-GPM e das estações mensurados durante o período avaliado, em escala mensal.	57
Figura 4. Diagramas de dispersão dos dados de precipitação do SM2RAIN-ASCAT e das estações mensurados durante o período avaliado, em escala mensal.	57
Figura 5. Diagramas de dispersão dos dados de precipitação do SM2RAIN-CCI e das estações mensurados durante o período avaliado, em escala mensal.	59
Figura 6 - Precipitação estimada pelo SM2RAIN (GPM e ASCAT) e mensurada pelas estações, em escala temporal mensal, para o período de 2007 a 2018. (A) Arcoverde, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Petrolina.....	61
Figura 7 - Precipitação estimada pelo SM2RAIN-CCI e mensurada pelas estações, em escala temporal mensal, para o período de 1998 a 2015. (A) Arcoverde, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Petrolina.	62
Figura 8 - Comparação dos dados de precipitação das estações pluviométricas com os do algoritmo SM2RAIN (GPM e ASCAT), em escala anual. (A) Arcoverde, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Petrolina.....	64
Figura 9 - Comparação dos dados de precipitação das estações pluviométricas com o do algoritmo SM2RAIN-CCI em escala anual. (A) Arcoverde, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Petrolina.....	66
Figura 10 - Precipitação anual média acumulada obtida a partir do SM2RAIN-GPM para o Estado de Pernambuco.....	69
Figura 11 - Precipitação anual média acumulada obtida a partir do SM2RAIN-ASCAT para o Estado de Pernambuco.....	70
Figura 12 - Precipitação anual média acumulada obtida a partir do SM2RAIN-CCI para o Estado de Pernambuco.....	71
Figura 13. Precipitação acumulada mensal obtida a partir do SM2RAIN-GPM para o Estado de Pernambuco.	72
Figura 14. Precipitação acumulada mensal obtida a partir do SM2RAIN-ASCAT para o Estado de Pernambuco.	73

Figura 15. Precipitação acumulada mensal obtida a partir do SM2RAIN-CCI para o Estado de Pernambuco.	74
Figura 16. Anomalias da precipitação obtidas pelo algoritmo SM2RAIN-GPM para o período de 2007 a 2018.	75
Figura 17. Anomalias da precipitação obtidas pelo algoritmo SM2RAIN-ASCAT para o período de 2007 a 2018.	76
Figura 18. Anomalias da precipitação obtidas pelo algoritmo SM2RAIN-CCI para o período de 1998 a 2015.	77
Figura 19. Distribuição espacial das estações de umidade do solo no Estado de Pernambuco.	84
Figura 20 - Mapa de solos para o Estado de Pernambuco realizado pelo ZAPE, com classificação dos solos adaptadas conforme a nomenclatura da EMBRAPA (2006).	85
Figura 21 - Comparação dos dados diários de umidade do solo medidos in situ e estimados por satélite (SMOS-BEC) para o período de julho de 2015 a abril de 2019.	98
Figura 22 - Diagramas de dispersão dos dados diários de umidade do solo, estimados por sensoriamento remoto e obtidos in situ.	99
Figura 23 - Comparação dos dados mensais de umidade do solo medidos in situ e estimados por satélite (SMOS-L4) para o período de julho de 2015 a abril de 2019.	101
Figura 24. Variação semanal dos índices SWDI e AWD em algumas estações do Estado de Pernambuco	105
Figura 25. Coeficientes de correlação entre os índices SWDI e AWD em algumas estações do Estado de Pernambuco.	106
Figura 26. Variação mensal do SWDI e os índices SMCI, VCI e TCI para o estado de Pernambuco.	108
Figura 27. SWDI trimestral para o Estado de Pernambuco durante o período de julho de 2015 a junho de 2019.	110
Figura 28. VCI trimestral para o Estado de Pernambuco durante o período de julho de 2015 a junho de 2019.	112
Figura 29. TCI trimestral para o Estado de Pernambuco durante o período de julho de 2015 a junho de 2019.	114
Figura 30. SMCI trimestral para o Estado de Pernambuco durante o período de julho de 2015 a junho de 2019.	116
Figura 31 - Mapa de localização da bacia hidrográfica do rio Pajeú.	123

Figura 32. Configuração espacial da rede pluviométrica da bacia hidrográfica do rio Pajeú.	124
Figura 33. Mapa de uso e cobertura do solo da Bacia Hidrográfica do rio Pajeú.	125
Figura 34. Mapa pedológico da Bacia Hidrográfica do rio Pajeú	126
Figura 35. Correção de bias pelo método Linear Scaling para precipitação (obs = dados históricos observados (1961-2005); raw = dados históricos brutos (1961-2005); LS = dados históricos corrigidos (1961-2005) pelo método de escala linear).....	136
Figura 36. Correção de bias pelo método Linear Scaling para precipitação (obs = dados históricos observados (1961-2005); raw = dados históricos brutos (1961-2005); LS = dados históricos corrigidos (1961-2005) pelo método de escala linear).....	137
Figura 37. Comportamento do SPI6 e do SPI12 para a bacia hidrográfica do rio Pajeú simulados pelos modelos Eta-BESM e Eta-MIROC5 e os dados observados para o tempo presente (1961 – 2019).	140
Figura 38. Projeções do SPI referentes aos períodos de 6 e 12 meses para a bacia hidrográfica do rio Pajeú simulados pelo modelo Eta-BESM na forçante 4.5 e 8.5.....	142
Figura 39. Projeções do SPI referentes aos períodos de 6 e 12 meses para a bacia hidrográfica do rio Pajeú simulados pelo modelo Eta-MIROC5 na forçante 4.5 e 8.5.	144
Figura 40. Comportamento de futuras secas baseado no SPEI-12 obtido pelos modelos climáticos na Bacia Hidrográfica do Rio Pajeú.....	145
Figura 41. Projeções do SPEI referentes aos períodos de 6 e 12 meses para a bacia hidrográfica do rio Pajeú simulados pelo modelo Eta-BESM na forçante 4.5 e 8.5.....	147
Figura 42. Projeções do SPEI referentes aos períodos de 6 e 12 meses para a bacia hidrográfica do rio Pajeú simulados pelo modelo Eta-MIROC5 na forçante 4.5 e 8.5.	148
Figura 43. Comportamento de futuras secas baseado no SPEI-12 obtido pelos modelos climáticos na Bacia Hidrográfica do Rio Pajeú.....	150
Figura 44. Comparação dos dados diários de umidade do solo medidos in situ e estimados pelo modelo SWAT (SM-SWAT) para o período de julho de 2015 a julho de 2017, nas estações de (A) Iguaraci, (B) Itacuruba, (C) Mirandiba, (D) São José do Egito e (E) Tuparetama.	152
Figura 45. Projeções do SSMI referentes aos períodos de 6 e 12 meses para a bacia hidrográfica do rio Pajeú simulados pelo modelo Eta-BESM na forçante 4.5 e 8.5.....	154
Figura 46. Projeções do SSMI referentes aos períodos de 6 e 12 meses para a bacia hidrográfica do rio Pajeú simulados pelo modelo Eta-MIROC5 na forçante 4.5 e 8.5.	155
Figura 47. Comportamento de futuras secas baseado no SSMI-12 obtido pelos modelos climáticos na Bacia Hidrográfica do Rio Pajeú.....	156

LISTA DE TABELAS

Tabela 1. Instrumentos de sensoriamento remoto e plataformas de satélite (passadas e atuais) para observação global da umidade do solo.	29
Tabela 2. Índices estatísticos utilizados para avaliação do desempenho do SM2RAIN-GPM em escala temporal mensal e anual.	67
Tabela 3. Índices estatísticos utilizados para avaliação do desempenho do SM2RAIN-ASCAT em escala temporal mensal e anual.....	67
Tabela 4. Índices estatísticos utilizados para avaliação do desempenho do SM2RAIN-CCI em escala temporal mensal e anual.	67
Tabela 5. Valores estatísticos da avaliação dos dados estimados pelo SMOS-BEC em Pernambuco, em base diária e mensal.	103
Tabela 6. Distribuição das estações meteorológicas utilizadas na pesquisa.....	124
Tabela 7. Classificação dos períodos secos e chuvosos do SPI segundo Mckee, Doesken, Kleist (1993).....	133
Tabela 8. Precipitação e temperatura do Eta-MIROC5 para os três tempos futuros períodos sob os RCPs.....	138
Tabela 9. Precipitação e temperatura do Eta-BESM para os três tempos futuros períodos sob os RCPs.....	138

LISTA DE ABREVIATURAS E SIGLAS

AMSR-E	<i>Advanced Microwave Scanning Radiometer - Earth Observing System</i>
APAC	Agência Pernambucana de Águas e Clima
AR5	Quinto Relatório de Avaliação
ASAR	<i>Advanced Synthetic Aperture Radar</i>
ASCAT	<i>Advanced Scatterometer</i>
AWD	<i>Atmospheric Water Deficit</i>
BEC	<i>Barcelona Expert Center</i>
BESM	Modelo Brasileiro do Sistema Terrestre
CAD	Capacidade de água disponível
CC	Coefficiente de Correlação
CCI	<i>Climate Change Initiative</i>
CEMADEN	Centro Nacional de Monitoramento e Alertas de Desastres Naturais
CMAP	<i>CPC Merged Analyses of Precipitation</i>
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
DEM	Modelo Digital de Elevação
EASE	<i>Equal Area Scalable Earth grid</i>
EM	Erro Médio
EMA	Erro Médio Absoluto
ESA	<i>European Space Agency</i>
ET	Evapotranspiração
GEE	Gases do Efeito Estufa
GPM	<i>Global Precipitation Measurement</i>
GPCP	<i>Global Precipitation Climatology Project</i>
IIASA	<i>International Institute for Applied Systems Analysis</i>
IQD	Inverso do Quadrado da Distância
IMERG	<i>Integrated Multi-satellite Retrievals for GPM</i>
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais
IPCC	Painel Intergovernamental sobre Mudanças Climáticas
IR	Infravermelho

LAT	Latitude
LIS	<i>Lightning Imaging Sensor</i>
LON	Longitude
LS	Linear Scaling
LST	Temperatura de Superfície do Solo
MDR	Taxa de Perda de Detecção
MIRAS	<i>Microwave Imaging Radiometer using Aperture Synthesis</i>
MIROC	<i>Model for interdisciplinary Research on Climate</i>
MODIS	<i>Moderate-Resolution Imaging Spectroradiometer</i>
MCGs	Modelos Climáticos Globais
MCRs	Modelos Climáticos Regionais
MXTP	Temperatura máxima do ar a 2m da superfície
MNTP	Temperatura mínima do ar a 2m da superfície
NASA	<i>National Aeronautics and Space Administration</i>
NCP	Normais Climatológicas Provisórias
NDVI	Índice de Vegetação por Diferença Normalizada
NEB	Nordeste Brasileiro
OMM	Organização Meteorológica Mundial
PREC	Precipitação
PERSIANN	<i>Remotely Sensed Information using Artificial Neural Networks</i>
PCD	Plataforma de Coleta de Dados
PDSI	Índice de Severidade da Seca de Palmer
R²	Coefficiente de Determinação
RB	Bias Relativo
RCP	Caminhos Representativos de Concentração
REQM	Raiz do Erro Quadrático Médio
RMSD	Desvio da Raiz Quadrada Média
RMSE	Raiz do Erro Quadrático Médio
RT	<i>Real Time</i>
SEBAL	<i>Surface Energy Balance Algorithm for Land</i>
SM	<i>Soil Moisture</i>
SMI	Índice de Umidade do Solo
SMAP	<i>Soil Moisture Active and Passive</i>
SSMI	Standardized Soil Moisture Index
SMCI	Índice de Condição de Umidade do Solo

SMOS	<i>Soil Moisture and Ocean Salinity</i>
SPEI	Índice Padronizado de Evapotranspiração
SPI	Índice de Precipitação Padronizada
SRTM	Missão Topográfica Radar Shuttle
SUPer	Unidades de resposta hidrológica para Pernambuco
SWAT	<i>Soil and Water Assessment Tool</i>
SWDI	<i>Soil Water Deficit Index</i>
TCI	Índice de Condição de Temperatura
TIROS-1	<i>Television InfraRed Observating Satellite</i>
TMI	<i>TRMM Microwave Imager</i>
TMPA	<i>Multisatellite Precipitation Analysis</i>
TRMM	<i>Tropical Rainfall Measuring Mission</i>
VCI	Índice de Condição de Vegetação
ubRMSD	Desvio da Raiz Quadrada Média não-tendenciosa
VIRS	<i>Visible Infrared Scanner</i>

Sumário

INTRODUÇÃO GERAL	19
HIPÓTESES	21
OBJETIVOS	21
Geral:	21
Específicos:	21
CAPÍTULO I: REVISÃO BIBLIOGRÁFICA	22
1.1 RECURSOS HÍDRICOS	23
1.2 PRECIPITAÇÃO PLUVIOMÉTRICA NA REGIÃO SEMIÁRIDA	25
1.3 UMIDADE DO SOLO EM REGIÕES SEMIÁRIDAS	26
1.4 SENSORIAMENTO REMOTO APLICADO AO MONITORAMENTO DA PRECIPITAÇÃO PLUVIOMÉTRICA E DA UMIDADE DO SOLO	28
1.5 O ALGORITMO SM2RAIN	31
1.6 A SECA NO NORDESTE E NO ESTADO DE PERNAMBUCO	34
1.6.1 Índices de secas	36
1.7 MUDANÇAS CLIMÁTICAS	38
1.7.1 Modelos climáticos globais e regionais	40
1.7.2 Cenários do IPCC	41
1.8 MODELAGEM HIDROLÓGICA	43
CAPÍTULO II: VALIDAÇÃO DE PRODUTOS DERIVADOS DO ALGORITMO SM2RAIN NO ESTADO DE PERNAMBUCO PARA MONITORAMENTO DA SECA	45
1. INTRODUÇÃO	48
2. MATERIAL E MÉTODOS	50
2.1 Área de estudo	50
2.2. Base de dados	51
2.2.1 Dados <i>in situ</i>:	51
2.2.2 Dados do algoritmo SM2RAIN	51
2.3 Validação dos dados	52
2.4 Índices estatísticos	54
2.4.1 Coeficiente de correlação de Pearson (CC):	54
2.4.2 Raiz do erro quadrático médio (RMSE):	54
2.4.3 Bias relativo (RB):	55
2.5 Anomalia de precipitação	55
3. RESULTADOS E DISCUSSÃO	55
4. CONCLUSÕES	78

1. INTRODUÇÃO	82
2. MATERIAL E MÉTODOS	83
2.1 Área de estudo	83
2.2 Dados da APAC	86
2.3 Dados do CEMADEN	86
2.4 Dados SMOS-L4	86
2.5 Validação dos dados	88
2.6 Índices estatísticos	89
2.6.1 Coeficiente de correlação de Pearson (CC):	89
2.6.2 O viés (bias):	89
2.6.3 Raiz do erro quadrático médio (RMSD):	90
2.6.4 Desvio da raiz quadrada média não-tendenciosa (ubRMSD):	90
2.7 Índices de seca	91
2.7.1 Soil Water Deficit Index (SWDI)	91
2.7.2 Atmospheric Water Deficit (AWD)	92
2.8 Correlação de Pearson do SWDI com outros índices de seca	93
2.8.1 Índice de Condição de Umidade do Solo (SMCI)	93
2.8.2 Índice de condição de vegetação (VCI)	94
2.8.3 Índice de condição de temperatura (TCI)	95
3. RESULTADOS E DISCUSSÃO	96
3.1 Avaliação e validação dos dados SMOS-L4 (1km) em Pernambuco	96
3.2 Correlação do índice SWDI com o AWD	103
3.3 Correlação dos índices de seca com o SWDI	107
4. CONCLUSÕES	117
CAPÍTULO IV: MODELAGEM DOS IMPACTOS DAS MUDANÇAS CLIMÁTICAS NA BACIA HIDROGRÁFICA DO RIO PAJEÚ	118
1. INTRODUÇÃO	121
2. MATERIAL E MÉTODOS	123
2.1 Área de estudo	123
2.2 O modelo SWAT	126
2.3 Calibração e validação do modelo hidrológico	127
2.4 Projeções climáticas	129
2.5 Correção de tendência	130
2.6 Índice de Precipitação Padronizada – SPI	131
2.7 Índice de Evapotranspiração de Precipitação Padronizada (SPEI)	133
2.8 Índice de Umidade do Solo Padronizado – (SSMI)	135

3. RESULTADOS E DISCUSSÃO.....	135
3.1 Correção de tendência pelo método Linear Scaling.....	135
3.2 SPI Dados observados.....	139
3.3 Projeção do comportamento do SPI na Bacia Hidrográfica do Pajeú ao longo do século XXI.....	141
3.3.1. Análise das projeções segundo o modelo Eta-BESM.....	141
3.3.2 Análise das projeções segundo o modelo Eta-MIROC5.....	142
3.4 Projeção do comportamento do SPEI na bacia hidrográfica do rio Pajeú ao longo do século XXI.....	145
3.4.1 Análise das projeções segundo o modelo Eta-BESM.....	145
3.4.2 Análise das projeções segundo o modelo Eta-MIROC5.....	147
3.5 Validação dos dados de umidade de solo gerados pelo SWAT.....	150
3.6 Projeção do comportamento do SSMI na bacia hidrográfica do rio Pajeú ao longo do século XXI.....	152
3.6.1 Análise das projeções segundo o modelo Eta-BESM.....	153
3.6.2 Análise das projeções segundo o modelo Eta-MIROC5.....	154
4. CONCLUSÃO.....	157
5. REFERÊNCIAS BIBLIOGRÁFICAS.....	158

INTRODUÇÃO GERAL

As regiões subúmidas secas, áridas e semiáridas sofrem com as irregularidades das precipitações pluviométricas, trazendo uma série de consequências negativas de cunho ambiental, social e econômico, podendo afetar atividades como o abastecimento público, a produção de alimentos, a economia da região e com isso impactar o meio ambiente (BURITI e BARBOSA, 2018; FAO, 2018; IPCC, 2008; IPCC, 2017; NÚÑEZ COBO e VERBIST, 2018; RIBEIRO NETO et al., 2014).

A região mais afetada pelas secas no Brasil corresponde à região semiárida situada principalmente no Nordeste Brasileiro (NEB), por possuir os maiores déficits hídricos do país e apresentar chuvas abaixo de 800 mm por ano, região ciclicamente submetida à ocorrência de secas, dispõe apenas de 4% dos recursos hídricos do país e é habitado por 35% da população brasileira (CIRILO, 2015; MARENGO, 2008).

Desde 2012, a região semiárida do Nordeste do Brasil tem sido afetada pela seca, abrangendo uma área de cerca de 1 milhão de km². No final de 2017, a precipitação ainda estava abaixo da média histórica. A avaliação desse fenômeno mostrou que foi a seca mais extrema e mais longa já registrada na área (ALVALÁ et al., 2019; MARENGO et al., 2017). O Estado de Pernambuco possui 80% do seu território inserido no semiárido, com precipitação irregular associada a eventos de seca recorrentes e persistentes (SOUZA et al., 2018).

Diante da problemática supracitada, torna-se importante o uso de tecnologias combinadas para subsidiar entidades envolvidas na gestão hídrica na tomada de decisões. Na gestão de recursos hídricos, as aplicações são as mais variadas, desde a estimativa de dados de precipitação, umidade do solo, escoamento e vazão até a recriação e previsão de cenários de seca e os impactos decorrentes de sua persistência (HAJJ et al., 2018; SOUZA et al., 2018; TAO et al., 2016; ZHANG et al., 2019).

As áreas mais extensas ou com deficiência de redes de monitoramento requerem técnicas sofisticadas para computar os processos que atuam no balanço hídrico, como o uso de dados orbitais, através do sensoriamento remoto (LOUZADA, XAVIER e PEZZOPANE, 2018; ZHANG et al., 2019).

O sensoriamento remoto tem o potencial reconhecido para a estimativa dos aspectos espaciais e temporais das condições de seca em todo o globo (JOHNSON et al., 1993; PETERS et al., 2002). Aliado a essa técnica, vários índices têm sido desenvolvidos para a avaliação e quantificação da seca em períodos históricos e futuros, considerando diferentes variáveis de

causa e resposta, tais como precipitação, umidade do solo e condição da vegetação (PALMER, 1965, 1968; GIBBS e MAHER, 1967; SHAFER e DEZMAN, 1982; KOGAN, 1990, 2002; MCKEE et al., 1993; KEYANTASH e DRACUP, 2004, BHUIYAN et al., 2006, ABBAS et al., 2014).

Segundo os autores, Mishra e Singh 2010 e Sehgal et al. (2017), a avaliação do futuro a incidência de secas é fundamental para a gestão e planejamento dos recursos hídricos, e isso requer investigação de secas históricas e seus impactos. Os cenários futuros podem ser simulados através de Modelos de Circulação Geral (MCG's) e os Modelos Climáticos Regionais (MCR's), os quais são aninhados aos MCG'S para promover o refinamento da escala. Estes podem alimentar modelos hidrológicos, uma vez calibrados e validados, permitindo avaliar os impactos sobre os recursos hídricos em diversas escalas, inclusive em bacias hidrográficas.

Todas as tecnologias e ferramentas devem ser utilizadas para contribuir em uma melhor gestão dos recursos hídricos, principalmente em regiões onde as secas são os maiores desafios, devido a sua constância, causando grandes dificuldades de acesso à água, até mesmo para consumo humano. Por isso, a adoção dessas técnicas possibilita compreender melhor os processos que interferem na qualidade e disponibilidade dos recursos hídricos, espacial e temporalmente, assim, podendo ganhar cada vez mais notoriedade e atenção.

HIPÓTESES

- I. Dados de sensores orbitais de umidade do solo e precipitação são capazes de gerar índices que estimam com maior precisão o impacto da seca no Estado de Pernambuco.

- II. Com modelo climático e hidrológico em diferentes cenários de projeção é possível analisar os prováveis eventos de seca até o final do século XXI, na bacia hidrográfica do rio Pajeú.

OBJETIVOS

Geral:

Estimar e avaliar a seca no Estado de Pernambuco, por meio de dados de sensores remotos, modelos climáticos e modelo hidrológico.

Específicos:

- Validar dados de precipitação pluviométrica obtida pelo algoritmo no Estado de Pernambuco;
- Validar os dados de umidade do solo obtido por sensoriamento remoto utilizando dados em campo para o Estado de Pernambuco;
- Calcular índice de seca a partir dos dados previamente validados em Pernambuco;
- Analisar o comportamento espaço-temporal de futuros eventos de seca, utilizando os índices (SPI, SPEI, SSMI), na Bacia Hidrográfica do rio Pajeú até o final do século XXI, projetados por dois modelos climáticos e o modelo hidrológico SWAT, utilizando dois cenários de emissão de gases do efeito estufa.

CAPÍTULO I: REVISÃO BIBLIOGRÁFICA

1.1 RECURSOS HÍDRICOS

A água é uma substância essencial para a natureza terrestre em sua base mais fundamental, sendo, dos pontos de vista químico, físico e biológico, o principal constituinte de toda a vida orgânica do planeta. Para as sociedades humanas, além de ser este elemento vital, a água também é um importante componente social, político e econômico e, enquanto recurso utilizável, trata-se de um fator estratégico, finito em sua capacidade de uso e aproveitamento: indispensável para o ambiente rural, é em torno de fontes confiáveis de água que as cidades são constituídas (TRINDADE e SCHEIBE, 2019).

Os recursos hídricos são as águas superficiais ou subterrâneas disponíveis para qualquer tipo de uso em uma determinada região ou bacia hidrográfica (SOUZA et al., 2012). Silva (2003) considera que “os recursos hídricos são facilmente comprometidos, sejam no âmbito da qualidade e/ou quantidade, sejam por características como alteração de cursos d’água ou diminuição dos canais de drenagem, tornando o atual cenário de degradação e descaso preocupante”.

Um dos principais problemas ambientais deste século é o esgotamento de recursos hídricos em diferentes partes do mundo (JALE et al., 2019). A edição de 2018 do Relatório do Desenvolvimento Mundial da Água das Nações Unidas afirmou que quase 6 bilhões de pessoas sofrerão com a escassez de água limpa até 2050. Este é o resultado do aumento da demanda por água, redução dos recursos hídricos e aumento da poluição na água (BORETTI e ROSA, 2019). Prevê-se que os recursos hídricos superficiais disponíveis permaneçam quase constantes a nível continental, embora a qualidade se deteriore e a distribuição espacial e temporal mude. Mas provavelmente, haverá uma redução nos aquíferos e a intrusão de sal nas áreas costeiras será muito dramática (WADA et al., 2016).

No Brasil, um total de 47% do ambiente urbano é abastecido exclusivamente com água de superfície, 39% com água subterrânea e 14% de ambas fontes. Embora, no país, haja uma privilegiada quantidade de recursos hídricos, tanto superficiais quanto subterrâneos, os problemas inerentes à qualidade, distribuição e oferta hídrica são diversos e distintos entre as suas regiões (BASTOS et al., 2018). Enquanto algumas regiões sofrem com a falta d’água, como o Nordeste, outras a possuem em abundância, como o Norte e Centro Oeste. As regiões Sul e Sudeste sofrem com conflitos referentes ao uso, como consequência de seu tamanho populacional e alto grau de desenvolvimento (LOPES et al., 2008).

Vale ressaltar que 68,5% dos recursos hídricos estão localizados na região Norte, na qual habitam apenas cerca de 7% da população brasileira. Por outro lado, a Região Sudeste apresenta apenas de 6% da disponibilidade hídrica e é a mais populosa, com 43% da população nacional; e a região Nordeste com 3% da água e 29% da população (ROMERO e BRUNA, 2004; LOPES e NEVES, 2017).

O Nordeste semiárido é uma região desprovida em volume de escoamento de água dos rios. Essa situação pode ser explicada em razão da variabilidade temporal das precipitações e das características geológicas dominantes, onde há predominância de solos rasos baseados sobre rochas cristalinas e conseqüentemente baixas trocas de água entre o rio e o solo adjacente. O resultado é a existência de densa rede de rios temporários (CIRILO, 2008).

Agregando-se as potencialidades superficiais e subterrâneas, diversos estudos, a partir do PLIRHINE (SUDENE, 1980), atualizados pelo Projeto Áridas (1994) e agrupados por (REBOUÇAS, 1997, p.144), apresentam indicadores potenciais de quantidade de água por habitante por ano. Esses indicadores expõem regiões particularmente críticas como Leste da Paraíba (1.030 m³/hab/ano), Leste Potiguar (997 m³/hab/ano), Fortaleza (846 m³/hab/ano) e Leste de Pernambuco (819 m³/hab/ano). O parâmetro estabelecido pela ONU é de 1.500 m³/hab/ano como a quantidade potencial de água mínima para o bem-estar e desenvolvimento de qualquer região.

Diante da problemática, fica claro que um planejamento eficaz na utilização dos recursos hídricos e mais estudos sobre tema são cruciais para alcançar o desenvolvimento sustentável, pois a água não é um recurso natural infinito. Santos Neto et al. (2014) afirmam que entender o comportamento da precipitação serve como alternativa para solucionar diversos problemas no planejamento dos recursos hídricos e planejamento urbano, além de prevenir catástrofes e condicionar o cotidiano da população local.

Segundo Radha e Sudhakaran (2015), o estudo da precipitação pluviométrica torna-se fundamental no planejamento de atividades agrícolas, na gestão de recursos hídricos, e em estudos climatológicos, quando analisados os volumes precipitados e a respectiva distribuição conjugada no tempo e no espaço. Para Liang, Wang e Zhang (2018) a análise estatística de propriedades inerentes à precipitação desempenha papel decisivo não apenas nas avaliações de secas e cheias, mas também no manejo e gerenciamento dos recursos hídricos.

1.2 PRECIPITAÇÃO PLUVIOMÉTRICA NA REGIÃO SEMIÁRIDA

A precipitação pluviométrica é a principal forma de entrada de água em um sistema natural, participando do ciclo hidrológico global, o qual é representado pelo fluxo de água entre a superfície e a atmosfera impulsionado pela radiação solar, gravidade e rotação terrestre (TUCCI, 2012; UCHIYAMA et al., 2018). Este atributo climático exerce influência sobre as condições ambientais, como também aos mais diversos setores da sociedade, afetando assim a economia e o meio ambiente (SILVA et al., 2007). Além disso, é um dos principais elementos meteorológicos objetos de estudo por pesquisadores que trabalham com mudança climática (SOUZA et al., 2018).

O conhecimento da distribuição e variabilidade da precipitação é de suma importância para aprimorar o conhecimento sobre os mecanismos dinâmicos e termodinâmicos associados com os sistemas atmosféricos locais, de meso e grande escala que atingem uma região (JESUS et al., 2013). Mudanças na precipitação têm implicações sobre o ciclo hidrológico e recursos hídricos. Espera-se que as mudanças climáticas alterem a média da temperatura e os valores de precipitação, e conseqüentemente a variabilidade dos eventos de chuva, que podem causar inundações e ainda mais secas severas e frequentes (GUIMARÃES et al., 2016; MARENGO et al., 2017, 2018).

Silva et al. (2017) destacam a necessidade do monitoramento do regime pluviométrico, pois é útil devido (à) vários aspectos: existência de diversos projetos de irrigação implantados em funcionamento e futuros; abastecimento d'água para grandes, médias e pequenas cidades que em sua maioria, dependem diretamente dos níveis dos rios ou de forma indireta, do volume acumulado das barragens distribuídas no Nordeste; diversas culturas agrícolas dependentes exclusivamente da regularidade das chuvas.

A variação das chuvas e sua irregularidade espaço-temporal ao longo dos anos são bem notórias na região semiárida do Nordeste (MARRA e MORIN, 2018). Marengo (2008) destaca que esta região sofre constantemente com os efeitos do comportamento variável das chuvas no espaço e no tempo. Em intervalos de anos, e até mesmo décadas, ciclos de fortes estiagens e secas costumam atingir a região, além de ser frequente, a ocorrência de veranicos durante a estação chuvosa que, dependendo da intensidade e duração, provocam fortes danos às culturas de subsistência. A principal característica da região se deve à precipitação média anual variar

entre 400 e 800 mm; possuir temperaturas acima de 23 °C, e evapotranspiração acima de 2000 mm/ano (MOSCATI e GAN, 2007).

Pereira (2014) verificou que no semiárido brasileiro há alguns núcleos com tendência negativa distribuídos nos estados de Pernambuco, Paraíba, Ceará e Bahia, onde a precipitação variou de 1 a 5 mm/ano. Tais tendências, de modo geral, podem significar aumento dos períodos sem chuvas ao longo dos anos, tanto no período chuvoso quanto no período menos chuvoso, o que foi observado também no estudo do autor.

Existem diversas maneiras de medir a precipitação em uma determinada área. As formas mais conhecidas e utilizadas são através de aparelhos denominados de pluviômetros ou pluviógrafos, bem como os radares e medições através de imagens de satélites (LI et al., 2017). No entanto, a falta de conjunto de dados observacionais de precipitação de longo prazo e concomitante consistentes, é o grande desafio para o estudo detalhado e o monitoramento do padrão de chuva na região. Ademais, as incertezas sobre as medidas observacionais afetam diretamente na avaliação dos dados de precipitação (MARENGO, 2012).

Como alternativa, conjuntos de dados podem ser utilizados no estudo da variabilidade espaço-temporal da precipitação de uma região extensa como o Nordeste brasileiro: i) obtidos por sensoriamento remoto e ii) oriundos de simulação numérica por modelos de previsão de tempo ou de clima (FASULLO, 2012; LIMBERGER e SILVA, 2018).

Assim como a precipitação, outra variável que compõem o ciclo hidrológico, e que tem sido bastante explorada em estudos no semiárido brasileiro é a umidade do solo. Segundo Ochsner (2013), a umidade do solo controla as trocas de água e energia entre os principais compartimentos ambientais (atmosfera e terra) e processos hidrológicos, como precipitação, evaporação, infiltração e escoamento.

1.3 UMIDADE DO SOLO EM REGIÕES SEMIÁRIDAS

O teor de água do solo é um componente vital no ciclo hidrológico, com forte efeito na dinâmica do carbono, água e energia em uma interface superfície-atmosfera. Este é um fator determinante nos padrões de distribuição e crescimento de plantas em ambientes áridos e semiáridos (GALLEGO-ELVIRA et al., 2016; HE et al., 2017; JIA et al., 2017; NEVES et al., 2017; ZHANG et al., 2016; ZHANG e SHANGGUAN, 2016).

A umidade do solo relaciona-se à água presente na parte superficial do solo. Sua importância consiste, indubitavelmente, pelo fato de controlar a troca de água e energia entre a superfície e a atmosfera, ou seja, governa a divisão destes fluxos de massa e energia desempenhando assim um papel fundamental na avaliação dos diferentes componentes do balanço hídrico e energético (BROCCA et al., 2017; ROMANO, 2014; VEREECKEN et al., 2014).

Essa variável constitui um dos principais fatores para o estudo onde há déficit hídrico no solo, principalmente para regiões semiáridas (ROSSATO et al., 2017). Segundo Monte-Mor (2012) é comum em regiões semiáridas, a presença de vegetação escassa, crostas no solo e variações sutis de textura, que alteram significativamente os padrões de distribuição espacial do conteúdo de água. Para Wu et al. (2016), a compreensão adequada da variabilidade espaço-temporal da umidade do solo é essencial, principalmente em regiões agrícolas áridas e semiáridas, onde geralmente são necessárias irrigações regulares, pois os recursos hídricos são bastante limitados e mal distribuídos.

Cosh et al. (2018) afirmam que estudos voltados à dinâmica temporal da umidade do solo em regiões áridas e semiáridas ainda são pouco realizados e, quando ocorrem, são de curta duração e não consideram uma grande rede de monitoramento. Esses estudos precisam ser mais concentrados nesse tipo de região, especialmente em bacias hidrográficas, considerando que o conteúdo de água tende a ser reduzido e fortemente afetado pela sazonalidade das precipitações.

As medições de umidade do solo feitas em diferentes escalas espaciais e temporais são cada vez mais necessárias em uma ampla gama de aplicações ambientais, que incluem a previsão do rendimento da safra (HOLZMAN et al., 2014), planejamento de irrigação, ocorrência de inundações e secas (KORICHE e RIENTJE, 2016) e previsão do tempo (DILLON et al., 2016).

As técnicas de medidas da umidade do solo (gravimétricas, tensiométricas e higrométricas) são pontuais e não consideram a variabilidade espacial e temporal típica deste parâmetro (MAFFRA e CENTENO, 2016). Para contornar essas dificuldades, o sensoriamento remoto aparece como uma alternativa para o monitoramento rotineiro da umidade do solo em grandes escalas e de forma contínua (WANG e QU, 2009). Segundo De Jeu (2003) a umidade do solo derivada por satélite é uma poderosa ferramenta para a detecção do conteúdo de água no solo em regiões semiáridas, bem como para diversas aplicações envolvendo os processos entre a superfície e a atmosfera.

1.4 SENSORIAMENTO REMOTO APLICADO AO MONITORAMENTO DA PRECIPITAÇÃO PLUVIOMÉTRICA E DA UMIDADE DO SOLO

O sensoriamento remoto é a ciência que permite a coleta de informações de uma região sem a necessidade de contato físico. Devido as novas tecnologias eletrônicas e de computação, é possível o uso de sensores a bordo de satélites orbitando o planeta que periodicamente coletam imagens da superfície terrestre (ALLEN et al., 2002; BASTIAANSEN et al., 1998a; BASTIAANSEN et al., 1998b; BASTIAANSEN, 2000; MOREIRA e VALERIANO, 2014). Menezes e Almeida (2012) caracterizam o termo sensoriamento remoto como “a ciência que visa o desenvolvimento da obtenção de imagens da superfície terrestre por meio da detecção e medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres”.

As interações da radiação eletromagnética com a superfície da Terra podem fornecer informações não apenas sobre a distância entre o sensor e o objeto, todavia também sobre a direção, intensidade, comprimento de onda e polarização da radiação eletromagnética. Essas medições podem oferecer informações posicionais sobre os objetos e dados a respeito das características dos materiais da superfície (ZHU et al., 2017).

A evolução do sensoriamento remoto é marcada por sensores cada vez mais confiáveis e temáticos. Existem sensores operando em diferentes regiões do espectro eletromagnético e dependendo do tipo, o sensor capta dados de uma ou mais faixas do espectro. Assim, é possível obter dados de energia invisível ao olho humano. Os comprimentos de onda comumente usados em radares operam na região das micro-ondas, que são maiores que as do visível e dos infravermelhos (JENSEN, 2009).

Para um estudo específico, como monitoramento da precipitação e umidade do solo, por exemplo, é necessário um conjunto diferenciado de sensores com a habilidade de ‘visualizar’ além da camada difusa de gases que compõem a atmosfera. Ademais, esses sensores devem ser capazes, no caso da umidade do solo, de ultrapassar as barreiras de nuvens e vegetação, com a habilidade de detectar a radiação eletromagnética refletida pelo solo. Esses sensores operam também na faixa espectral de micro-ondas, com comprimento de onda variando de 0,5 a 100 cm (BITTELLI, 2011; JOSHI et al., 2016). O sensoriamento remoto por micro-ondas foi identificado como o mais adequado para a detecção da umidade do solo com base no contraste entre as propriedades dielétricas da água líquida e do material do solo (DE JEU, 2003; GONZÁLEZ-ZAMORA et al., 2015; ROSSATO, 2011).

Os sensores desse grupo podem ser divididos em ativos (radares) e passivos (radiômetros). Os radares transmitem uma onda eletromagnética e mensura a energia refletida que retorna ao sensor, já os radiômetros detectam a radiação emitida pela superfície da Terra (BITTELLI, 2011). A principal vantagem dos radares é a altíssima resolução espacial, tendo como desvantagens a maior sensibilidade à rugosidade de superfície, dossel vegetal e baixa resolução temporal. Os radiômetros têm como vantagens a elevada precisão sobre solos descobertos e alta resolução temporal, sendo desfavorecidos pela resolução espacial mais baixa, influenciada pela cobertura vegetal e rugosidade de superfície (ZHANG e ZHOU, 2016).

Apenas para monitoramento da umidade do solo, existem diversos sensores que já foram lançados em missões encerradas e outros atualmente operacionais. Um resumo dos principais instrumentos pode ser verificado na Tabela 1.

Tabela 1. Instrumentos de sensoriamento remoto e plataformas de satélite (passadas e atuais) para observação global da umidade do solo.

Instrumento	Satélite	Frequência (GHz)	Banda	Resolução espacial	Resolução temporal (d)	Tipo de sensor
AMSR2	GCOM-W1	6,9-89	S, X	25-50 km	2	passivo
AMSR-E	Aqua	6,9-89	C, X	25-50 km	2	passivo
Aquarius	Aquarius	1,26	L (ativo)	76-156 km	7	ativo/passivo
		1,41	L (passivo)			
ASAR	ENVISAT	5,33	C	300-1000 m	5	ativo
ASCAT	MetOp	5,25	C	25-50 km	2	ativo
MIRAS	SMOS	1,4	L	25-60 km	3	passivo
NISAR	NISAR		L e S	0,1-50 km	12-16	ativo
PALSAR	ALOS	1,27	L	10-100 m	46	ativo
RADARSAT-1 e 2		5,40	C	10 m	24	ativo
Tandem-L	Tandem-L	1,2	L	3-20 m	8	ativo
Sentinel-1A e 1B			C	5-20 m	6-12	ativo
SMAP	SMAP	1,41	L (passivo)	40 km (pas.)	2-3	ativo/passivo
		1,26	L (ativo)	3 km (ati.)	2-3	
SSM/I	SSM/I	19,35	K	13-69 km	0,5	Passivo
WindSAT	Coriolis 6.8-37		C, X e K	8-71 km	8	Passivo

Fonte: (MOHANTY et al., 2017).

Dentre as missões mais recentes, o Soil Moisture Ocean Salinity (SMOS) da Agência Espacial Europeia (ESA), tem ganho grande destaque em estudos de umidade do solo (MIALON et al. 2015; SCAINI et al., 2015). O sensor opera na banda L e sofre menos interferência da influência da vegetação e atmosfera em relação às bandas C e X e por isso, são ideais para recuperação da umidade do solo (JENSEN, 2009; KERR, 2007). Essa missão realizou campanhas para avaliar o produto obtido remotamente em comparação com dados *in situ* em diferentes climas, de modo a estudar os efeitos da seca (LOUVET et al., 2015; PANCIERA et al., 2014; VITTUCCI et al., 2013; VITTUCCI et al., 2016).

Assim como existem diversos satélites para o monitoramento de umidade do solo, também existe uma gama enorme deles para monitorar a precipitação pluviométrica. Iniciando

com o TIROS-1 (Television InfraRed Observating Satellite) sendo lançado em 1960. Poucos anos depois, em 1963, o WMO estabeleceu o programa World Weather Watch (observação do clima mundial) para coordenar a capacidade observacional da superfície terrestre por satélites. Destaca-se depois, o GPCP (Global Precipitation Climatology Project), que foi lançado em 1979 gerando dados mensais de precipitação em pixels de 2,5° (HUFFMAN et al., 2007).

O CMAP (CPC Merged Analyses of Precipitation) utilizou dados destes e de outros satélites para obter um produto mesclado que foi disponibilizado a partir de 1987 (XIE e ARKIN, 1997). Outros que também ganham destaque são o Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks (PERSIANN) (NGUYEN et al., 2018) e o Climate Hazard Group InfraRed Precipitation Satellite (CHIRPS) (BAI et al., 2018).

Houve então o surgimento do TRMM (Tropical Measurement Mission) em 1997, para melhorar o conhecimento da distribuição tridimensional da precipitação nos trópicos, uma vez que gera cobertura nessa região (NASA, 2019). O exemplo mais recente e bem-sucedido de estimativas de precipitação por satélite é representado pelas Recuperações Multi-Satélite Integradas para Medição de Precipitação Global (GPM) (IMERG) da missão GPM (HOU et al., 2014), que fornecem uma alta espacial (0,1°) e resolução temporal (30 minutos) e cobertura quase global ($\pm 60^\circ$). Para obter tal resolução e cobertura, os produtos IMERG usam uma constelação de sensores polares e geoestacionários de satélites operando nas bandas de micro-ondas e infravermelho.

No entanto, o uso de vários sensores gera alguns problemas, incluindo a inconsistência entre as estimativas de precipitação por diferentes sensores (problema de intercalibração), as dificuldades em coletar observações de várias agências espaciais (ou seja, um obstáculo na entrega dos produtos em tempo quase real), e o alto custos de operação e manutenção de toda a constelação. Além disso, como a abordagem “top-down” requer a fusão de medições instantâneas de chuva de vários sensores, a falha de um deles pode implicar em uma degradação significativa na precisão da estimativa de chuva acumulada devido à alta variabilidade temporal da chuva (TRENBERTH e ASRAR, 2014).

Nos últimos anos, surgiu uma nova abordagem "bottom-up" que usa observações de umidade do solo via satélite para inferir, ou corrigir, a precipitação sobre a Terra (BROCCA et al., 2013; CROW et al., 2009; PELLARIN et al., 2013; WANDERS et al., 2015). A principal diferença entre as abordagens “bottom-up” e “top-down” está no tipo de medição, ou seja, taxas

de precipitação acumulada com o método bottom-up e taxas de precipitação instantâneas com o método top-down. Essa diferença torna as duas abordagens altamente complementares e sua integração já foi testada e demonstrada com sucesso em vários estudos recentes (BROCCA et al., 2016; CIABATTA et al., 2017; CHIARAVALLOTTI et al., 2018; MASSARI et al., 2019).

Quando estimativas de precipitação acumulada são necessárias (por exemplo, precipitação diária), a abordagem bottom-up tem a vantagem de exigir um número muito menor de medições e, portanto, de sensores de satélite (BROCCA et al., 2014). Segundo o autor citado anteriormente, o SM2RAIN é a única técnica que fornece diretamente estimativas de chuva a partir de observações de umidade do solo, enquanto as outras são técnicas baseadas em correção.

1.5 O ALGORITMO SM2RAIN

Uma abordagem diferente foi recentemente proposta por Brocca et al. (2013) que usou dados de umidade do solo para obter uma estimativa direta da precipitação. Dessa forma, é realizada a “hidrologia backward”, conforme sugerido por Kirchner (2009), a precipitação é calculada a partir do conhecimento do estado de umidade do solo e sua variação no tempo por meio de um algoritmo denominado SM2RAIN.

O algoritmo é baseado na inversão da equação do balanço hídrico do solo para recuperar os dados chuva a partir de dados de umidade do solo. O solo funciona como um natural medidor, medindo a quantidade de chuva precipitada. Especificamente, a equação do balanço hídrico do solo pode ser descrita pela seguinte expressão (Figura 1):

$$n Z ds(t) / dt = p(t) - g(t) - r(t) - e(t) \quad (1)$$

onde n [-] é a porosidade do solo, Z [L] é a profundidade da camada do solo, $s(t)$ [-] é a saturação relativa do solo ou umidade relativa do solo, t [T] é o tempo e $p(t)$, $r(t)$, $e(t)$ e $g(t)$ [L / T] é a precipitação, escoamento superficial, evapotranspiração e drenagem (percolação profunda mais escoamento subsuperficial), respectivamente.

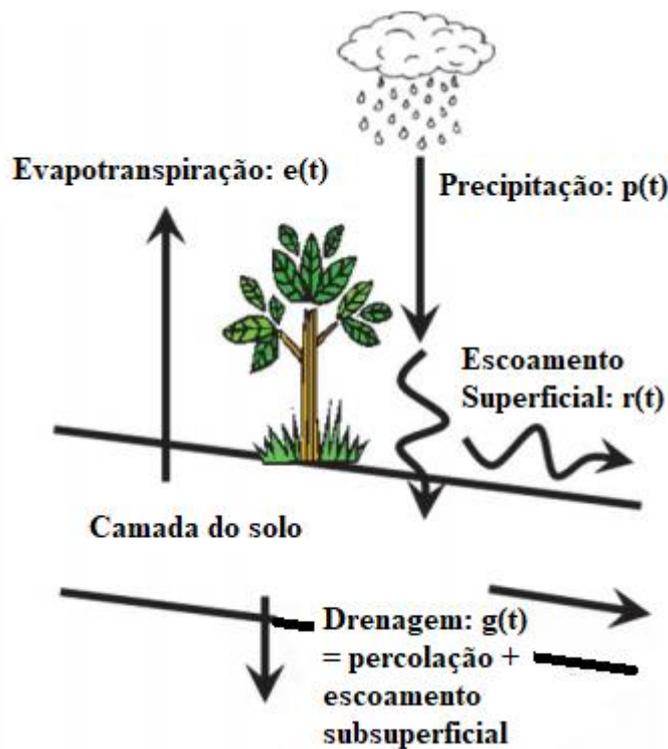


Figura 1 - Representação esquemática da equação do balanço hídrico do solo e fluxos usados no algoritmo SM2RAIN.

Por razões de simplicidade, a taxa de interceptação não é considerada na equação, pois seria necessário o uso de outra expressão para simular o teor de água do armazenamento de interceptação. Para a taxa de drenagem, a seguinte relação é adotada na Equação 2 (FAMIGLIETTI e WOOD, 1994):

$$g(t) = a s(t)^b \quad (2)$$

onde a (L/T) e b (-) são dois parâmetros que expressam a não linearidade entre a taxa de drenagem e a saturação do solo. Observe que $g(t)$ inclui a contribuição de percolação profunda e escoamento subsuperficial (fluxo interno mais fluxo de base). Basicamente, $g(t)$ representa as perdas laterais e descendentes de água da coluna de solo (Figura 1). A taxa de escoamento superficial é expressa na Equação 3 de acordo com Georgakakos e Baumer (1996):

$$r(t) = p(t) s(t)^c \quad (3)$$

onde c (-) é um parâmetro que assume valores maiores que unidade, com grandes valores representando um comportamento de limite altamente não linear. A taxa de evapotranspiração

(equação 4) é representada por uma relação linear dependendo da evapotranspiração potencial, $ET_{pot}(t)$ (BROCCA et al., 2014):

$$e(t) = ET_{pot}(t) s(t) \quad (4)$$

A evapotranspiração potencial (equação 5) é calculada através da relação empírica de Blaney e Criddle modificada por Doorenbos e Pruitt (1977):

$$ET_{pot}(t) = -2 + 1.26 [\xi (0.46 T_a (T) + 8.13)] \quad (5)$$

onde $T_a(t)$ (°C) é a temperatura do ar e ξ (-) é a porcentagem do total de horas diurnas para o período utilizado (diário ou mensal) fora do total de horas diurnas do ano (365×12). O rearranjo da Equação (1), integrando as Equações (2–4),

$$p(t) = \frac{\frac{Z^* ds(t)}{dt} + a s(t)^b + ET_{pot}(t) s(t)}{1 - s(t)^c} \quad (6)$$

onde Z^* representa a capacidade de água na camada do solo. Esta equação pode ser usada para estimar a taxa de precipitação, $p(t)$, uma vez que a umidade relativa do solo, $s(t)$, os quatro parâmetros (Z^* , a , b e c) e a taxa de evapotranspiração potencial, $ET_{pot}(t)$, são conhecidos. Valores negativos de precipitação, que podem ocorrer durante alguns ciclos, e são definidos como iguais a zero. O uso da equação 6, para estimar a precipitação tem algumas limitações que ocorrem quando o solo está saturado, também para solos altamente permeáveis, durante condições de neve e congelamento e para áreas densamente vegetadas.

Sempre que chover, a taxa de evaporação pode ser assumida com segurança como desprezível ($e(t) = 0$). Além disso, ao assumir que toda precipitação se infiltra no solo, a taxa de escoamento é zero ($r(t) = 0$). Para a taxa de drenagem, a seguinte relação pode ser adotada, $g(t) = as(t)^b$, onde $a[L/T]$ e $b[-]$ são dois parâmetros que expressam a não linearidade entre a taxa de drenagem e a saturação do solo. O rearranjo da Equação 1, com as premissas descritas, resulta em:

$$p(t) = Z \frac{ds(t)}{dt} + a s(t)^b \quad (7)$$

Esta equação pode ser usada para estimar a taxa de precipitação a partir do conhecimento de SM relativo, $s(t)$, suas flutuações no tempo, $ds(t)/dt$, e três parâmetros (Z , a e b) a serem estimados através da calibração. Mesmo que as suposições feitas para derivar a Equação 2 possam introduzir alguns erros, elas permitem a obtenção de um método simples (mas eficaz)

para a obtenção da precipitação de dados SM (BROCCA et al., 2013) que pode ser facilmente aplicado em uma escala global.

O algoritmo SM2RAIN foi aplicado com sucesso nas estimativas de precipitação de medições de umidade do solo *in situ* (BROCCA et al., 2013, 2015) e estimativas baseadas em satélites de umidade de solo como, Moisture Ocean Salinity Mission (SMOS) (BROCCA et al., 2014, 2016; TARPANELLI et al., 2017), Advanced Microwave Scanning Radiometer (AMSR) (BROCCA et al., 2014; TARPANELLI et al., 2017), Soil Moisture Active and Passive (SMAP) (KOSTER et al., 2016; TARPANELLI et al., 2017) e o Advanced SCATterometer (ASCAT) (BROCCA et al., 2014; CIABATTA et al., 2015, 2017; MASSARI et al., 2017; TARPANELLI et al., 2017).

Os dados de precipitação estimados pelo algoritmo SM2RAIN de diferentes satélites de umidade, torna-se uma alternativa para melhor entendimento do comportamento da variabilidade espaço-temporal da precipitação. Segundo Lu et al. (2018) e Wang et al. (2017), o monitoramento da precipitação permanece sendo um grande desafio, principalmente por causa da sua elevada variabilidade espacial e temporal, que não é corretamente registrada pelas estações de monitoramento em superfície. Para Santos et al. (2019), o conhecimento dessa variabilidade da precipitação é importante no contexto da gestão do risco de seca em regiões como o Nordeste do Brasil, que carece de dados observacionais de precipitação pluviométrica consistentes.

1.6 A SECA NO NORDESTE E NO ESTADO DE PERNAMBUCO

A seca é um fenômeno natural que acarreta impactos negativos sobre o meio ambiente, a economia e a sociedade com consequências diretas sobre a disponibilidade de água, energia, crescimento e desenvolvimento das regiões atingidas, assim como nos níveis de pobreza e saúde da população. Além disso, 44% das áreas agrícolas do mundo e cerca de 2 bilhões de pessoas estão localizadas nessas áreas, e a maioria corresponde a países em desenvolvimento (D'ODORICO et al., 2014; VIEIRA, et al., 2015).

As secas são tradicionalmente classificadas na literatura em quatro tipos: meteorológica, hidrológica, agrícola e socioeconômica (KEYANTASH e DRACUP, 2002; BRITO et al., 2018). A seca meteorológica é caracterizada por um período com escassez de precipitação pluviométrica em uma determinada região (KEYANTASH e DRACUP, 2002; MISHRA e

SINGH, 2010; CGEE e ANA, 2012; HAO e SINGH, 2015; BRITO et al., 2018), sendo a origem dos outros tipos de secas (HAO e SINGH, 2015).

A seca agrícola ocorre quando a umidade do solo está abaixo da quantidade necessária para atender à demanda das plantas e para repor as perdas por evapotranspiração (KEYANTASH e DRACUP, 2002), resultando na perda da cultura (MISHRA e SINGH, 2010).

O déficit de precipitação, quando prolongado, tem como consequência uma redução das vazões e dos níveis dos lagos, dos reservatórios e das águas subterrâneas, caracterizando uma seca hidrológica, a qual persistente mesmo após o encerramento da seca meteorológica (CGEE e ANA, 2012; RAJSEKHAR et al., 2015; HAO e SINGH, 2015), em razão do lento tempo de recarga das águas superficiais e subterrâneas. Mishra e Singh (2010) classificam o déficit hídrico das águas subterrâneas como um quinto tipo de seca, a subterrânea, mas essa não é uma posição majoritária na literatura.

Por fim, tem-se a seca socioeconômica, que pode ser considerada uma consequência dos outros três tipos, os quais são considerados como tipos físicos de secas, em associação com fatores humanos (WILHITE e BUCHANAN-SMITH, 2005). Isto ocorre quando a quantidade de água disponível não consegue atender às demandas da sociedade e dos setores econômicos (MISHRA e SINGH, 2010).

Segundo o Atlas das secas (NÚÑEZ COBO e VERBIST, 2018) durante o século XX os eventos de seca a nível global causaram mais da metade das mortes associadas a desastres naturais e foi, depois das inundações, o desastre natural com o segundo maior nível de impacto humano. Esse relatório afirma ainda que, só no ano de 2015, 50,5 milhões de pessoas foram afetadas pelas secas no mundo.

No Nordeste Brasileiro (NEB), elas afetam a população, principalmente aquela mais vulnerável, localizada na região semiárida, constituindo um fenômeno grave que coloca em risco a segurança alimentar, energética e hídrica da região (MARENGO et al., 2018). Episódios de seca no NEB são relatados desde o século XVI, provenientes de várias fontes (ARAÚJO 1982, MAGALHÃES et al. 1988, GUTIERREZ et al. 2014, WILHITE et al. 2014, MARENGO et al. 2016). Segue uma lista de eventos atualizados para 2016: 1583, 1603, 1624, 1692, 1711, 1720, 1723-1724, 1744-1746, 1754, 1760, 1772, 1766-1767, 1777-1780, 1784, 1790-1794, 1804, 1809, 1810, 1816-1817, 1824-1825, 1827, 1830-1833, 1845, 1877-1879, 1888-1889, 1891, 1898, 1900, 1902-1903, 1907, 1915, 1919, 1932-1933, 1936, 1941-1944, 1951-53, 1958,

1966, 1970, 1976, 1979-1981, 1982-1983, 1986-87, 1992-1993, 1997-1998, 2001-2002, 2005, 2010 e 2012-2016.

Pereira et al. (2015) identificaram a vulnerabilidade e a capacidade de adaptação às variações climáticas em seis Estados do Nordeste, dentre eles Pernambuco, esse tipo de estudo permite avaliar a situação de risco de populações associada aos impactos das mudanças climáticas. Segundo os autores a população rural é mais vulnerável às sucessivas secas porque dependem da atividade agropecuária e do regime de chuvas. Os municípios mais vulneráveis são aqueles onde a maioria da população reside no campo, mais de 30% dela é dedicada a atividades agropecuárias, a produtividade é baixa e a produção agrícola é pouco diversificada.

Brito et al. (2017), estudando as secas severas mais recentes no Semiárido Brasileiro, avaliaram a duração, a severidade e a frequência de seca utilizando os índices SPI-12 e o VHI analisados por quinquênios. Esse estudo abrangeu o período de 1981 a 2016 e nele identificaram, que pelo índice SPI-12, o período de 1996 a 2001 mostrou eventos de seca mais curtos (20-30 meses), mas com alta severidade no nordeste brasileiro, dentre as áreas mais atingidas estava o Agreste pernambucano.

Outro levantamento realizado pelo CEPED UFSC (2013), durante os anos de 1991 a 2012 revelou que nesse período ocorreram 1.308 registros oficiais de estiagem e seca em Pernambuco, sendo o ano de 2012 o que apresentou a maior frequência anual de desastres causados por esse fenômeno no estado. Considerando a problemática da seca no Nordeste, em especial o Estado de Pernambuco, é necessário o monitoramento das secas para caracterizá-las e de prevê-las.

1.6.1 Índices de secas

Os índices de secas aparecem como uma importante ferramenta na integração de diferentes variáveis relacionadas ao fenômeno. Além de serem úteis na detecção e no monitoramento das condições de secas, eles também podem determinar o tempo e o nível das respostas ao desastre (STEINEMANN et al., 2005). A partir desses índices, pode-se caracterizar e comparar diferentes eventos de secas, além de desenvolver planos e sistemas de monitoramento e de alerta de secas (AGHAKOUCHAK, 2015).

Segundo Sánchez et. al. (2016), os índices de seca são usados para identificar, classificar e monitorar esse fenômeno. Eles permitem a avaliação quantitativa da intensidade, duração e extensão espacial de condições climáticas anômalas e, portanto, dão suporte a sistemas de

tomada de decisão. Os índices traduzem as informações de diversas variáveis e indicadores em um único número, sendo, portanto, úteis para caracterizar uma situação e para servir como suporte para a tomada de decisão (HAO e SINGH, 2015). Podem ser compostos por diferentes variáveis relacionadas às secas, como precipitação, vazão, umidade do solo, armazenamento de água em reservatórios e nível das águas subterrâneas (STEINEMANN et al., 2005; HAO et al., 2016).

Os índices de seca podem ser classificados de acordo com o tipo de seca que estes identificam. Os índices de seca meteorológica utilizam parâmetros como precipitação, temperatura e evaporação (KEYANTASH e DRACUP, 2002). Os índices de seca hidrológica são associados a variáveis referentes aos sistemas de água presente no ciclo hidrológico, como o nível de água em reservatórios, nível de água subterrânea e vazões (KEYANTASH e DRACUP, 2012; BARKER et al., 2016). Os índices de seca agrícola, ou seca de umidade do solo, estão justamente relacionados aos parâmetros vinculados à agricultura e às propriedades do solo, como umidade do solo, evapotranspiração e temperatura do solo (KEYANTASH e DRACUP, 2002).

Nos últimos anos diversos índices foram desenvolvidos voltados para identificação de déficits de precipitação, tais como: Percentil da Precipitação Normal; Índice Chinês Z; Índice de Precipitação e Evapotranspiração Padronizado (SPEI) e Índice da Anomalia da Precipitação. Dentre os índices mais comumente utilizados no monitoramento de secas e que considera apenas dados de precipitação, destaca-se o Índice Normalizado de Precipitação (SPI, do inglês “Standardized Precipitation Index”), desenvolvido por McKee et al. (1993, 1995). Esse índice alcançou a notoriedade e ampla utilização, que em 2009 foi escolhido pela Organização Mundial de Meteorologia (WMO) para ser a recomendação global quanto ao uso de índice “meteorológico” de seca (HAYES et al., 2011).

O SPI corresponde também a um dos métodos preconizados pelo Instituto Nacional de Meteorologia (INMET) para caracterizar as anomalias de chuva no Brasil (GOIS et al., 2015). Blain (2014) descreve o SPI como um algoritmo matemático desenvolvido para caracterizar e detectar anomalias de precipitação pluvial em relação a uma condição climática esperada.

As principais vantagens do uso do SPI perante aos demais índices, consistem no fato dele envolver apenas a variável precipitação, evitando a dependência das condições de umidade do solo (HAYES et al., 1999); na independência da topografia da área de estudo; na capacidade de monitorar períodos secos e chuvosos em uma ampla escala de tempo de 1 a 72 meses

(TURKES e TATLI, 2009); e na sua padronização, que garante a frequência de eventos em qualquer local e escala de tempo de forma consistente (ALTAMIRANO, 2010).

A umidade do solo é outra variável amplamente utilizada em estudos de secas. Vários autores, dentre eles Martínez-Fernández et al. (2016) e Velpuri et al. (2015) utilizaram dados obtidos pelos instrumentos MIRAS do SMOS e SMAP, respectivamente, para modelar índices de seca de importância agrícola. Chen et al. (2013) utilizaram quatro anos de dados do AMSR-E para criar índices de seca baseados na temperatura de brilho, verificando boa relação, em alguns casos, com o índice de precipitação padronizada (SPI) para os mesmos pontos.

Em decorrência disso, outros índices vêm sendo desenvolvidos, como o Soil Water Deficit Index (SWDI) que, além de considerar os dados gerados pelos satélites, leva em conta propriedades de solo como capacidade de campo, ponto de murcha permanente e capacidade de água disponível (BAI et al., 2018; MARTÍNEZFERNÁNDEZ et al., 2016), gerando informações mais consistentes, especialmente do ponto de vista agrícola.

O conceito de padronização do SPI também pode ser aplicado a outras variáveis para derivar os índices de seca, como o índice padronizado de umidade do solo (SSI) (HAO e AGHAKOUCHAK, 2013). O SSI, conhecido como um índice de seca agrícola, monitora a extensão e grau de umidade do solo, desempenhando um papel complementar em uma revisão abrangente das condições de seca.

O Índice de Umidade do Solo Padronizado (SSMI), também segue a metodologia proposta por McKee et al. (1993) para o cálculo do Índice de Precipitação Padronizado (SPI), utilizando dados padronizados de umidade do solo. O Índice de Condição de Umidade do Solo (SMCI) é um índice que consiste em uma normalização da umidade do solo com valores relativos ao máximo absoluto e mínimo referente a todo o período de estudo.

Nesse sentido, a correta detecção da intensidade e frequência da seca por meio de índices é essencial para entender o fenômeno de forma mais precisa, especialmente e temporalmente. Essa é uma preocupação ainda mais crescente nos últimos anos em virtude das mudanças climáticas.

1.7 MUDANÇAS CLIMÁTICAS

O clima é força dinâmica que transforma muitos aspectos do meio ambiente, podendo influenciar a configuração de regiões da Terra, a estrutura do solo e a consequente produção

agrícola, bem como as formas de vida que habitam determinada área (AMBRIZZI, 2014). O Painel Intergovernamental de Mudanças Climáticas (IPCC, 2001), principal referência científica em relação ao tema, define o termo mudança climática como “uma variação estatisticamente significativa nas condições médias do clima ou em sua variabilidade, que persiste por um longo período. Pode advir de processos naturais ou ainda de mudanças antropogênicas persistentes na composição da atmosfera ou no uso do solo”.

Nas últimas décadas, o tema mudanças climáticas é um dos mais debatidos pela comunidade científica, gestores públicos e sociedade em geral. A preocupação com a questão encontra-se atrelada aos possíveis impactos que o referido fenômeno pode causar sobre os sistemas naturais e socioeconômicos (FERREIRA et al., 2018). Para Sabbaghi et al. (2020) tornou-se o maior desafio ambiental deste século, pois causa grandes impactos nos recursos hídricos e na produtividade agrícola, especialmente em ambientes áridos e semiáridos.

Delazeri (2015) destaca que em decorrência do acúmulo de Gases de Efeito Estufa (GEEs) ao longo dos últimos anos na atmosfera intensificado por atividades humanas, as mudanças climáticas refletem uma ameaça para a diversidade biológica e recursos hídricos, produzindo impactos até mesmo em áreas com pouca antropização.

Diante da relevância desses impactos, vários estudos no contexto de mudanças do clima vêm sendo desenvolvidos, abordando aspectos físicos como: projeções de temperatura e precipitação oriundas de modelos climáticos globais (CUTTER e FINCH, 2008; LEE et al., 2015; OBERMAINER e ROSA, 2013). A mudança do clima, seja por causas naturais ou antrópicas, representa séria ameaça para a população humana, pois a alteração do padrão observado de temperatura e precipitação apresenta impactos, tanto diretos (secas, inundações e enxurradas) quanto indiretos (migração de pessoas e favorecimento da proliferação de doenças de veiculação hídrica e transmitidas por vetores) (CONFALONIERI, 2003; De SHERBININ et al., 2011).

Hallegatte e Mach (2016) afirmam que os cenários mais otimistas preveem um aumento da temperatura entre 1,5°C e 2,0°C. Por outro lado, o IPCC projeta que até 2100, a temperatura média do planeta pode subir em mais de 5°C (IPCC, 2015). Conforme o IPCC (2014b) em regiões secas de latitudes médias e subtropicais, a precipitação média tende a diminuir, afetando a quantidade e qualidade dos recursos hídricos superficiais e subterrâneos. As mudanças na precipitação poderão proporcionar eventos extremos mais intensos e frequentes (IPCC, 2014b).

Uma das técnicas que auxilia a análise das possíveis mudanças climáticas em uma determinada região ou em padrões globais são os modelos climáticos (SALES e PEREIRA, 2015). Estes incluem Modelos Climáticos Globais (MCG) e Modelos Climáticos Regionais (MCR). De acordo com Lyra (2015), os MCGs e MCRs são utilizados como importantes ferramentas para projeções de cenários climáticos, auxiliando nos estudos do clima no futuro.

1.7.1 Modelos climáticos globais e regionais

Modelos Climáticos Globais (MCG) ou Modelos de Circulação Geral, Modelos Acoplados Atmosfera-Oceano de Circulação Global (AOGCM) ou, ainda, Modelos do Sistema Terrestre (ESM) são representações do sistema climático terrestre baseados em leis de conservação de massa, energia e momento e leis da termodinâmica e de radiação (MARAUN et al., 2017).

Há um grande número de MCGs, cujos resultados são fornecidos por vários centros de pesquisa em todo o mundo, e que podem variar em precisão, dependendo de sua resolução de grade espacial e outros fatores. Eles são capazes de projetar mudanças na atmosfera terrestre causada pelos elementos ocasionadores do aquecimento global, especialmente os gases de efeito estufa (SRIVASTAV, SCHARDONG e SIMONOVIC, 2015).

Dentre os MCGs, tem ganhado bastante destaque o Modelo Interdisciplinar para Pesquisas do Clima ou MIROC. O MIROC5 (por estar na quinta versão) é um modelo desenvolvido em cooperação com o Japão, é bastante utilizado para simulações do clima em diversas regiões do planeta. (WATANABE et al., 2010). Hirota et al. (2011) analisaram o quão eficiente o modelo MIROC5 é capaz de reproduzir os eventos de chuva sobre as regiões tropicais do planeta e verificaram que essa versão é melhor do que as anteriores e tem uma relação mais fraca com a temperatura da superfície do oceano.

Outros modelos também tem ganhado destaque como, o Modelo Ambiental Global do Centro Hadley HadGEM2- ES (COLLINS et al., 2011; MARTIN et al., 2011); o CANESM2 que é composto por modelos de oceanos, gelo marinho, atmosfera, terra e ciclo de carbono (LARGE et al. 2001); o Modelo Brasileiro do Sistema Terrestre (BESM) que é um conjunto de programas computacionais que acopla os componentes de superfície continental, oceano, atmosfera e química globais, com o principal objetivo de gerar cenários de mudanças climáticas com perspectiva brasileira, ao incorporar processos de formação de nuvens, dinâmica da

vegetação e o conhecimento criado no país sobre a influência dos biomas brasileiros sobre o clima global (INPE, 2015).

Porém os cenários climáticos futuros, derivados de MCGs, apresentam escalas espaciais (240 a 600 km) geralmente incompatíveis com as escalas requeridas para estudos de impactos, o que exige o refinamento de escala, conhecido como *downscaling*, a partir da incorporação de informações locais que dão origem ao Modelo Climático Regional (MCR, em inglês) (CHOU et al., 2014).

A criação de um modelo regional, ou a regionalização dos modelos globais de simulação climática se faz necessária. Os MCR, em geral, produzem prognósticos mais acurados do que os modelos globais, já que possuem melhor resolução horizontal e parametrizações físicas mais adequadas para resolver os processos atmosféricos de mesoescala (GIORGI e MEARNNS, 1999; MISRA et al., 2002; CUADRA e ROCHA, 2006).

O modelo regional Eta, bastante utilizado, foi proposto por Mesinger (1984) em conjunto com o Instituto Hidrometeorológico da Sérvia e Universidade de Belgrado, aperfeiçoado por Black (1994) através do Centro Meteorológico dos Estados Unidos. Segundo Chou et al. (2012) esse modelo é muito utilizado em estudos de adaptação, impactos e vulnerabilidade no Brasil e na América do Sul.

Esse modelo vem sendo aprimorado ao longo dos anos por pesquisadores do Centro de Previsão de Tempo e Estudos Climáticos do Instituto Nacional de Pesquisas Espaciais (CPTEC/INPE) (CHOU et al. 2005; 2012; MESINGER et al. 2012), para produzir previsões em alta resolução, para previsões de tempo (CHOU, 1996; SELUCHI et al., 2003; VIEIRA et al., 2016; SIQUEIRA et al., 2016), clima sazonal (CHOU et al., 2005; PILOTTO et al., 2012; RESENDE e CHOU, 2015) e clima subsazonal (CHOU et al., 2005).

Utilizar os modelos na projeção das mudanças climáticas é simular como as ações humanas ou atividades naturais irão afetar a humanidade em décadas ou séculos. Nesse contexto, definir os cenários é importante, uma vez que se estabelecem o uso da terra e as forças radiativas em situações hipotéticas de emissão de gases do efeito estufa na atmosfera (COLLINS et al., 2013).

1.7.2 Cenários do IPCC

No seu Quinto Relatório de Avaliação (AR5) de 2014, o IPCC usou os novos cenários RCPs (Caminhos Representativos de Concentração”, do inglês Representative Concentration Pathways (RCP’S)). Cada um dos quatro cenários considera o histórico evolutivo de diversos motivos, com a forçante radiativa na atmosfera, emissão de gases, concentração de gases de efeito estufa, e informações de tipo de cobertura terrestre, para as projeções.

Os RCPs incluem um cenário de mitigação rigoroso (RCP 2.6), dois cenários intermediários (RCP 4.5 e RCP 6.0) e um cenário com emissões de GEE muito altas (RCP 8.5), os quais correspondem as forçantes radiativas de $8,5 \text{ W.m}^{-2}$, 6 W.m^{-2} , $4,5 \text{ W.m}^{-2}$ e $2,6 \text{ W.m}^{-2}$, respectivamente. Essas estimativas são baseadas na concentração de gases de efeito estufa e outros agentes (CHUO et al., 2014a; VAN VUUREN et al., 2011).

O RCP 2.6 foi desenvolvido pela equipe de modelagem IMAGE (Integrated Model to Assess the Global Environment) da PBL Netherlands Environmental Assessment Agency. Neste cenário, o mais otimista, o crescimento da radiação atingiria seu pico no meio do século e depois recuaria. Para alcançar tais níveis de forçante radiativa, as emissões de gases de estufa são substancialmente reduzidas ao longo do tempo (VAN VUUREN et al., 2007).

O RCP 4.5 foi desenvolvido pela equipe de modelagem do JGCRI (Pacific Northwest National Laboratory’s Joint Global Change Research Institute) dos EUA. É um cenário de estabilização em que a forçante radioativa total é estabilizada pouco depois de 2100, sem ultrapassar o nível alto do longo termo da forçante radiativa (CLARKE et al., 2007; SMITH e WIGLEY, 2006; WISE et al., 2009).

O RCP 6.0, desenvolvido pelo time de modelagem AIM do NIES (National Institute for Environmental Studies) do Japão, é um cenário de estabilização em que a forçante radiativa total é estabilizada pouco depois de 2100, através da aplicação de uma série de tecnologias e estratégias para reduzir as emissões de gases de efeito estufa (FUJINO et al., 2006; HIJIOKA et al., 2008).

E finalmente, o RCP 8.5, é o cenário mais preocupante, com aumento constante na taxa de radiação provocada pelo crescimento na emissão de GEE e em uma maior concentração. Este cenário desenvolvido usando o modelo MESSAGE e pelo quadro de avaliação integrada do IIASA (International Institute for Applied Systems Analysis) da Áustria. Este RCP, é um cenário pessimista, e é caracterizado pelo aumento das emissões de gases estufa ao longo do tempo, representando cenários da literatura que levam a altos níveis de concentrações (RIAHN et al., 2007).

Segundo Collins et al. (2013) cada cenário traz um aumento da superfície terrestre diferente, sendo de 0,3 a 2,6°C para o RCP2.6, de 1,1 a 2,6°C para o RCP4.5, de 1,4 a 3,1°C para o RCP6.0 e de 2,6 a 4,8°C para o RCP8.5. Publicações recentes, incorporando projeções de evolução do clima para vários cenários de emissões dos gases de efeito estufa em modelos hidrológicos, têm procurado analisar os impactos das mudanças climáticas nos regimes hidrológicos em bacias hidrográficas (KARLSSON et al., 2016; XU e LUO, 2015).

1.8 MODELAGEM HIDROLÓGICA

Os modelos hidrológicos são ferramentas que têm sido muito utilizados para melhorar o entendimento e representação dos processos que envolvem recursos hídricos nas bacias hidrográficas (CALDEIRA et al., 2018). Machado et al. (2017) enfatizam que modelos hidrológicos surgiram como uma solução à necessidade de complementar dados existentes ou suprir aqueles indisponíveis. São desenvolvidos com o intuito de responder às questões decorrentes de cada época, dando ênfase aos processos hidrológicos mais representativos de cada região.

Para Viana et al. (2018) a modelagem hidrológica permite verificar a consistência das informações já disponíveis nas séries históricas que, em geral são curtas e, com base nesses dados, os modelos são calibrados e ajustados para gerar séries simuladas, permitindo a obtenção de dados até mesmo em bacias pouco ou não monitoradas.

Atualmente, existem diversos modelos hidrológicos que são aplicados em diversas situações, estruturadas física ou conceitualmente, discretizados espacialmente como concentrados ou distribuídos, desde níveis de sub-bacias até regiões hidrologicamente homogêneas. Desses modelos, destacam-se: HBV (BERGSTRÖM, 1992); SWAT (ARNOLD, ALLEN e BERNHARDT, 1993); TOPMODEL (BEVEN e BINLEY, 1992); DHSVM (WIGMOSTA, VAIL e LETTENMAIER, 1994); MGB-IPH (COLLISCHONN e TUCCI, 2003); e LASH (BESKOW, MELLO e NORTON, 2011; MELLO et al., 2008).

O Soil and Water Assessment Tool (SWAT), desenvolvido na Texas A&M University, é um modelo semi-distribuído e contínuo no tempo, desenvolvido com o intuito de avaliar os impactos das mudanças de uso e ocupação do solo em bacias hidrográficas de diferentes escalas. O modelo se destaca por possuir compatibilidade com grande quantidade de softwares de

geoprocessamento (ANDRADE et al., 2017a; ANDRADE et al., 2017b; MARONEZE et al., 2014).

Neitsch et al. (2011) destacam que o SWAT possibilita a modelagem de extensas bacias hidrográficas, com diferentes tipos e usos do solo ao longo de grandes intervalos de tempo. É um modelo distribuído de base física, contínuo no tempo, o qual simula o escoamento superficial, a erosão em planos e canais, o transporte de nutrientes e pesticidas em escalas de tempo diárias, mensais e anuais.

No Estado de Pernambuco no Nordeste do Brasil, o modelo SWAT tem sido amplamente utilizado onde pesquisas vem sendo realizadas em algumas bacias hidrográficas (ANDRADE et al., 2020; SOUSA et al., 2019; VIANA et al., 2018). De forma geral, os modelos hidrológicos são uma ferramenta fundamental na investigação dos impactos das mudanças climáticas nos recursos hídricos em uma bacia hidrográfica, e estes podem ser usados em um modo preditivo para entender o comportamento hidrológico em uma bacia diante de condições bem diferentes das utilizadas na calibração e verificação do modelo, como é o caso dos cenários decorrentes de mudanças climáticas (SOUSA, 2019).

**CAPÍTULO II: VALIDAÇÃO DE PRODUTOS DERIVADOS DO ALGORITMO
SM2RAIN NO ESTADO DE PERNAMBUCO PARA MONITORAMENTO DA SECA**

VALIDAÇÃO DE PRODUTOS DERIVADOS DO ALGORITMO SM2RAIN NO ESTADO DE PERNAMBUCO PARA MONITORAMENTO DA SECA

RESUMO: O conhecimento da variabilidade da precipitação é importante no contexto da gestão do risco de seca em regiões como o Nordeste do Brasil. O Estado de Pernambuco vem sofrendo com as irregularidades das chuvas e com o fenômeno das secas. Diante disso, esse estudo teve como objetivo verificar a aplicabilidade de dados de precipitação estimados pelo algoritmo SM2RAIN na estimativa da seca em Pernambuco, a partir de mapas de anomalias. Três produtos foram utilizados SM2RAIN-GPM, SM2RAIN-ASCAT, SM2RAIN-CCI, sendo validados utilizando oito estações do Instituto Nacional de Meteorologia (INMET) espalhadas em todo o Estado, utilizando a técnica conhecida como ponto a pixel (*point-to-pixel*). Os resultados indicaram que todos os três algoritmos baseados no SM2RAIN possuem bom desempenho na estimativa da precipitação em Pernambuco, porém, o SM2RAIN-ASCAT foi o que obteve coeficientes de correlação (CC) superiores a 0,80 em escala mensal e 0,85 em escala anual. Os mapas da anomalia ilustraram que em 2012 foi o ano que o Estado esteve em condições de seca extrema, mesmo em parte da Zona da Mata e do Litoral. Então, fica evidente o potencial do uso de dados do algoritmo SM2RAIN para monitoramento da chuva em todo o Estado e alertam à necessidade de monitoramento contínuo, pois, auxilia na adoção de técnicas de convivência produtiva com as secas.

Palavras-chave: Anomalia, precipitação, sensoriamento remoto.

VALIDATION OF PRODUCTS DERIVED FROM THE SM2RAIN ALGORITHM IN THE STATE OF PERNAMBUCO FOR DROUGHT MONITORING

ABSTRACT: Knowledge of rainfall variability is important in the context of drought risk management in regions such as Northeast Brazil. The State of Pernambuco has been suffering from the irregularities of the rains and the phenomenon of droughts. Therefore, this study aimed to verify the applicability of precipitation data estimated by the SM2RAIN algorithm to estimate drought in Pernambuco, using anomaly maps. Three products were used SM2RAIN-GPM, SM2RAIN-ASCAT, SM2RAIN-CCI, being validated using eight stations from the National Institute of Meteorology (INMET) spread throughout the state, using the technique known as point-to-pixel . The results indicated that all three algorithms based on SM2RAIN have good performance in estimating precipitation in Pernambuco, however, SM2RAIN-ASCAT was the one that obtained correlation coefficients (CC) higher than 0.80 in monthly scale and 0.85 in annual scale. The maps of the anomaly illustrate that 2012 was the year that the state was in extreme drought conditions, even in part of the Zona da Mata and the coast. So, the potential of using data from the SM2RAIN algorithm for monitoring rainfall throughout the State is evident and they alert to the need for continuous monitoring, as it helps in the adoption of techniques for productive coexistence with droughts.

Keywords: Anomaly, precipitation, remote sensing.

1. INTRODUÇÃO

O Brasil é um dos países que sofrem constantemente com extremos climáticos, com destaque para a ocorrência de enchentes e deslizamentos de terra em centros urbanos, seguido da seca em diversas regiões do país. Desta forma, cabe ressaltar a relevância de estudos observacionais que visem à caracterização do regime de chuvas para aperfeiçoar o entendimento a respeito da variabilidade pluviométrica nas diversas regiões do país (SOBRAL et al., 2018). Nas regiões subúmidas e semiáridas, a questão da água é crucial para o desenvolvimento local e para a manutenção da qualidade de vida, dado que nessas áreas tal recurso é mais escasso que nas áreas úmidas e hiperúmidas (LUCENA, CABRAL JÚNIOR e STEIKE, 2018).

O estudo do regime de chuvas de uma região é tradicionalmente realizado a partir de dados de postos pluviométricos, porém os dados podem apresentar baixo grau de confiabilidade em áreas extensas, visto que a distribuição dos pluviômetros não abrange todo o território (NÓBREGA, SOUZA e GALVÍNCIO, 2008; PEREIRA et al. 2013). Além disso, a maioria dos dados de pluviômetros ainda são coletados manualmente, portanto o recolhimento e a digitalização desses dados estão sujeitos a erros humanos e são uma fonte de atraso na disponibilidade de dados (SATGÉ et al., 2020).

Wang et al. (2017), afirmam que devido à grande variabilidade da precipitação, observações medidas em postos pluviométricos representam apenas um registro em escala pontual que pode resultar em significativos erros quando interpolados para grandes áreas, especialmente em regiões com variações topográficas e climáticas, como é o caso de Estado de Pernambuco, com altitudes que variam de 3 m no litoral a 1200 m no sertão e precipitação que alterna entre acumulados de 500 mm ano⁻¹ a 2200 mm ano⁻¹ (POSSAS et al., 2012).

Diante disso, o sensoriamento remoto se torna uma ferramenta fundamental para coleta de dados de chuva, contribuindo para a obtenção de informações oportunas, de baixo custo, sinópticas, sistemáticas e com alta frequência de revisitação da superfície terrestre, promovendo um conhecimento melhor da precipitação em qualquer área do globo terrestre (ATZBERGER, 2013; CUNHA et al., 2017; ROSSATO et al., 2017; SÁNCHEZ et al., 2016a; SCAINI et al., 2015; SOUZA et al., 2018).

Nas últimas décadas, com o intuito de monitorar atributos climáticos, incluindo a precipitação, diversos satélites e produtos foram lançados. O exemplo mais recente, bem-

sucedido, trazendo diversas correções de estimativas de precipitação por satélite é representado pelo IMERG, da missão GPM. Porém, os satélites utilizam vários sensores, causando alguns problemas, como a inconsistência entre as estimativas de precipitação de diferentes sensores (problema de intercalibração), as dificuldades em coletar observações de várias agências espaciais (ou seja, problema de entrega dos produtos em tempo quase real), e requer a fusão de medições instantâneas de chuva de vários sensores, a falha de um deles pode implicar em uma degradação significativa na precisão da estimativa de chuva acumulada devido à alta variabilidade temporal da precipitação (TRENBERTH e ASRAR, 2014).

Devido a esses problemas não desprezíveis em produtos de precipitação baseada em satélite, uma alternativa para monitorar a chuva é por meio do recente algoritmo chamado SM2RAIN, que estima precipitação a partir de observações de umidade do solo *in situ* e/ou baseadas em satélite (BROCCA et al., 2013). O algoritmo SM2RAIN é baseado na inversão da equação do balanço hídrico para recuperar os valores de chuva, sendo aplicado com sucesso aos produtos ativos e passivos de umidade do solo da European Space Agency Climate Change Initiative (ESA-CCI) (LIU et al., 2011, 2012; WAGNER et al., 2012); do Advanced SCATterometer (ASCAT) (WAGNER et al., 2013), e na combinação dos dados do Integrated Multi-Satellite Retrievals (IMERG) e da missão Global Precipitation Measurement (GPM) (MASSARI et al., 2019).

Diversos pesquisadores testaram a aplicabilidade do SM2RAIN e perceberam que ele pode fornecer estimativas de precipitação promissoras, no entanto, por ser relativamente novo, deve ser avaliado nas diversas regiões do mundo (BROCCA et al., 2015; CIABATTA et al., 2015; CIABATTA et al., 2016; CHIARAVALLIOTI et al., 2018).

Tendo em vista se tratar de um algoritmo novo e aplicado em várias categorias de satélites de umidade do solo, podendo apresentar variações de desempenho em diferentes regiões no Estado de Pernambuco, o objetivo dessa pesquisa focou na avaliação e validação dos dados gerados pelo algoritmo SM2RAIN com dados de estações convencionais, para geração de mapas de anomalia de seca.

2. MATERIAL E MÉTODOS

2.1 Área de estudo

O estudo foi desenvolvido no Estado de Pernambuco (Figura 2), localizado na região Nordeste do Brasil entre as latitudes 7° e 10° Sul e longitudes 34° e 42° Oeste, ocupando uma área de cerca de 98.938 km². A área de estudo tem característica do clima tropical, com a umidade relativa do ar situa-se em torno de 81,5%, com pouca variação (GUEDES, 2012).

O Estado se divide em cinco mesorregiões: Região Metropolitana do Recife (RMR), Zona da Mata, Agreste, Sertão Pernambucano e Sertão do São Francisco. Dessas, as três últimas estão inseridas no polígono das secas correspondendo a 88,84% do Estado (SOBEL et al., 2009). O sertão, possui o clima tropical semiárido, quente e seco, com precipitações pluviométricas escassas e mal distribuídas, com período chuvoso raramente ultrapassando quatro meses ao ano, com valores entre 350 mm e 800 mm. Na mesorregião Agreste, o clima é o tropical, quente e úmido a semiárido, com precipitações pluviométricas escassas e mal distribuídas entre 500 mm e 1000 mm e a insolação é bastante elevada, com a temperatura variando de 23 a 27 °C (GUEDES, 2012; TEIXEIRA, 2016).

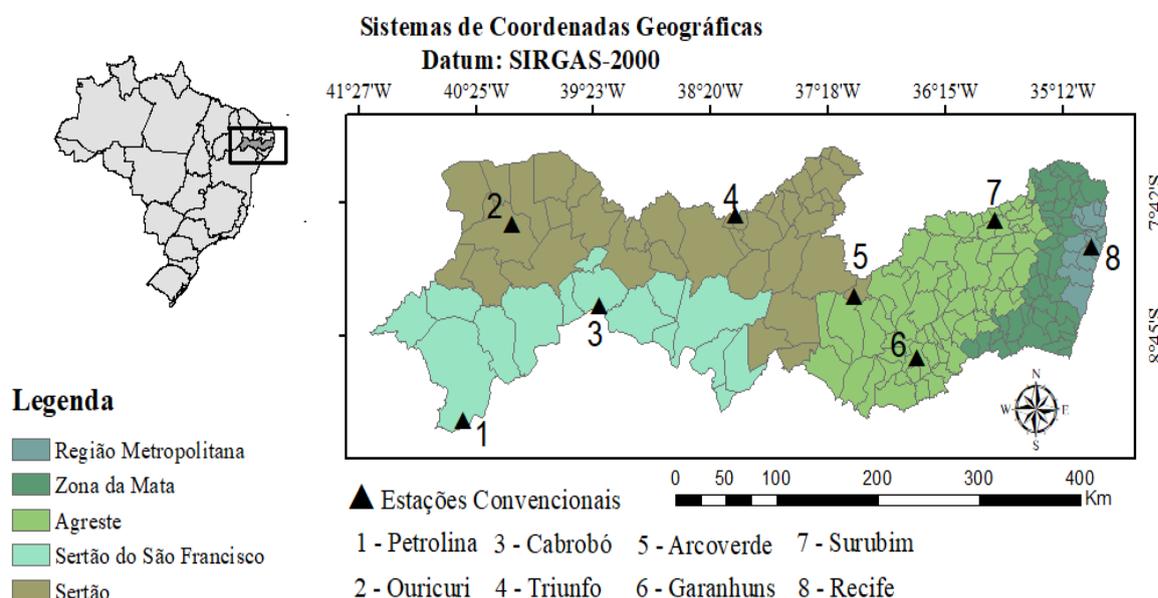


Figura 2 - Mapa de localização do Estado de Pernambuco e das mesorregiões, com destaque para a localização das estações INMET.

2.2. Base de dados

2.2.1 Dados *in situ*:

Para a validação do produto de precipitação do algoritmo SM2RAIN, foram utilizadas oito estações do Instituto Nacional de Meteorologia (INMET) (Figura 2), para o período de janeiro de 1998 a dezembro de 2018. A escolha da localização das estações foi influenciada pelas diferentes condições pluviométricas do estado, visando validar os dados estimados pelo algoritmo em variadas situações. Devido à maior disponibilidade de dados e menor incidência de falhas, foram selecionadas apenas estações convencionais. Os dados diários foram agrupados em mensais para igualar à série do SM2RAIN.

2.2.2 Dados do algoritmo SM2RAIN

Nesse estudo foram utilizados conjuntos de dados de precipitação estimados pelo algoritmo SM2RAIN, baseado em diferentes produtos de umidade do solo estimado por satélites. Todos os dados do algoritmo estão disponíveis da página (<http://hydrology.irpi.cnr.it/download-area/sm2rain-data-sets/>) de forma gratuita, em escala global.

SM2RAIN-CCI: é a versão do algoritmo SM2RAIN, aplicado aos produtos ativos e passivos de umidade do solo da Iniciativa de Mudança Climática da Agência Espacial Europeia (ESA CCI, do inglês European Space Agency's Climate Change Initiative) (LIU et al., 2011, 2012; WAGNER et al., 2012) para o período de janeiro de 1998 a dezembro de 2015 (18 anos). Os conjuntos de dados de chuva derivados do CCI (mm/dia) estão disponíveis em uma grade de 0,25 graus de resolução espacial e uma resolução temporal diária no formato netCDF. O produto representa a precipitação acumulada entre 00:00 e 23:59 UTC do dia indicado, calibrados e com correção climatológica.

SM2RAIN-ASCAT: o algoritmo SM2RAIN foi aplicado aos produtos de umidade do solo Advanced Microwave Scanning Radiometer for Earth Observing (AMSR-E), Soil Moisture and Ocean Salinity (SMOS), and Advanced SCATterometer (ASCAT) para desenvolver o conjunto de dados do SM2RAIN-ASCAT. O ASCAT é um dispersômetro e

consiste no segmento espacial do Sistema Polar EUMETSAT (EPS), operando a 5,255 GHz (polarização VV da banda C) a bordo dos satélites MetOp A, B e C.

O conjunto de dados de chuva SM2RAIN-ASCAT (mm/dia), tem uma resolução espacial de 12,5 km e uma resolução temporal diária disponíveis para o período de janeiro de 2007 a 31 de dezembro de 2019 (13 anos), com versão 1.2. O produto representa a precipitação acumulada entre as 00h00 e as 23h59 UTC do dia indicado, no formato netCDF e GeoTIFF.

SM2RAIN+GPM: o conjunto de dados de precipitação com base na integração de IMERG-LR (do inglês, Integrated Multi-Satellite Retrievals) da Global Precipitation Measurement Mission (GPM) com estimativas de precipitação baseadas em SM2RAIN derivadas de produtos de umidade do solo ASCAT H113 H-SAF, SMOS-L3 e SMAP-L3. Os conjuntos de dados de chuva (mm/dia) estão disponíveis em uma grade de 0,25 graus de resolução espacial e uma resolução temporal diária no formato netCDF, para o período de janeiro de 2007 a 31 de dezembro de 2018 (12 anos).

Cada ponto gerado, dos produtos do SM2RAIN, corresponde a um “pluviômetro” fictício que fornece dados acumulados de precipitação, sendo esse valor único para todo o ponto, obtido a partir do valor médio para aquela área. A precipitação varia bastante espacialmente por vários fatores, no entanto, esta foi a resolução utilizada no estudo por ser a fornecida pelo algoritmo em escala global. Com os dados diários gerados pelo algoritmo, foram calculadas médias mensais e anuais de precipitação e a sua distribuição foi obtida por interpolação espacial, utilizando o método do Inverso do Quadrado da Distância (IQD).

2.3 Validação dos dados

Os dados de precipitação estimados pelo SM2RAIN-CCI foram validados utilizando como base referencial os postos pluviométricos durante o período de 1998 – 2015; enquanto, SM2RAIN-ASCAT e +GPM durante o período 2007 – 2018. Para harmonizar os conjuntos de dados, o produto de precipitação ASCAT foi reamostrado por meio do algoritmo vizinho mais próximo sobre a grade de 0,25°, considerando pelo menos cinco pixels da grade do algoritmo de 12,5 km em torno de cada pixel da nova grade.

A validação é importante para garantir a confiabilidade dos dados mensurados pelo

algoritmo. Embora a sua precisão seja globalmente conhecida, variações pontuais decorrentes de fatores diversos podem interferir em sua leitura (ex.: topografia, clima local, etc.). Nesse estudo, os dados do satélite foram validados utilizando a técnica conhecida como ponto a pixel (*point-to-pixel*), conforme proposto por Gao et al. (2018).

O procedimento consiste em extrair a série dos pixels do algoritmo SM2RAIN e comparar diretamente com o posto pluviométrico correspondente, inserido na área do pixel com centroide mais próximo. Obviamente, existem diversas técnicas de validação, cada uma com suas vantagens, limitações e níveis de complexidade, como a comparação ponto a ponto (*point-to-point*), com as leituras dos pluviômetros sendo interpoladas para a área do pixel, e pixel a pixel (*pixel-to-pixel*), com as leituras dos pixels do SM2RAIN sendo interpoladas para a área dos pluviômetros (AMITAI et al., 2012; CHEN et al., 2013).

Essas duas últimas propostas utilizam uma abordagem baseada na validação espacial, por área, e não apenas na extração direta da série de dados, por isso, podem estar mais propensas a erros (TAN e DUAN, 2017). Por esse motivo, e considerando a reduzida quantidade de postos utilizados, uma abordagem ponto a pixel foi utilizada. Essa é a forma de validação mais utilizada na literatura.

Uma triagem prévia de dados mensurados em superfície foi realizada para identificar falhas e a consistência dos valores registrados para o período. Visando tornar as comparações com os dados dos postos pluviométricos mais consistentes e precisas, dias com falhas nas estações também foram removidos da série dos produtos do SM2RAIN utilizadas para comparação.

A remoção de dias com falhas obedeceu a alguns critérios: (1) para cada dia com falha, foram observados os volumes precipitados utilizando uma janela deslizante de 15 dias, com o dia (ou os dias) com falha fixados no centro desse intervalo. Se houve registro de precipitação nesse intervalo temporal, o dia com falha foi removido automaticamente da série do INMET e do algoritmo SM2RAIN.

No entanto, se (2) não houve registro de precipitação nesse período e chuvas também não foram detectadas no algoritmo, dentro dessa mesma janela de tempo, o dia com falha foi considerado como possuindo precipitação igual a zero. Quando a quantidade de dias com falhas foi superior a 3, consecutivamente ou na janela deslizante de 15 dias, (3) a falha foi removida da série do INMET e igualmente retirada da série do algoritmo, mesmo que o segundo indicasse

precipitação igual a zero.

2.4 Índices estatísticos

Para avaliação da precisão do algoritmo SM2RAIN quando comparado aos postos pluviométricos, foram selecionadas algumas métricas estatísticas comumente utilizadas em estudos de validação de dados de sensoriamento remoto, incluindo precipitação e umidade do solo (CHEN et al., 2017; TAN e DUAN, 2017; WANG et al., 2017), como:

2.4.1 Coeficiente de correlação de Pearson (CC):

Avalia o grau de concordância entre o algoritmo SM2RAIN com os postos pluviométricos (Equação 8), variando de -1 a 1, correspondendo à perfeita correlação negativa e positiva entre as duas séries de dados, respectivamente. Vale destacar que um CC bastante elevado não implica dizer que os dados do algoritmo e campo sejam iguais (exceto quando $CC = 1$), mas sim que eles possuem os mesmos padrões de flutuação (ALBERGEL et al., 2013).

$$CC = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad (8)$$

em todos os casos, considera-se que: em que x e y correspondem à precipitação estimada pelo algoritmo e mensurada em campo, respectivamente, e \bar{x} e \bar{y} representam a média dessas variáveis; O coeficiente de correlação foi classificado conforme os critérios adotados por Shimakura (2006): muito fraco ($\pm 0,0$ a $\pm 0,19$), fraco ($\pm 0,20$ a $\pm 0,39$), moderado ($\pm 0,40$ a $\pm 0,69$), forte ($\pm 0,70$ a $\pm 0,89$) e muito forte ($\pm 0,90$ a $\pm 1,0$).

2.4.2 Raiz do erro quadrático médio (RMSE):

A estatística é utilizada para quantificar diferenças entre as séries (algoritmo e campo), representando a magnitude média do erro (Equação 9). O uso do RMSD ajuda a demonstrar uma magnitude mais realista de discordância entre os dados, quanto mais próximo o valor for de 0, melhor é o desempenho dessa estatística (KERR, 2007; LOEW e SCHELENZ, 2011).

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (y_n - x_n)^2} \quad (9)$$

2.4.3 Bias relativo (RB):

Indica subestimativa ou superestimativa dos dados mensurados pelo SM2RAIN conforme a magnitude do valor (negativo ou positivo) (Equação 10):

$$RB = \frac{1}{N} \sum_{n=1}^N (y_n - x_n) \quad (10)$$

2.5 Anomalia de precipitação

Após a validação dos dados, foi realizado o cálculo das anomalias de precipitação a partir de dados do SM2RAIN para avaliar a severidade da seca no período estudado em dinâmica espacial e temporal. Portanto, foram gerados mapas de anomalias de precipitação mensais e anuais, destacando (em porcentagem), os períodos em que as chuvas excederam ou foram inferiores à média histórica. Essa aplicação é necessária para confirmar se o algoritmo, sem uma climatologia de 30 anos completa, consegue espacializar a seca corretamente, principalmente para o período crítico de 2012 a 2017.

3. RESULTADOS E DISCUSSÃO

Os dados de precipitação diários extraídos pelo algoritmo SM2RAIN foram agrupados em acumulados mensais e comparados com aqueles registrados nas estações pluviométricas, no mesmo período. Em algumas estações, foram filtrados períodos com falhas em dados de precipitação, não havendo validação nesses intervalos específicos.

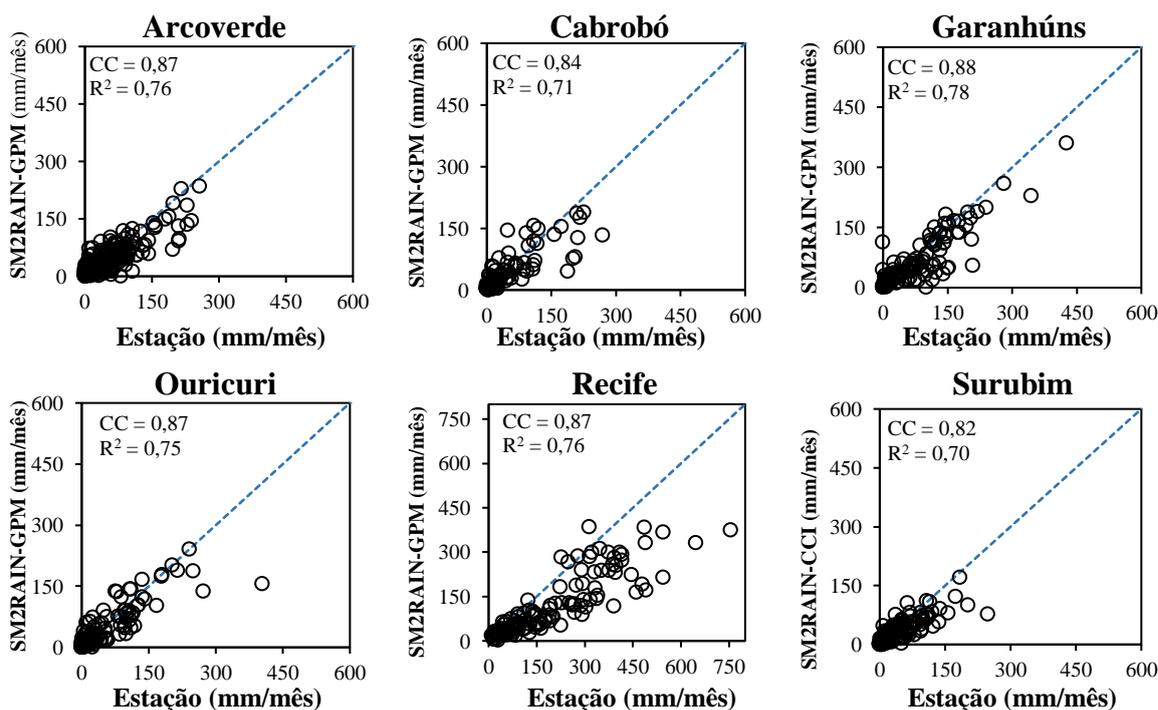
As Figuras 3 e 4 ilustram, em escala mensal, os diagramas de dispersão dos dados gerados pelo SM2RAIN (ASCAT e +GPM) e das estações utilizadas para validação. Os coeficientes de correlação (CC) foram altos em quase todos os casos (maior que 0,85), indicando forte similaridade entre os dados estimados pelo algoritmo e mensurados nos pluviômetros.

O CC ficou abaixo dos 0,80 apenas na estação localizada em Trinfo para o SM2RAIN+GPM, porém, mantendo boa correlação com o SM2RAIN-ASCAT. Vale ressaltar que, os satélites usados pelo algoritmo têm uma resolução espacial de 0,25° (~ 26 km x 26 km),

ou seja, pixels quilométricos ao passo que as estações fornecem um dado pontual. Nesse sentido, além dos fatores topográficos e atmosféricos que naturalmente interferem na qualidade do dado mensurado, a própria discrepância da escala espacial contribui com essa característica, considerando a grande variabilidade espacial da precipitação (CRISTIANO, VELDHUIS e GIESEN, 2017).

No caso do coeficiente de determinação (R^2), seu uso é feito para indicar, de maneira descritiva, a qualidade dos dados gerados pelo algoritmo em relação àqueles mensurados in situ, indicando, nesse caso, que os dados possuem menor semelhança no padrão de variação temporal quanto mais distante de 1 for o R^2 . Todas as estações tiveram um R^2 superior ou igual a 0,70, exceto para estação de Triunfo (SM2RAIN-GPM), também como foi visto na análise do CC. Considerando que essa estação encontra-se em um local de alta altitude, que tende a apresentar menor precipitação, naturalmente os valores de R^2 foram mais baixos quando comparados aos dos satélites, que geram um dado médio para toda a área, caracterizada por baixas altitudes.

Goudarzi, Sarraf e Ahmadi (2020) avaliou os dados de precipitação gerados pela técnica CMORPH e do SM2RAIN-ASCAT sobre o Lago Maharlu, na região semiárida do Irã. Os resultados mostraram que as estatísticas de probabilidade de detecção, índice de sucesso crítico e razão de alarme falso mostraram precisão aceitável na detecção de precipitação, onde o SM2RAIN-ASCAT teve melhor precisão nesta área



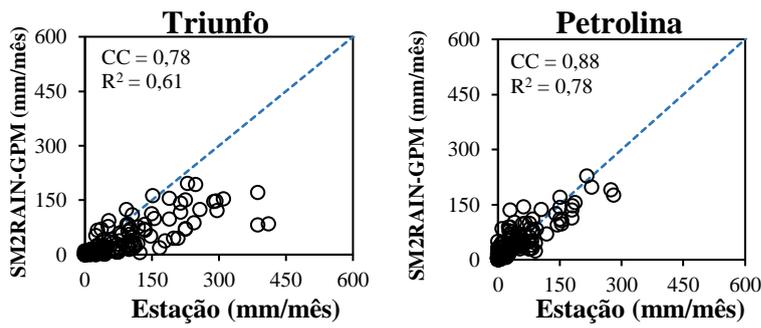


Figura 3. Diagramas de dispersão dos dados de precipitação do SM2RAIN-GPM e das estações mensurados durante o período avaliado, em escala mensal.

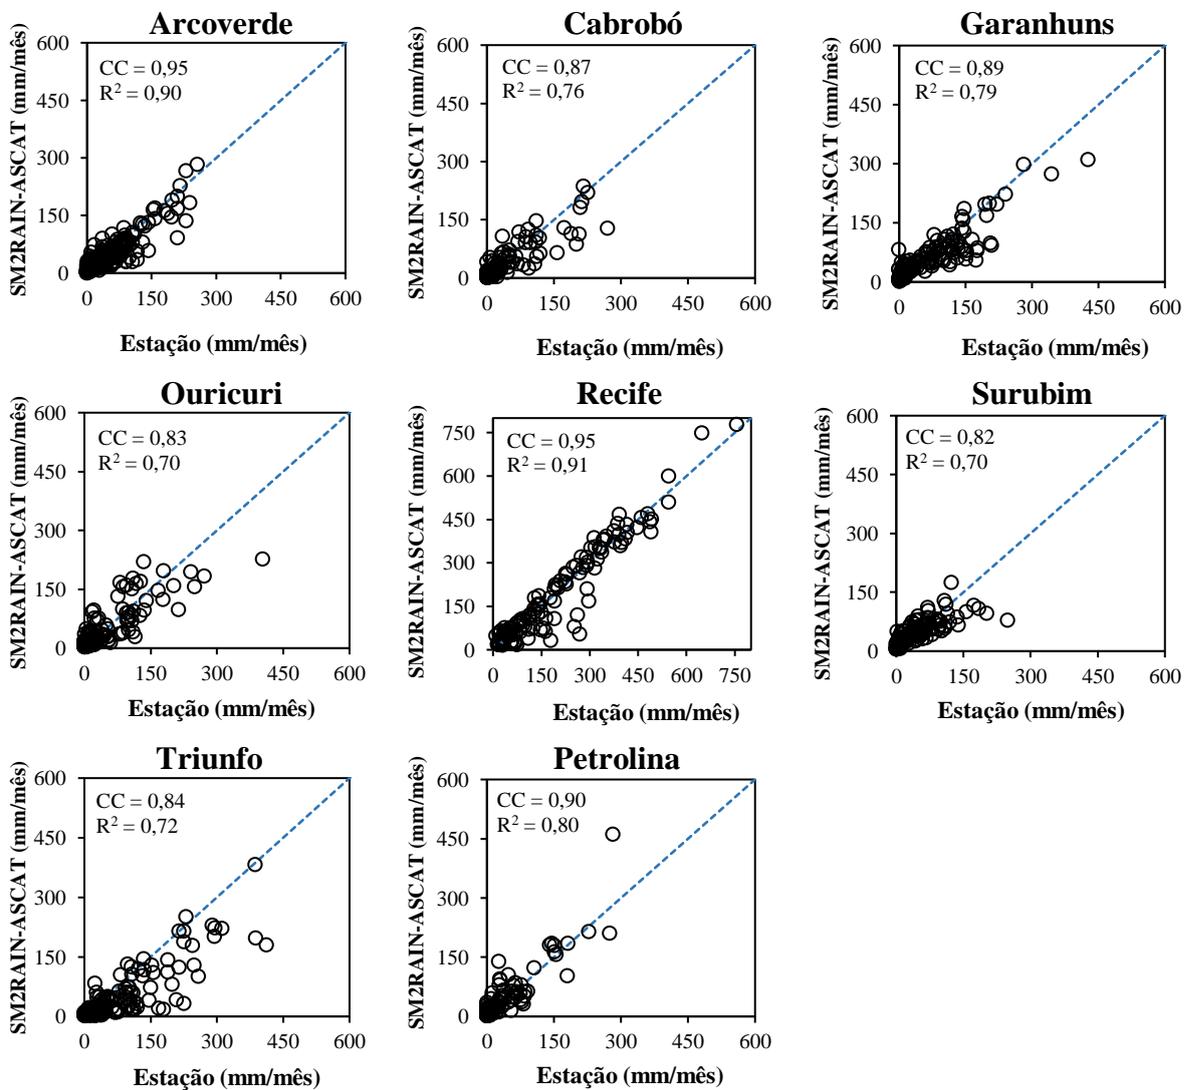
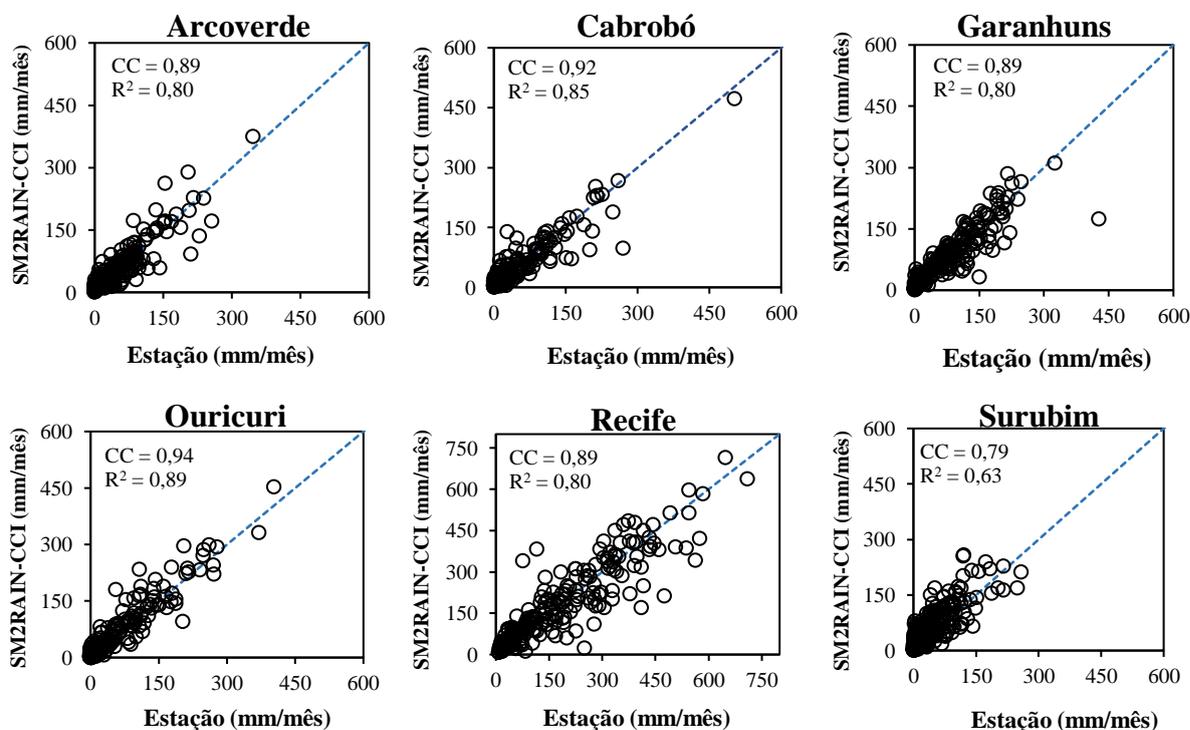


Figura 4. Diagramas de dispersão dos dados de precipitação do SM2RAIN-ASCAT e das estações mensurados durante o período avaliado, em escala mensal.

A série temporal do SM2RAIN-CCI (Figura 5) é maior e foi analisada de forma individual em relação aos outros satélites, por conta da disponibilidade dos dados gerados pelo produto. Por isso, é importante destacar a qualidade dos dados diários que foram gerados pelo CCI, onde ficou evidente a boa correlação em grande parte das estações, tendo valores de CC acima dos 0,90 em Ouricuri e Cabrobó, indicando ser um ótimo algoritmo para um monitoramento da precipitação em todo o Estado, principalmente no sertão. Verificando os dados das outras regiões também encontramos altos valores de CC e R^2 , porém, a estação de triunfo foi a única com pouco desempenho nessa comparação.

Ciabatta et al. (2018) avaliou a qualidade do conjunto de dados de chuva SM2RAIN-CCI e comparou com dois produtos de satélite de chuva de última geração, ou seja, o produto em tempo real 3B42 de Análise de Precipitação Multi-satélite da Missão de Medição Tropical (TMPA 3B42RT) e o Clima Técnica de Morphing do Centro de Previsão (CMORPH) e um conjunto de dados modelados (ERA-Interim). Concluíram que o algoritmo SM2RAIN obteve relativamente bons resultados em coeficiente de correlação (valor médio $> 0,56$), diferença de raiz quadrada média (RMSD, valor médio $< 10,34$ mm em 5 dias) e viés (valor médio $< -14,44\%$) durante o período de avaliado.



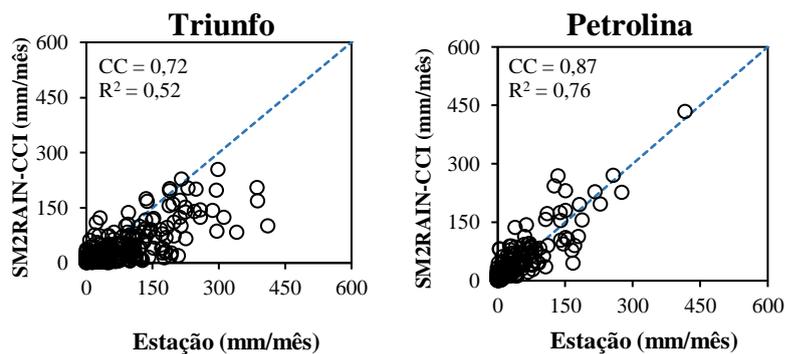


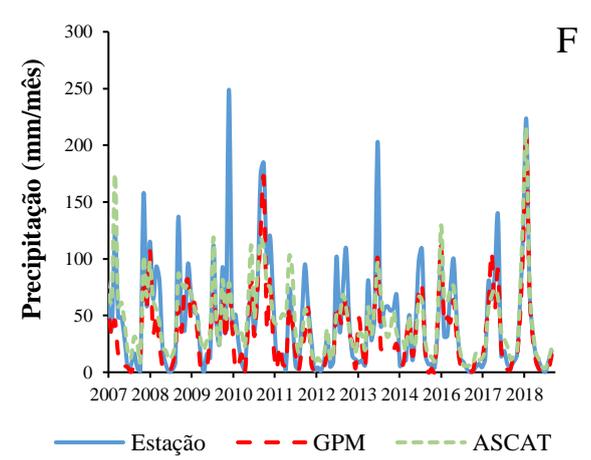
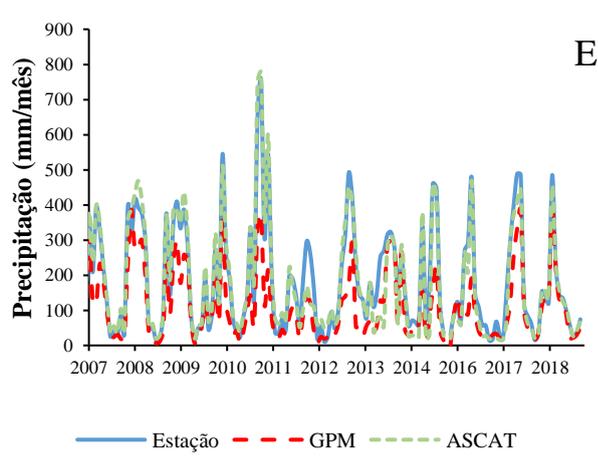
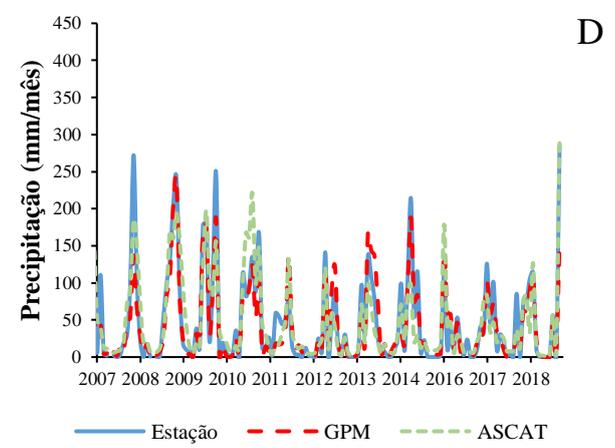
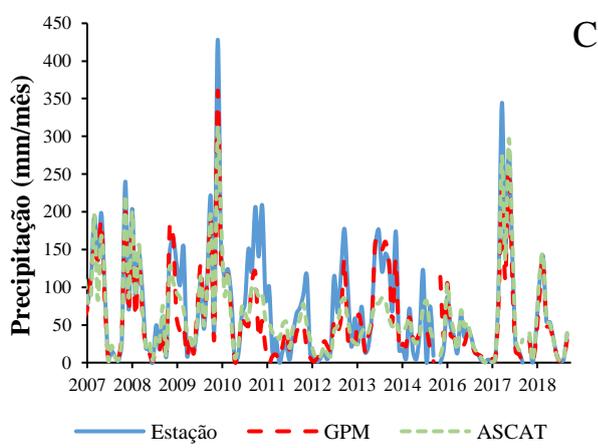
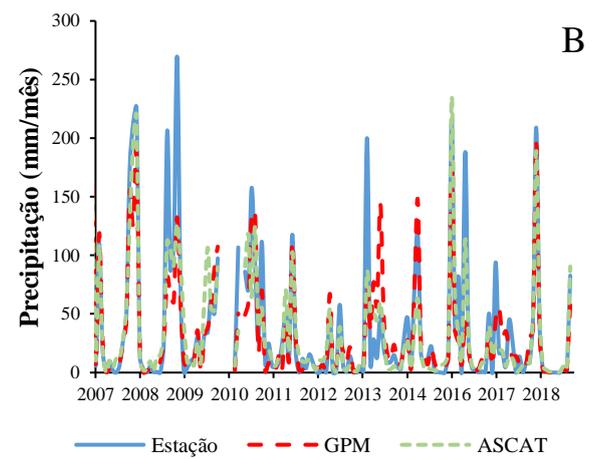
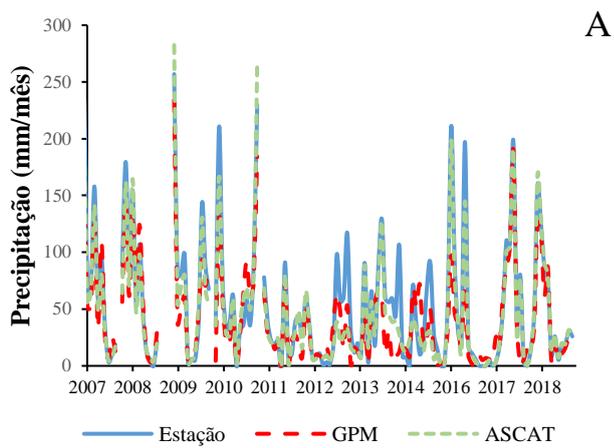
Figura 5. Diagramas de dispersão dos dados de precipitação do SM2RAIN-CCI e das estações mensurados durante o período avaliado, em escala mensal.

A Figura 6 mostra a relação dos dados mensais gerados pelo SM2RAIN-GPM e SM2RAIN-ASCAT, comparados com os dados de estações convencionais do INMET espalhadas por Pernambuco em pontos estratégicos de observação. Os dados foram extraídos de forma diária em cada pixel dos algoritmos, mas para uma melhor interpretação, depois foram convertidos em escala mensal.

No geral, foi observado uma boa relação dos dados do algoritmo com os postos pluviométricos, embora, tenha evidenciado a tendência de subestimar ou superestimar, em alguns casos. O SM2RAIN-ASCAT e o SM2RAIN-GPM subestimaram os dados das estações na maior parte do período analisado.

Anjos et al. (2017) analisou a qualidade das estimativas de precipitação por satélite no município de Petrolândia em Pernambuco, caracterizando as variações das chuvas convectivas e estratiformes, relacionando-as com fenômenos climáticos e eventos extremos. Os autores observaram que os dados do satélite tendem a acompanhar a variabilidade da chuva durante o período estudado, e as estimativas ora superestimaram e, ora subestimaram os dados das estações pluviométricas com os quais foram comparados.

Segundo Brocca et al. (2015) o algoritmo SM2RAIN mostrou uma precisão muito alta nos experimentos, entre os dados gerados sinteticamente e os simulados, em intervalos de tempo diários, com um coeficiente de correlação superior a 0,94 e um Bias médio inferior a 4%. Brocca et al. (2019) destaca que o algoritmo já foi avaliado em várias áreas, incluindo Austrália, Europa e América do Norte, e produziu bons resultados na estimativa de chuva.



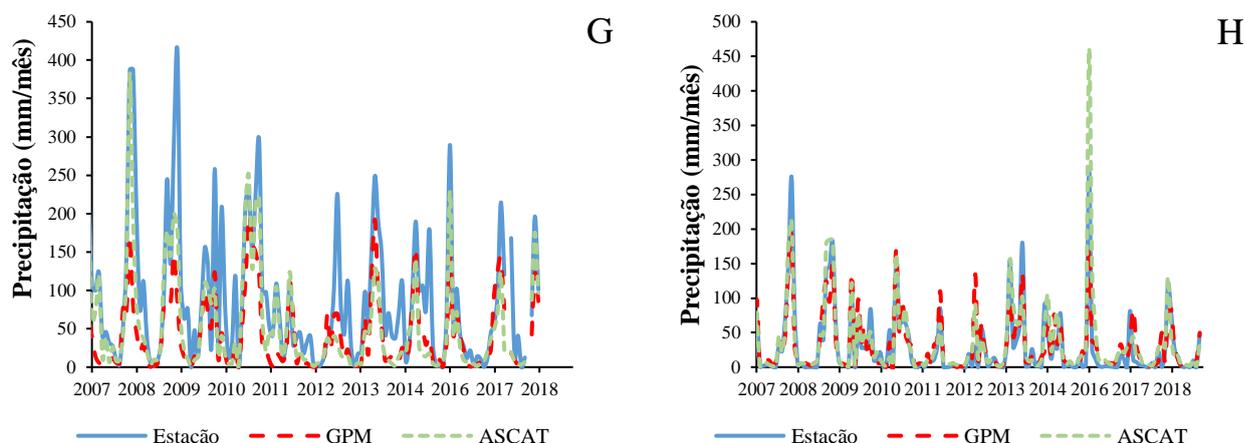
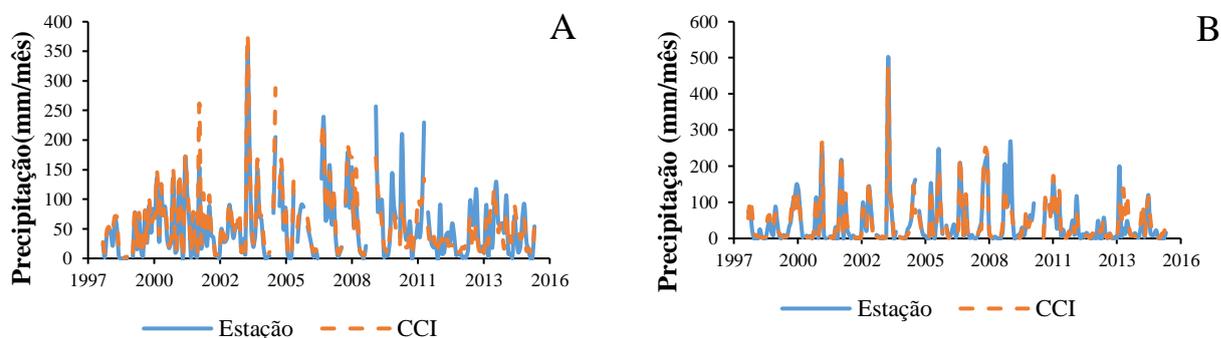


Figura 6 - Precipitação estimada pelo SM2RAIN (GPM e ASCAT) e mensurada pelas estações, em escala temporal mensal, para o período de 2007 a 2018. (A) Arcoverde, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Petrolina.

Na Figura 7 temos a relação dos dados mensais gerados pelo SM2RAIN-CCI comparados com os dados de estações convencionais do INMET. A análise temporal utilizada no estudo foi de 1998 até 2015, já que o satélite de umidade da ESA é mais antigo que os outros, conseqüentemente possui uma série maior. Observa-se uma boa distribuição temporal sempre similar à dos dados medidos, provando que à aplicação do algoritmo teve bons resultados em todos os satélites em estudo para o Estado de Pernambuco. Assim como os outros satélites citados acima, houve uma superestimação e subestimação dos dados em relação aos postos pluviométricos. Esse fato ficou mais evidente nas estações dos municípios de Surubim e Triunfo, onde houve uma maior discrepância.



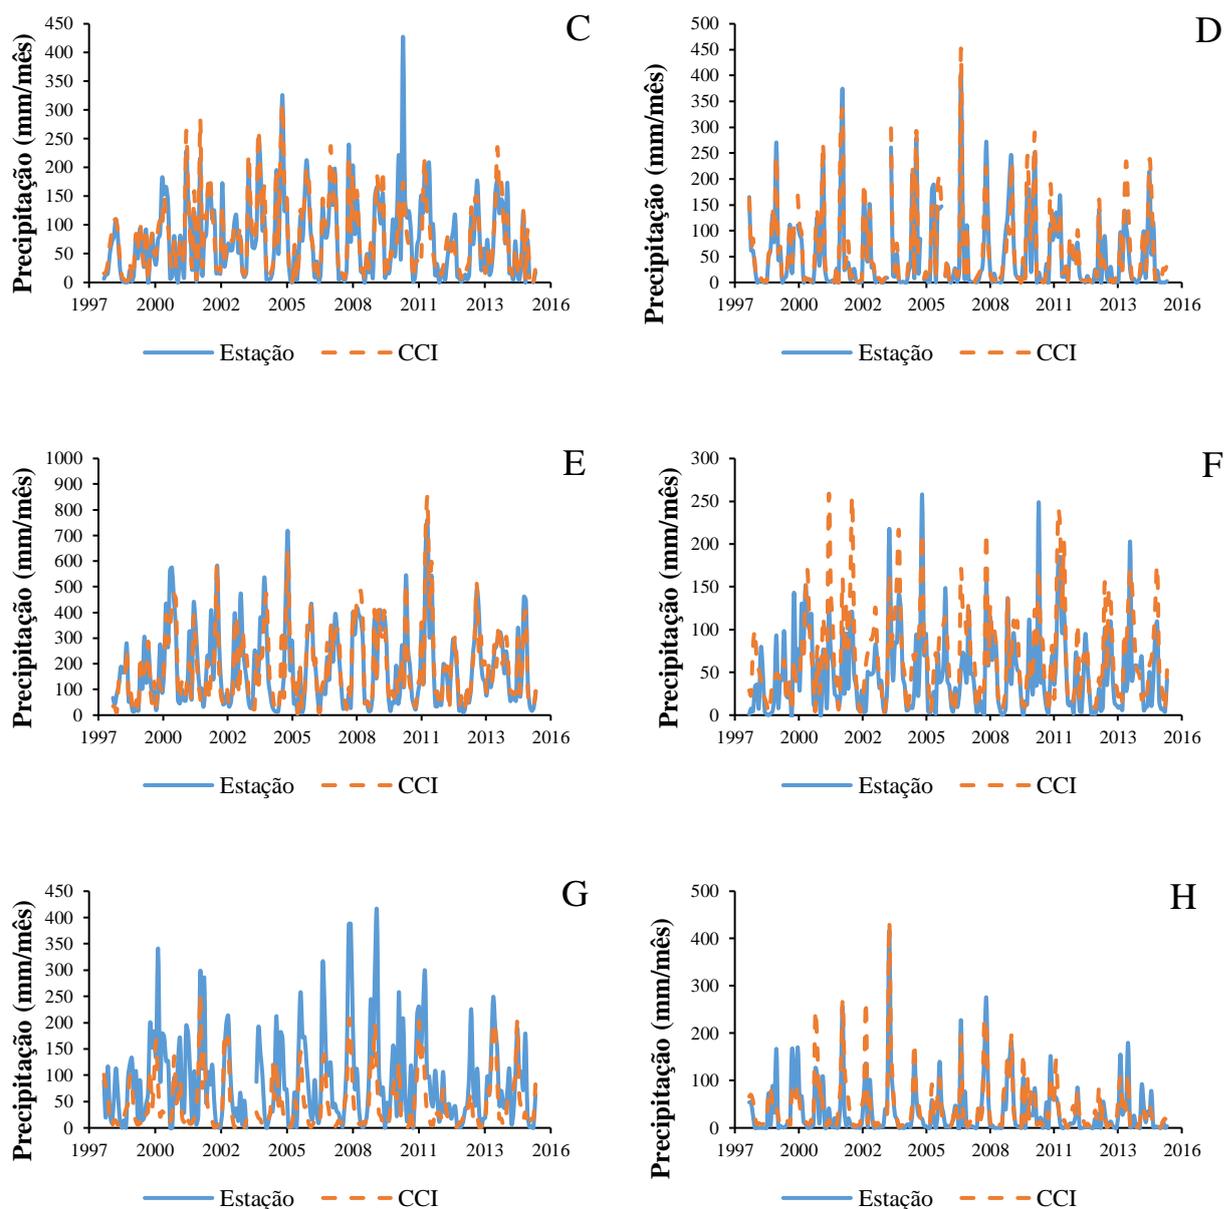


Figura 7 - Precipitação estimada pelo SM2RAIN-CCI e mensurada pelas estações, em escala temporal mensal, para o período de 1998 a 2015. (A) Arcoverde, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Petrolina.

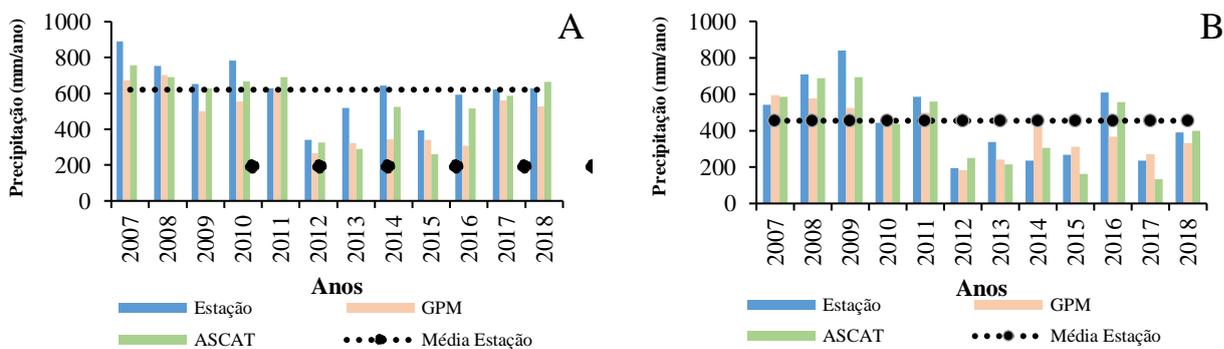
As imagens 8 e 9 mostram, em escala anual, a comparação dos dados de precipitação das estações pluviométricas com os do algoritmo SM2RAIN-GPM, SM2RIAN-ASCAT e SM2RAIN-CCI, respectivamente. A média anual de cada estação foi utilizada para detalhar que a medida que as estações estão mais localizadas na parte leste do Estado temos valores acima de 700 mm, enquanto na parte oeste temos valores abaixo.

Os valores dos algoritmos tenderam a acompanhar a variabilidade da chuva durante

todo o período estudado. No entanto, notou-se que o ano de 2012 ocorreu os menores valores de precipitações acumuladas anuais em todas as estações, chegando a ficar abaixo dos 200 mm nos municípios de Cabrobó e Petrolina, que estão localizados no sertão do São Francisco.

Nóbrega, Farias e Santos (2015) analisaram a tendência espacial e temporal da precipitação pluviométrica do Estado de Pernambuco, tendo como base, índices de extremos climáticos e a técnica dos quantis no período de 1978 a 2010, concluíram que o sertão de Pernambuco, representado pelas mesorregiões do Sertão Pernambucano e do São Francisco, foi que apresentou os maiores números de episódios extremamente secos. Nos locais inseridos na Zona Litorânea brasileira, as precipitações pluviométricas possuem magnitudes superiores a 1.500 mm (OLIVEIRA et al., 2017), enquadrando-se o município de Recife. Jardim et al. (2014) analisaram o comportamento da precipitação em relação à altitude no semiárido de Pernambuco, e concluíram que à medida que os valores de altitude eram reduzidos em cerca de 100 m, a precipitação tendeu a diminuir em média 99,62 mm para valores anuais.

Satgé et al. (2020) avaliaram a confiabilidade do algoritmo SM2RAIN–ASCAT e CCI na estimativa da precipitação em duas regiões áridas: Altiplano boliviano, peruano e o Paquistão (sul da Ásia) usando comparações diretas com pluviômetros e testando a sensibilidade da modelagem de fluxo de água para os conjuntos de dados. Como resultados, os autores verificaram que ambos tiveram os valores de precipitação mais parecidos com dados das estações registrados no Altiplano do que no Paquistão. Este fato foi explicado pela região ter características meteorológicas, topográficas e de cobertura do solo mais favorável para estimar a umidade do solo. Também foi concluído que o ASCAT descreve valores temporais de chuva mais semelhante com outros satélites, CHIRPS v.2, MSWEP v.2.2 e IMERG – F v.6 P, sendo que os gerados pelo SM2RAIN ainda foram melhores em algumas sub-regiões.



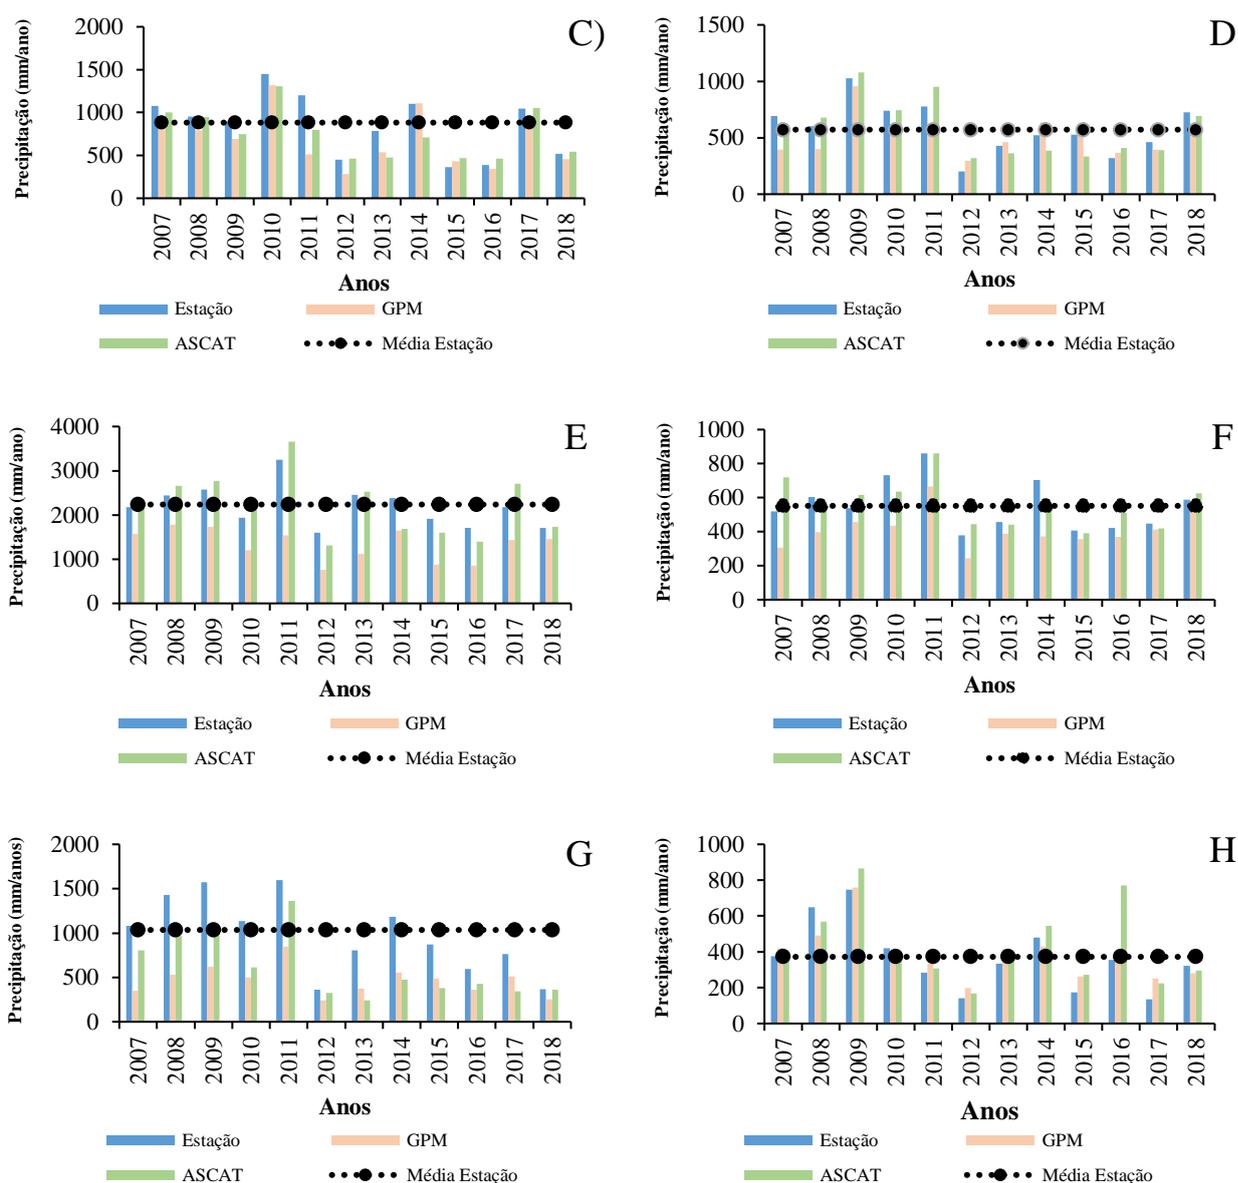
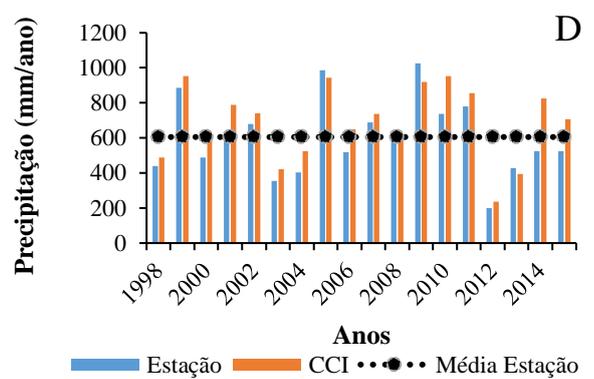
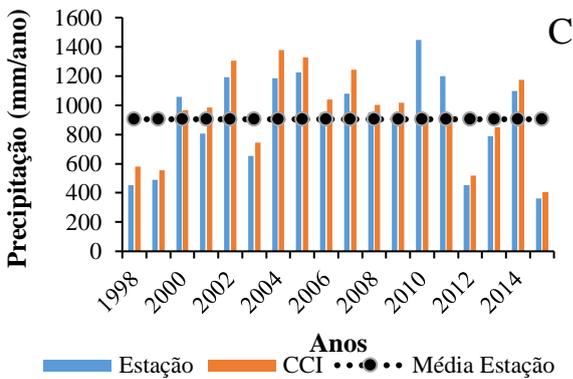
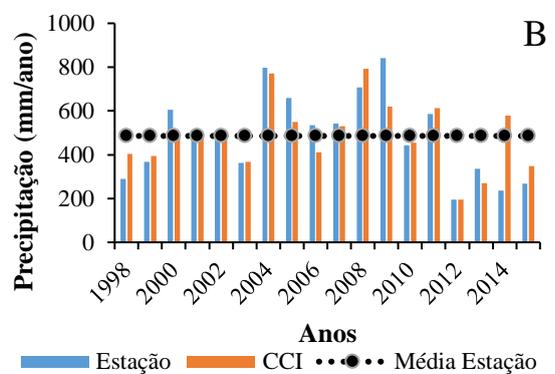
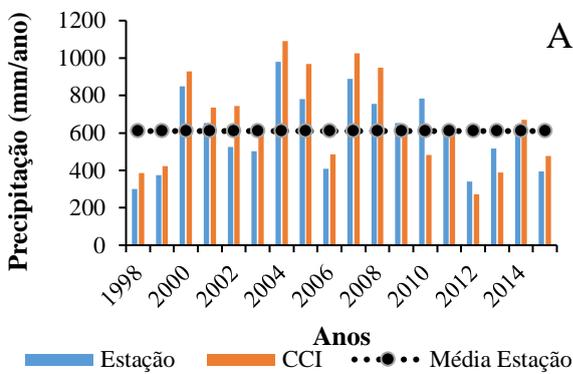


Figura 8 - Comparação dos dados de precipitação das estações pluviométricas com os do algoritmo SM2RAIN (GPM e ASCAT), em escala anual. (A) Arcoverde, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Petrolina.

Outro fato a ser considerado, é que em alguns anos os valores de precipitação foram maiores para o SM2RAIN-ASCAT e em outros anos para o SM2RAIN-GPM, porém, no ASCAT foi visto uma maior similaridade nessa variação temporal com dados do INMET, em destaque temos as estações localizadas Surubim e Recife. Todavia, foi o único satélite em que os valores de precipitação foram bem maiores que os in situ, como foi visto em Petrolina que em 2016, onde foi obtido um valor de 390 mm dos dados de campo, enquanto no algoritmo

baseado no ASCAT marcou quase 800 mm. Contudo, o GPM obteve um valor de 392 mm para aquele ano.

Assim como os satélites citados acima, O SM2RAIN-CCI (Figura 9) apresentou valores anuais de precipitação próximos com os registrados nas estações, para toda a série. Os anos de 1998, 1999 e 2012 foram os mais secos para todas as regiões estudadas em comparação com os outros anos, onde os menores valores foram encontrados na zona semiárida do Estado. Vale ressaltar, que analisando a estação de Triunfo, ocorreu a mesma similaridade com a Figura 7, pois, os dados gerados pelo CCI foram bem menores em comparação com os dados coletados pelo INMET, ficando bem abaixo da média geral do posto pluviométrico.



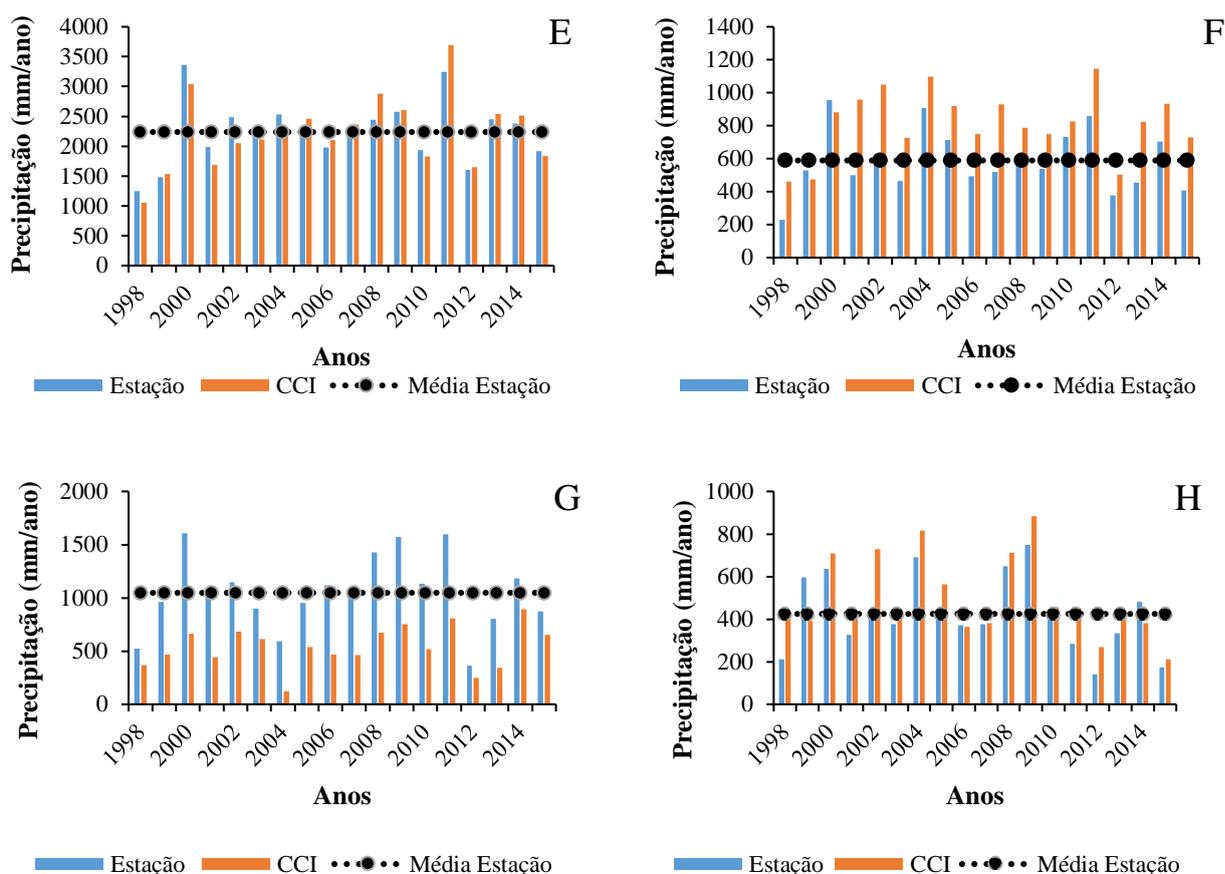


Figura 9 - Comparação dos dados de precipitação das estações pluviométricas com o do algoritmo SM2RAIN-CCI em escala anual. (A) Arcoverde, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Petrolina.

As Tabelas 2, 3, e 4 resumem os índices estatísticos utilizados para avaliação do desempenho do SM2RAIN, nas oito estações convencionais utilizadas para validação. Novamente, nota-se a tendência de os índices apresentarem pior desempenho para acumulados anuais, em quase todos os casos, evidenciando a importância da resolução temporal para que a qualidade da estimativa seja mantida. De todos os algoritmos, o SM2RAIN-ASCAT é o único que possui valores do índice de correlação acima de 0,80 para todas as estações analisadas.

Rahman et al. (2019) avaliaram o desempenho do algoritmo SM2RAIN-CCI e SM2RAIN-ASCAT, na escala diária em todo o Paquistão durante os períodos de 2000 – 2015 e 2007 – 2015, respectivamente, concluíram que o ASCAT obteve melhores resultados estatísticos em relação ao CCI e do Tropical Rainfall Measuring Mission (TRMM) em todas as regiões climáticas do Paquistão. Os autores ainda destacaram que os conjuntos de dados baseados em SM2RAIN são recomendados para gestão hídrica, programação de irrigação,

simulação de enchentes e sistema de alerta antecipado de enchentes, monitoramento de seca, modelagem de água subterrânea e coleta de água da chuva e monitoramento de vegetação e cultivo em áreas planas da região árida.

Tabela 2. Índices estatísticos utilizados para avaliação do desempenho do SM2RAIN-GPM em escala temporal mensal e anual.

Estação	Mensal				Anual			
	CC	R ²	Bias (%)	RMSE	CC	R ²	Bias(%)	RMSE
Arcoverde	0,87	0,76	23,76	31,64	0,79	0,63	-20,58	165,10
Cabrobó	0,84	0,71	-24,52	31,26	0,71	0,51	-10,07	152,79
Garanhuns	0,88	0,78	-19,74	37,72	0,83	0,70	-19,74	255,38
Ouricuri	0,87	0,75	-11,57	33,84	0,79	0,64	-11,46	147,40
Recife	0,87	0,76	-40,91	112,56	0,70	0,50	-40,95	668,26
Surubim	0,81	0,67	-14,54	30,12	0,75	0,57	-27,51	181,27
Triunfo	0,78	0,61	-52,77	75,23	0,83	0,69	-52,77	408,00
Petrolina	0,88	0,78	4,31	25,75	0,93	0,87	5,01	77,56

Tabela 3. Índices estatísticos utilizados para avaliação do desempenho do SM2RAIN-ASCAT em escala temporal mensal e anual.

Estação	Mensal				Anual			
	CC	R ²	Bias (%)	RMSE	CC	R ²	Bias (%)	RMSE
Arcoverde	0,95	0,90	-12,93	19,04	0,89	0,80	-11,01	101,49
Cabrobó	0,87	0,76	-16,62	28,32	0,94	0,88	-8,31	80,40
Garanhuns	0,89	0,79	-13,25	36,37	0,86	0,74	-13,24	140,57
Ouricuri	0,83	0,70	-0,89	36,25	0,89	0,80	-0,58	111,44
Recife	0,95	0,91	-2,43	46,06	0,88	0,78	0,79	138,41
Surubim	0,82	0,70	-0,52	36,20	0,89	0,81	-0,56	98,17
Triunfo	0,84	0,72	-38,96	58,87	0,86	0,75	-38,96	142,74
Petrolina	0,90	0,80	21,69	28,33	0,85	0,74	-20,20	146,09

Tabela 4. Índices estatísticos utilizados para avaliação do desempenho do SM2RAIN-CCI em escala temporal mensal e anual.

Estação	Mensal				Anual			
	CC	R ²	Bias (%)	RMSE	CC	R ²	Bias (%)	RMSE
Arcoverde	0,89	0,80	7,85	24,66	0,86	0,74	7,85	131,07
Cabrobó	0,92	0,85	0,32	24,24	0,77	0,60	0,32	116,69
Garanhuns	0,89	0,80	3,90	30,83	0,83	0,70	3,90	176,45
Ouricuri	0,94	0,89	13,41	25,40	0,89	0,80	13,41	125,62
Recife	0,89	0,80	-0,30	68,01	0,91	0,84	-0,30	239,00
Surubim	0,79	0,63	39,01	37,76	0,71	0,51	39,01	270,55
Triunfo	0,72	0,52	-48,53	72,23	0,78	0,61	-48,53	235,43
Petrolina	0,87	0,76	17,87	29,71	0,81	0,65	17,87	134,59

As figuras 10 e 11 ilustram a precipitação anual média acumulada obtida a partir do SM2RAIN-GPM e SM2RAIN-ASCAT para o Estado de Pernambuco, respectivamente. Com os dados de precipitação diários do algoritmo SM2RAIN, foram calculados acumulados anuais, pixel a pixel, sendo estes posteriormente interpolados para toda a área do estado a partir de técnicas geoestatísticas.

Nesta aplicação, optou-se pelo método do inverso do quadrado da distância (IQD) devido à sua simplicidade e boa aplicação com dados de precipitação, especialmente sob condições de alta densidade de pontos amostrais (ZHANG et al., 2017; ZHANG et al., 2018). A interpolação tem o objetivo de suavizar e tornar contínua a distribuição da precipitação, o que não é possível com a utilização das imagens nativas originais do algoritmo SM2RAIN.

O algoritmo SM2RAIN, com base em todos os três satélites de umidade, conseguiram especializar as menores e maiores taxas de precipitação acumuladas em toda área de estudo, assim como os resultados acima citados mostraram, a zona da mata obteve os maiores valores de precipitação. Boa parte do estado tem valores abaixo dos 600 mm para o GPM, enquanto no ASCAT esses valores são menores que 800 mm. Com a espacialização dos dados, ficou evidente que em 2012 foi o ano em que o estado mais sofreu com a estiagem, sendo que 2013 até 2018 também foi observado grande seca, porém, com menos intensidade.

Segundo Alves et al. (2016) analisando a distribuição pluviométrica em quatro municípios de diferentes mesorregiões do Estado de Pernambuco, enfatizou que cidades localizadas nas mesorregiões do Sertão Pernambucano e do São Francisco, Semiárido Pernambucano são caracterizadas por baixos índices pluviométricos anuais, com valores oscilando entre 400 e 800 mm, além de uma grande variabilidade espacial e temporal das chuvas.

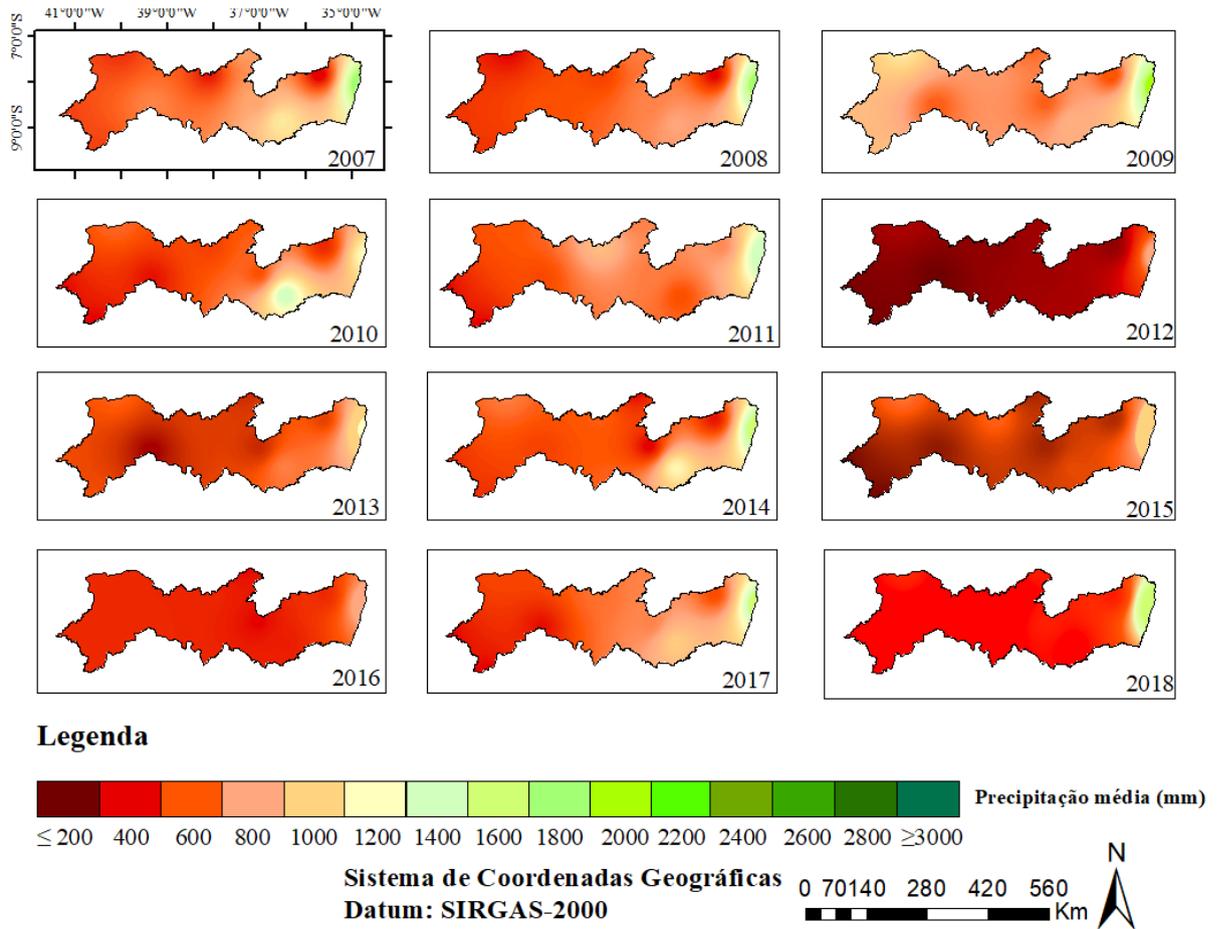


Figura 10 - Precipitação anual média acumulada obtida a partir do SM2RAIN-GPM para o Estado de Pernambuco.

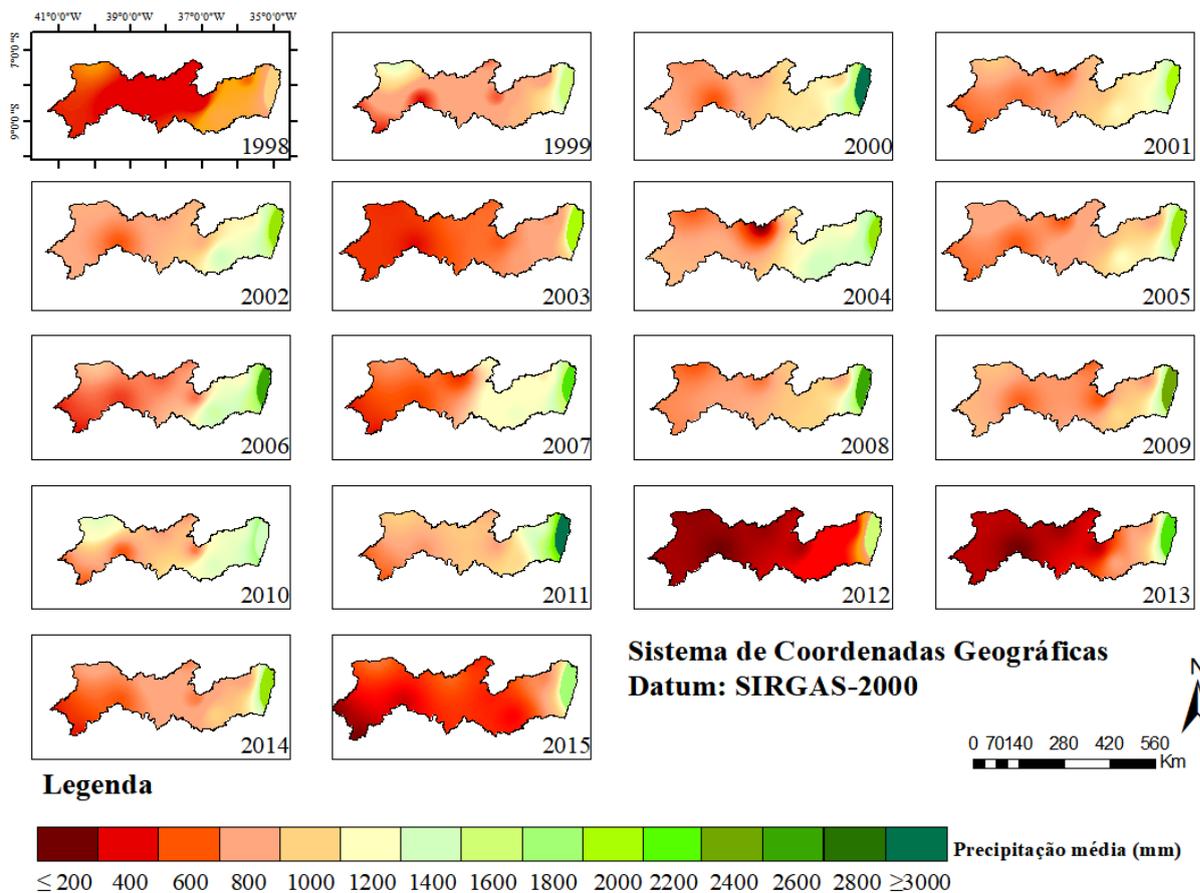


Figura 12 - Precipitação anual média acumulada obtida a partir do SM2RAIN-CCI para o Estado de Pernambuco.

As espacializações das precipitações mensais em todo o Estado, dos três satélites, são apresentadas nas Figuras 13, 14 e 15, que serve como planejamento para várias atividades, especialmente agrícolas. Diversas culturas necessitam ser implementadas em épocas do ano onde as chuvas naturalmente ocorrem em maior intensidade, especialmente na região Nordeste e em áreas em que há a prática da agricultura de sequeiro, onde a disponibilidade de água para condução de cultivos é reduzida ou até mesmo inexistente.

A partir dos dados gerados pelo SM2RAIN é possível reconhecer as épocas chuvosas em cada área do Estado ao longo do ano. O algoritmo mostrou que os meses de maio, junho e julho teve valores de precipitação acima de 200 mm para a zona da mata e 150 mm para o agreste e uma pequena parte do sertão. Para os meses mais secos destacam-se os meses de setembro, outubro, novembro e dezembro, onde a região do sertão é a mais afetada pela ausência de precipitação.

Ferreira et al. (2018) analisou a variabilidade espacial da dinâmica da chuva em escala mensal no estado de Pernambuco, observaram que as maiores médias mensais estão localizadas na Zona da Mata e na região metropolitana de Recife, No Sertão, o município de Triunfo é o mais chuvoso com valor mensal em torno de 87,41 mm.

Nóbrega, Farias e Santos (2015) também estudaram a variabilidade temporal e espacial da precipitação em Pernambuco por meio de índices de extremos climáticos e detectaram regularidades para região metropolitana de episódios secos e chuvosos enquanto que na região Agreste e Sertão uma predominância de eventos extremamente secos.

Da mesma forma que foi visto nos dados anuais, os valores mensais mudam em relação a cada produto do SM2RAIN, pois, cada satélite estima a umidade do solo de uma determinada forma e isso influencia nos valores finais de precipitação. Porém, ficou evidente que todos eles conseguiram especializar condizente do que já foi visto na literatura.

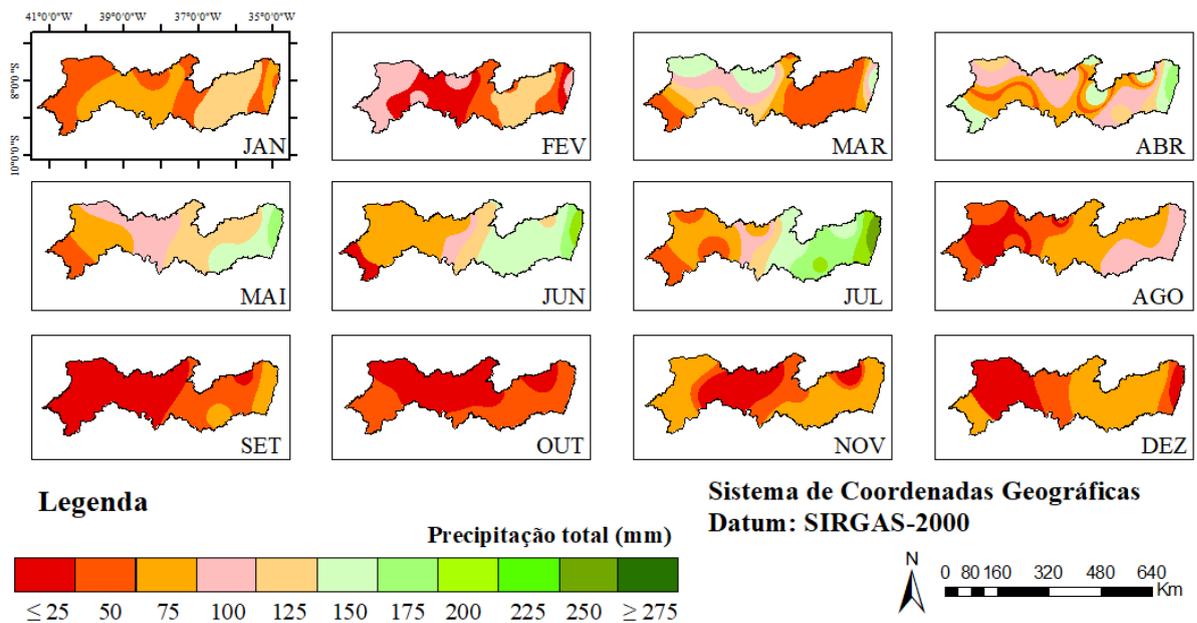


Figura 13. Precipitação acumulada mensal obtida a partir do SM2RAIN-GPM para o Estado de Pernambuco.

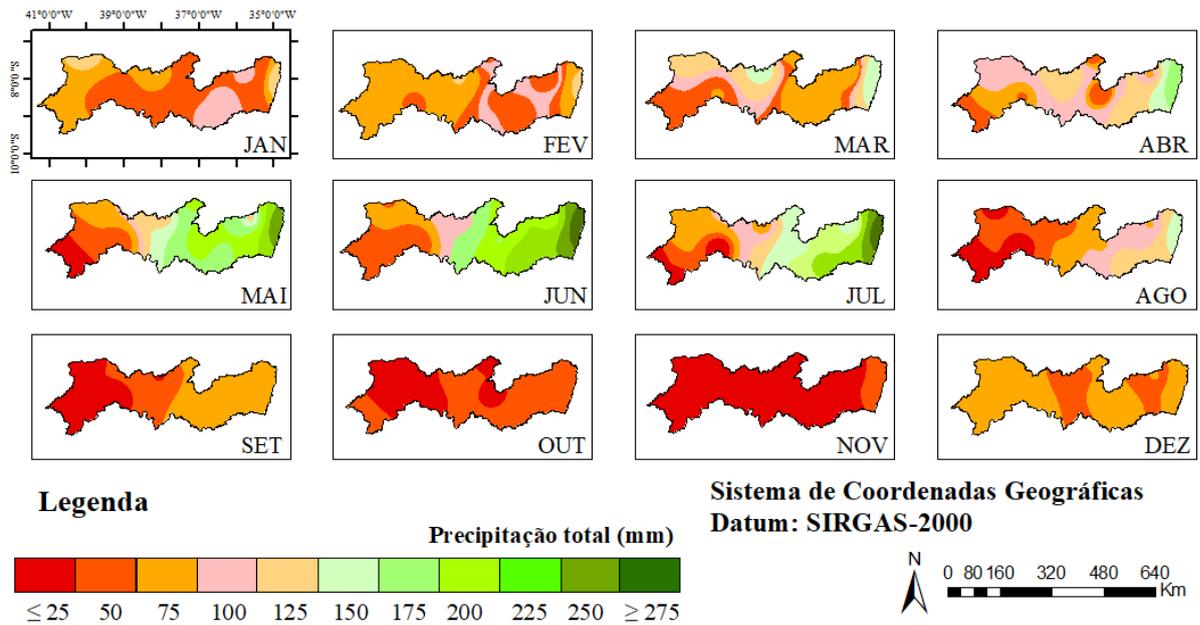


Figura 14. Precipitação acumulada mensal obtida a partir do SM2RAIN-ASCAT para o Estado de Pernambuco.

Para análises espaciais, quanto mais densa for a rede de postos pluviométricos e maior for a série, melhores serão os resultados obtidos. Por mais que o SM2RAIN-CCI tenha um período maior que pode ser calculado e avaliado, essa diferença na escala temporal não influenciou tanto no resultado do que foi avaliado no curto espaço de tempo dos outros satélites. Os resultados corroboraram com boa parte do que foi analisado pelo ASCAT e GPM, tendo os meses mais chuvosos em abril, junho, julho e os meses mais secos em outubro, novembro e dezembro.

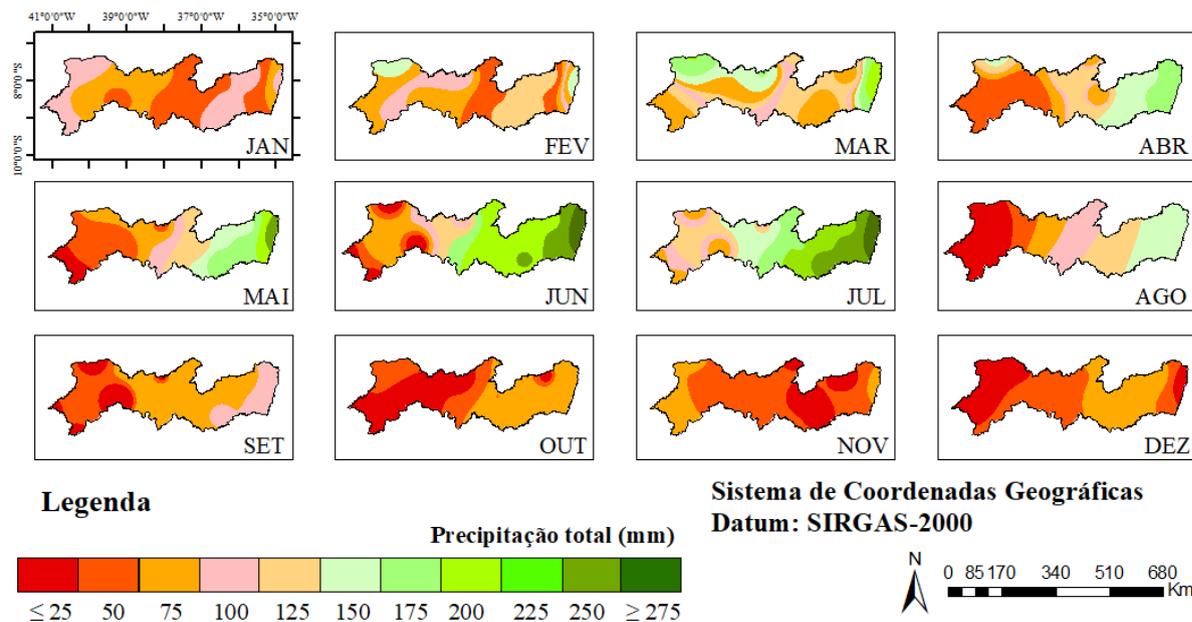


Figura 15. Precipitação acumulada mensal obtida a partir do SM2RAIN-CCI para o Estado de Pernambuco.

As figuras 16, 17 e 18 ilustram as anomalias da precipitação obtidas pelos algoritmos. Os mapas deixam evidente que o algoritmo consegue expressar os eventos de seca de forma satisfatória, inclusive em escala de mesorregião, em concordância com relatos presentes na literatura. O ano de 2012 foi identificado como o mais grave para o período, seguido pelo biênio 2015 – 2017, que foi severamente afetado pelo déficit hídrico iniciado em 2012, onde a região inserida na Zona da Mata e Litoral sentiu os impactos da escassez hídrica vivenciada nesse período.

Souza et al. (2019) avaliaram a seca para o Estado de Pernambuco, entre o período de 2010 a 2017, utilizando o índice VCI calculado a partir do NDVI no qual foram encontradas anomalias positivas para os anos de 2010 e 2011, indicando uma melhor condição para a vegetação, principalmente para as regiões do Agreste e Sertão. Já para o período de 2012 a 2017 mostraram anomalias iguais ou menor que -50% , indicando um estresse da vegetação para esse período, sendo os anos de 2012, 2013 e 2017 os que mostraram valores mais acentuados de seca.

O Centro de Estudos e Pesquisas em Engenharia e Defesa Civil da Universidade Federal de Santa Catarina (2013), revelou que durante os anos de 1991 a 2012 ocorreram 1.308 registros oficiais de estiagem e seca em Pernambuco, sendo o ano de 2012 o que apresentou a maior frequência anual de desastres causados por esse fenômeno no estado. O estudo reforça que as

consequências socioeconômicas não têm relação somente com a magnitude do fenômeno natural, mas também podem estar relacionadas a outras questões e evidência que o registro desses eventos em meses importantes para a agricultura pode resultar em consequências ainda mais graves.

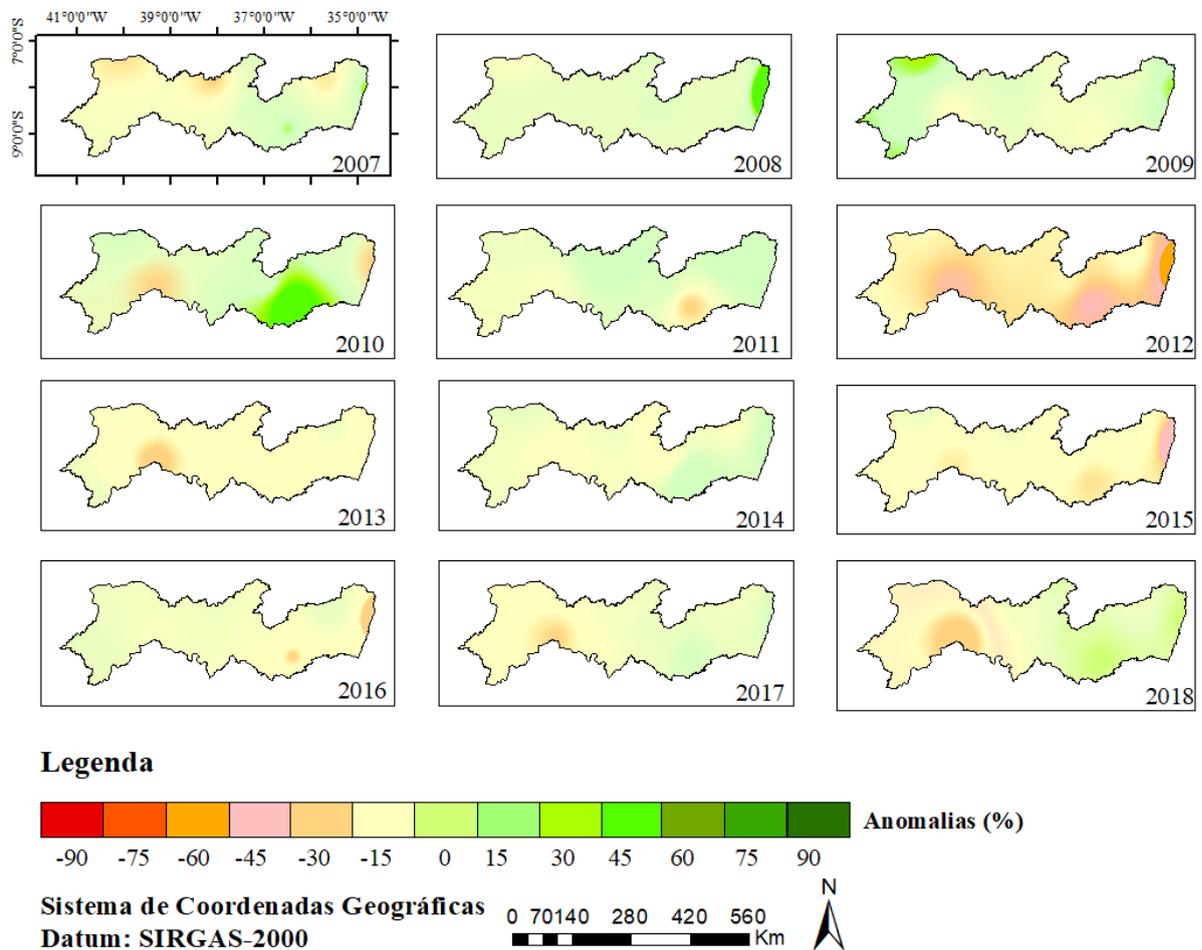


Figura 16. Anomalias da precipitação obtidas pelo algoritmo SM2RAIN-GPM para o período de 2007 a 2018.

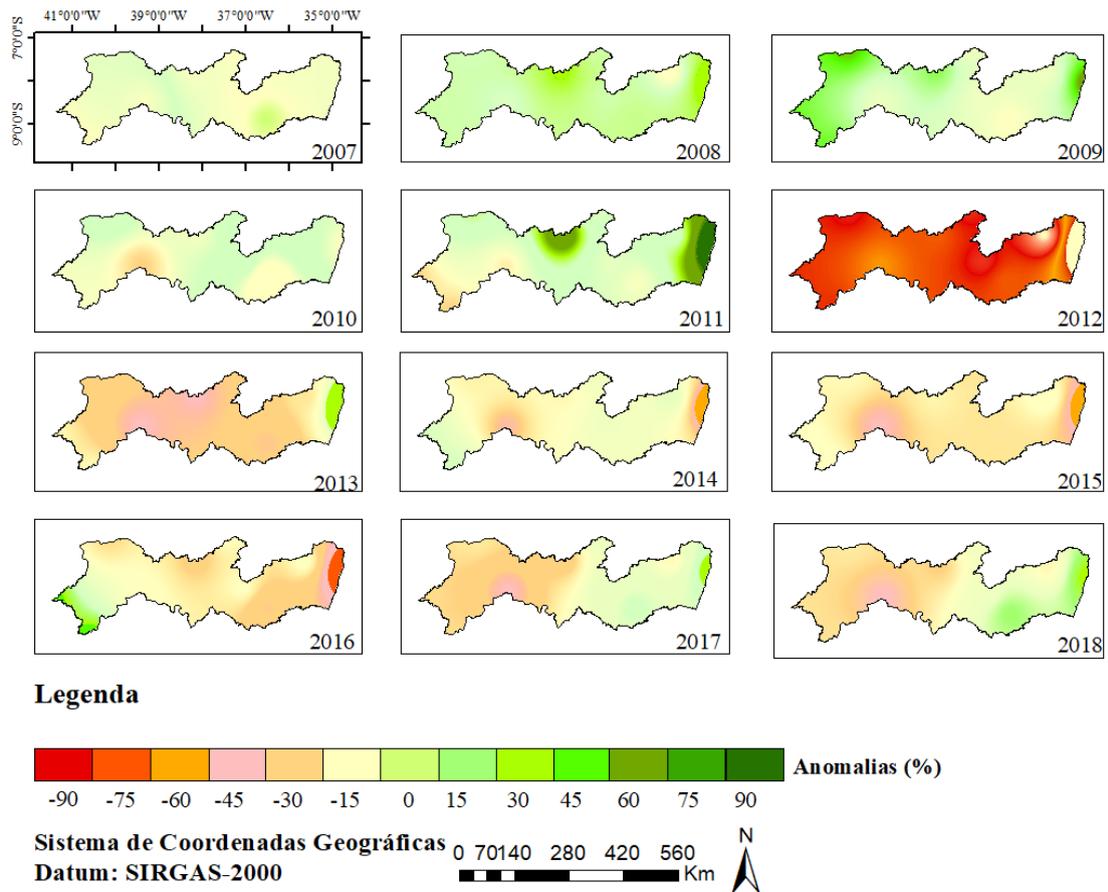


Figura 17. Anomalias da precipitação obtidas pelo algoritmo SM2RAIN-ASCAT para o período de 2007 a 2018.

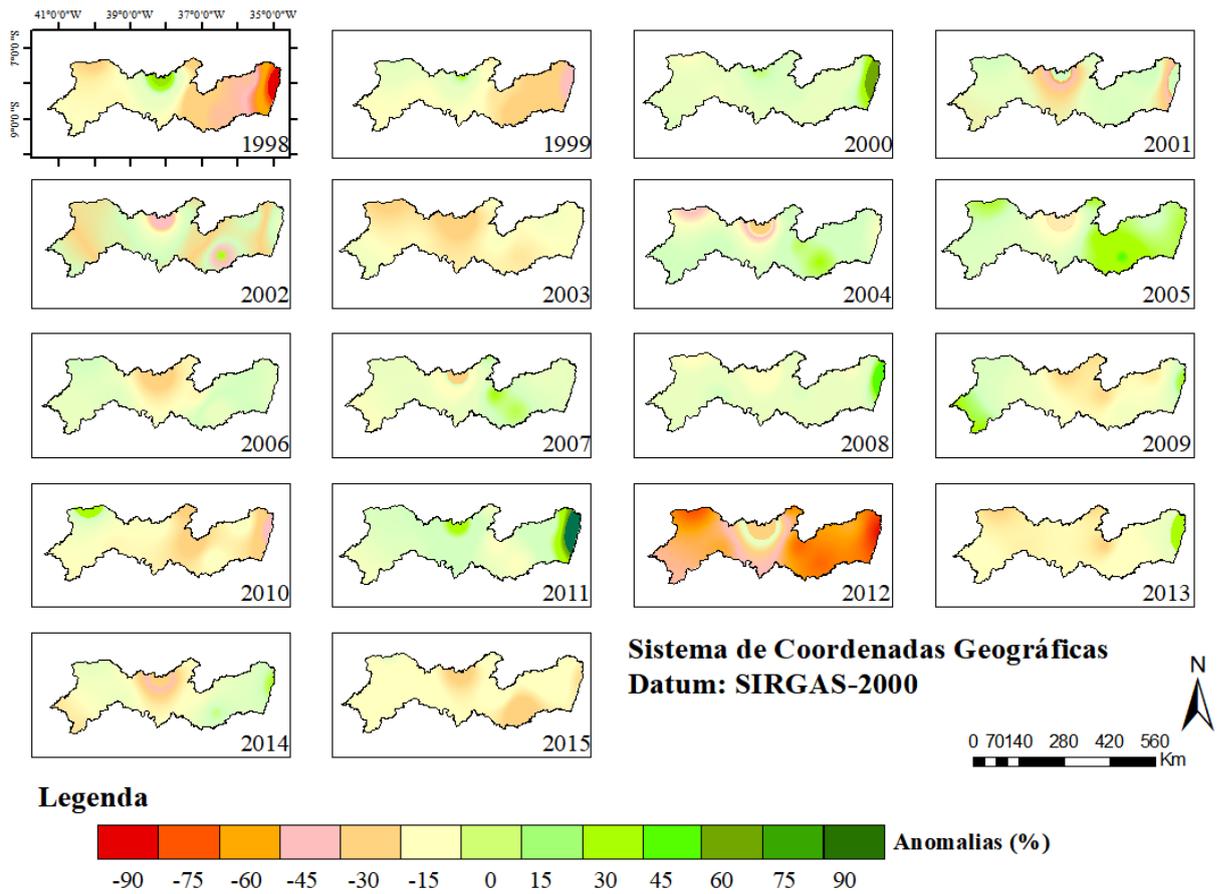


Figura 18. Anomalias da precipitação obtidas pelo algoritmo SM2RAIN-CCI para o período de 1998 a 2015.

4. CONCLUSÕES

Conclui-se que o desempenho do SM2RAIN-ASCAT, GPM e CCI são bastante similares no estado de Pernambuco, embora o ASCAT tenda a ser levemente superior, com base nas métricas estatísticas. Os dois primeiros satélites apresentam a característica de subestimar a precipitação nas mesorregiões, enquanto o último tende a superestimar. No entanto, devido aos elevados coeficientes de correlação, que indicam grande similaridade temporal nos dados, a remoção da tendência é possível e recomendada para correção dos valores estimados, especialmente quando se deseja realizar preenchimento de falhas ou aplicações hidrológicas.

No caso do Estado de Pernambuco, o SM2RAIN mostrou resultados satisfatórios para avaliação da seca baseada em anomalias, indicando que o não de 2012 foi o mais seco no período de 1998 a 2018. Dessa forma, é possível utilizar os dados do algoritmo com maior segurança, isoladamente ou em conjunto. Porém, por ser um algoritmo recente, não é possível afirmar que esse mesmo padrão de estimativas da precipitação será mantido nos próximos anos, de modo que novos estudos, inclusive de comparação com outros instrumentos orbitais, são recomendados para continuar acompanhando o desempenho e checar a sua aplicabilidade em estudos relacionados à gestão e gerenciamento de recursos hídricos.

**CAPÍTULO III: USO DA UMIDADE DO SOLO ESTIMADA POR SATÉLITE NA
DETECÇÃO DE SECAS EM PERNAMBUCO, NORDESTE DO BRASIL**

USO DA UMIDADE DO SOLO ESTIMADA POR SATÉLITE NA DETECÇÃO DE SECAS EM PERNAMBUCO, NORDESTE DO BRASIL

RESUMO: A umidade do solo é uma variável-chave nos ciclos de água e energia em escala global. No entanto, devido à escassez de dados de superfície, diversos satélites vêm sendo utilizados como fonte alternativa nos últimos anos. Esse estudo tem o objetivo de validar o produto de satélite global que monitora a umidade do solo, o Soil Moisture and Ocean Salinity (SMOS), com uma resolução de 1 km (versão L4), visando a estimativa de seca agrícola. Para a validação, foram consideradas estações meteorológicas da Agência Pernambucana de Águas e Clima (APAC) e do Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN) instaladas em todo o estado de Pernambuco. A seca foi estimada com base no Soil Water Deficit Index (SWDI), que utiliza propriedades físicas do solo para indicar quando as plantas estão em condições de déficit hídrico. Com o objetivo de avaliar o desempenho dos dados gerados pelo SWDI, foi calculado o índice Atmospheric Water Deficit (AWD) com dados de oito estações convencionais do INMET e os índices de seca agrícola Índice de Condição de Umidade do Solo (SMCI), Índice de Condição de Temperatura (TCI) e Índice de Condição de Vegetação (VCI). O SMOS-L4 apresentou bom desempenho em todo estado de Pernambuco com coeficiente de correlação acima de 0,80, tanto mensalmente como anualmente em comparação com os dados de umidade in situ das estações do CEMADEN e da APAC. O SWDI, gerado com dados orbitais, apresentou boa correlação com os índices de seca VCI, TCI e SMCI e com o AWD calculado com dados in situ, tendo coeficiente de correlação médio igual a 0,70 nas estações avaliadas, indicando o potencial do SMOS-L4 para o monitoramento da seca agrícola. Portanto, é possível utilizar imagens de *dowscaling* do SMOS como alternativa para calcular índices para monitorar de forma contínua e poder emitir alerta que podem favorecer a mitigação de impactos decorrentes de eventos extremos de seca, evidenciando condições em que a demanda hídrica é elevada.

Palavras-chave: SMOS-L4, seca agrícola, conteúdo de água no solo.

USE OF SATELLITE ESTIMATED SOIL HUMIDITY IN DRY DETECTION IN PERNAMBUCO, NORTHEAST OF BRAZIL

ABSTRACT: Soil moisture is a key variable in water and energy cycles on a global scale. However, due to the scarcity of surface data, several satellites have been used as an alternative source in recent years. This study aims to validate the global satellite product that monitors soil moisture, Soil Moisture and Ocean Salinity (SMOS), with a resolution of 1km (version L4), aiming at estimating agricultural drought. For validation, meteorological stations of the Pernambuco and Water and Climate Agency (APAC) and the National Center for Monitoring and Natural Disaster Alerts (CEMADEN) installed throughout the state of Pernambuco were considered. The drought was estimated based on the Soil Water Deficit Index (SWDI), which uses physical properties of the soil to indicate when the plants are in water deficit conditions. In order to evaluate the performance of the data generated by the SWDI, the Atmospheric Water Deficit (AWD) index was calculated with data from eight conventional INMET stations and the agricultural drought indices Soil Moisture Condition Index (SMCI), Temperature Condition (TCI) and Vegetation Condition Index (VCI). The SMOS-L4 performed well in the entire state of Pernambuco with a correlation coefficient above 0.80, both monthly and annually compared to the in situ humidity data from CEMADEN and APAC stations. The SWDI, generated with orbital data, showed a good correlation with the dryness indexes VCI, TCI and SMCI and with the AWD calculated with data in situ, with an average correlation coefficient equal to 0.70 in the evaluated stations, indicating the potential of SMOS -L4 for monitoring agricultural drought. Therefore, it is possible to use downscaling images from SMOS as an alternative to calculate indices to continuously monitor and be able to issue alerts that can favor the mitigation of impacts resulting from extreme drought events, showing conditions in which water demand is high.

Keywords: SMOS-L4, agricultural drought, soil water content.

1. INTRODUÇÃO

A umidade do solo é o conteúdo de água presente no espaço poroso do solo (micro e macroporos) (KITIĆ e CRNOJEVIĆ-BENGIN, 2013). A disponibilidade de água no solo é variável conforme as condições climáticas, tipo de solo e manejo (RICTHIE, 1981). Tem relevância em diversas aplicações, como na agricultura, para o gerenciamento da irrigação; nos processos hidrológicos, para previsão de enchentes e secas; e em alguns desastres geológicos, como movimentos de massa, onde a umidade do solo pode ser considerada um dos fatores desencadeadores de tais eventos (MAFFRA e CENTENO, 2016).

As técnicas de medidas da umidade do solo (gravimétricas, tensiométricas, higrométricas) são pontuais, escassas e mal distribuídas, não considerando a variabilidade espacial e temporal típica deste parâmetro (MAFFRA e CENTENO, 2016). Para contornar essas dificuldades o sensoriamento remoto aparece como uma alternativa para o monitoramento rotineiro da umidade do solo em grandes escalas e de forma contínua (WANG e QU, 2009).

Atualmente, instrumentos de sensoriamento remoto, especialmente sensores de sensoriamento remoto por micro-ondas, são amplamente utilizados para produzir um padrão global de umidade do solo em grandes escalas, como o Soil Moisture and Ocean Salinity (SMOS) (KERR et al., 2012). A grande vantagem dos sensores de micro-ondas é a possibilidade de obter dados da superfície do solo mesmo em presença de nuvens e vegetação. Além disso, o sensor possui a capacidade de realizar observações durante o dia ou à noite (VELPURI et al., 2015).

Porém, a maioria dos produtos de satélite SM tem uma resolução relativamente grosseira (dezenas de quilômetros). Nesta resolução, os produtos são difíceis de usar em modelo hidrológico regional e na previsão de riscos, como detecção de inundações e secas regionais (PENG et al., 2017). A aplicação de um método de *downscaling* para gerar um mapa SM de alta resolução pode ser uma solução eficiente para esse desafio. Malbêteau et al. (2016) destacam que o *downscaling* também pode ajudar a resolver o problema de incompatibilidade de escala entre as medições *in situ* e as recuperações de umidade do solo de satélite para validação.

Os métodos de *downscaling* desagregam a umidade do solo derivada de sensores micro-ondas para maior resolução temporal ou espacial usando a sinergia de informação visível, infravermelha e térmica (PILES et al., 2016). Piles et al. (2011, 2014) utilizaram uma

metodologia semiempírica onde o índice de vegetação da diferença normalizada (NDVI) e a temperatura da superfície terrestre (LST) de alta resolução do MODIS são combinadas com temperaturas de brilho de SMOS de alta precisão para derivar a umidade do solo em resolução de 1 km (SMOS-L4 versão 3.0).

Todavia, qualquer aplicação com dados de umidade do solo oriundo de sensoriamento remoto requer validação prévia, que consiste na comparação do dado estimado com um referencial mensurado em superfície. Validações de dados destinados a diversas aplicações, inclusive estudos de seca, vêm sendo realizadas em várias partes do globo (SCAINI et al., 2015; XU et al., 2018).

Existem diversas formas de estimar a seca utilizando dados de umidade do solo obtido por sensores orbitais. As metodologias mais tradicionalmente utilizadas são baseadas apenas na série do próprio sensor, que quanto maior for, mais precisa será nas avaliações. Essas técnicas são baseadas em cálculos de anomalias (PENG et al., 2015; SOUZA et al., 2018). No entanto, outros métodos consistem em utilizar dados adicionais que tragam maior representatividade do índice obtido, especialmente do ponto de vista agrícola. Como exemplo, tem-se o Soil Water Deficit Index (SWDI), que considera dados adicionais de propriedades do solo, como capacidade de campo, ponto de murcha e capacidade de água disponível para dar um indício de que a quantidade de água no solo é suficiente ou não ao suprimento vegetal (BAI et al., 2018; MARTÍNEZ-FERNÁNDEZ et al., 2016).

Diante disso, o objetivo desse estudo foi em validar dados de sensoriamento remoto obtido pelo produto SMOS-BEC e verificar a sua aplicabilidade utilizando o índice SWDI para o monitoramento de seca agrícola no estado de Pernambuco.

2. MATERIAL E MÉTODOS

2.1 Área de estudo

O estudo foi desenvolvido no Estado de Pernambuco (Figura 19), localizado na região Nordeste do Brasil e ocupa uma área de cerca de 98.938 km². Conforme o meio físico, o estado se divide em cinco mesorregiões: Região Metropolitana do Recife (RMR), Zona da Mata, Agreste, Sertão Pernambucano e Sertão do São Francisco.

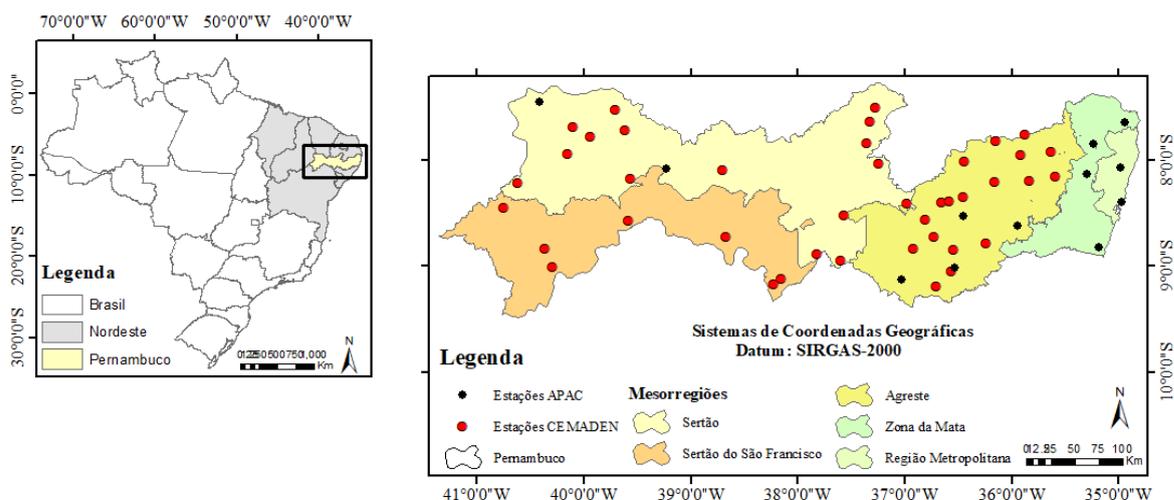


Figura 19. Distribuição espacial das estações de umidade do solo no Estado de Pernambuco.

A Figura 20 ilustra o mapa de solos mais expressivos do Estado de Pernambuco que são: Neossolos, Planossolos, Argilossolos, Nitossolos e Luvisolos. Os solos situados no Agreste do Estado encontram-se ocorrências Planossolos, Neossolos e Nitossolos, que têm no geral potencial de aproveitamento econômico com pastagem e com agricultura. As terras localizadas nas mesorregiões do São Francisco e Sertão pernambucano predominam os Neossolos, Latossolos, Argilossolos e Luvisolos.

A região localizada na mesorregião da Mata, apresenta solos mais desenvolvidos (Latosolos, Nitossolos, Luvisolos e Argilossolos), esses solos são cultivados com cana-de-açúcar e pequenas áreas de pastagens (CONDEPE/FIDEM, 2006; EMBRAPA, 2006).

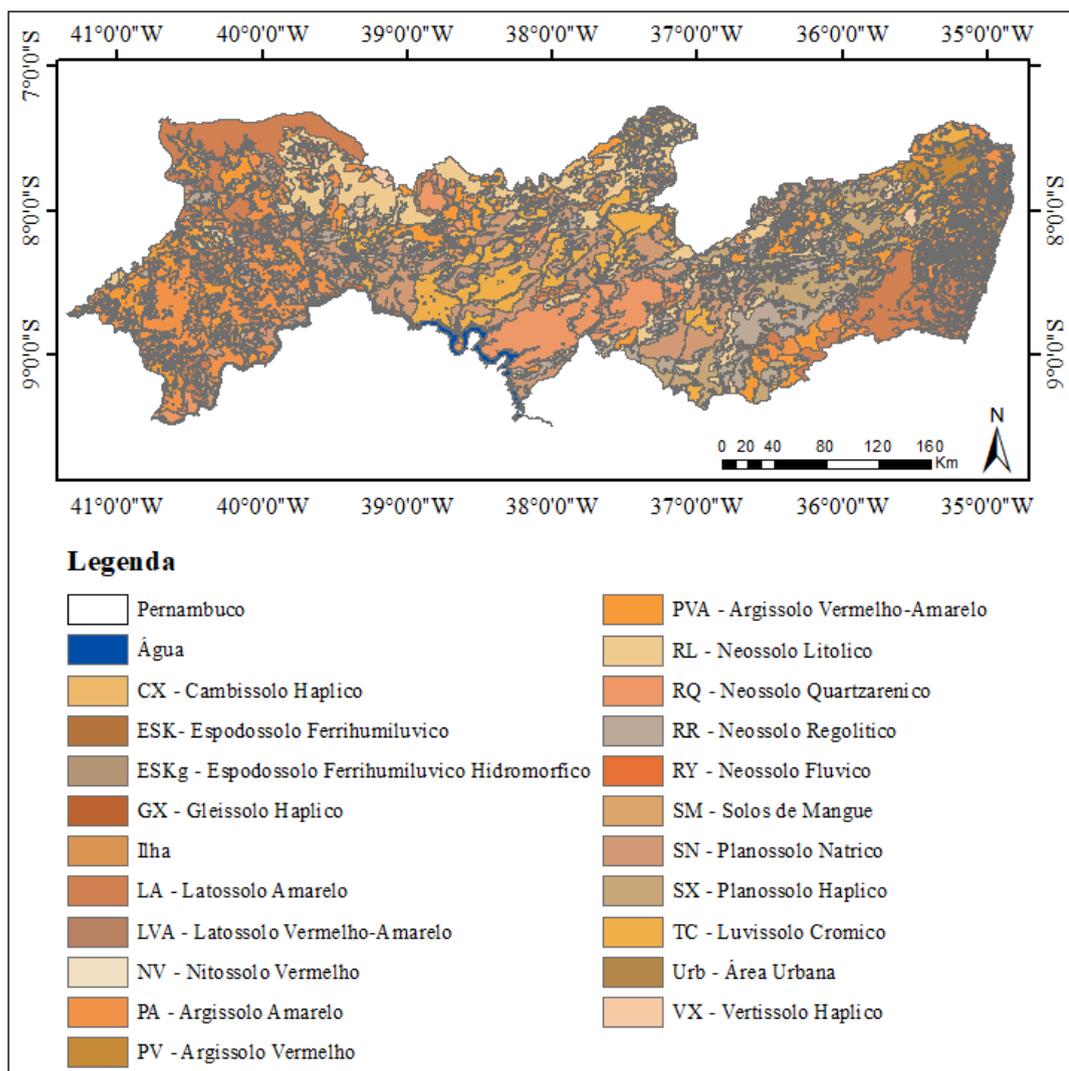


Figura 20 - Mapa de solos para o Estado de Pernambuco realizado pelo ZAPE, com classificação dos solos adaptadas conforme a nomenclatura da EMBRAPA (2006).

O clima predominante é tropical, onde as temperaturas são elevadas durante todo o ano, com temperaturas médias anuais que variam entre 25°C a 31°C. As precipitações pluviométricas não são uniformemente distribuídas, sendo mais abundantes no litoral, reduzindo-se à proporção que se dirigem para oeste. No sentido leste-oeste, o estado alonga-se consideravelmente, chegando a 784 km de extensão. Essa projeção para oeste faz com que cerca de 80% de seu território esteja situado em região de clima semiárido, onde as chuvas são poucas e irregulares, ocorrendo, periodicamente, o fenômeno das secas (CONDEPE/FIDEM, 2006).

Em Pernambuco há uma rede densa de plataformas de coleta de dados de umidade do solo, onde foram utilizadas 49 estações do Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN) e 12 estações da Agência Pernambucana de Águas e Climas

(APAC), totalizando 61 pontos de monitoramento em superfície em todo estado. Essas estações foram utilizadas para a validação dos dados obtidos pelos estimados do SMOS-L4. A validação é requerida antes que os dados orbitais sejam utilizados para outras finalidades, como a modelagem de secas.

2.2 Dados da APAC

A APAC possui doze estações de umidade do solo, distribuídas no Estado, instaladas a partir do ano de 2013. O sensor dessas estações é do modelo PR2/4 fabricado pela Delta-TDevices, que trabalham com precisão de $0,04 \text{ m}^3.\text{m}^{-3}$, e que permite a coleta em três profundidades diferentes (10, 20 e 40 cm). O sensor instalado na vertical coleta a umidade do solo e na horizontal a temperatura, que possui precisão entre 0°C e 40°C .

O tempo de resposta do equipamento é menor que 0,5 segundos, mas os valores coletados são horários. Para essa pesquisa, o intervalo de tempo considerado foi a média diária e mensal. Também foi utilizada apenas a umidade do solo à 10 cm de profundidade, já que a finalidade é a validação dos dados do satélite SMOS, visto que o satélite só pode obter informações da superfície do solo.

2.3 Dados do CEMADEN

As redes do CEMADEN cobrem o semiárido brasileiro com medidas coletadas desde 2015 de dois conjuntos de equipamentos: estações Aqua e Agro, ou seja, o primeiro tipo por sensores instalados em duas profundidades (10 e 20 cm) e o segundo em quatro profundidades (10, 20, 30 e 40 cm), ambos utilizando modelo EC-5 produzido pela Decagon Devices (precisão de $0,03 \text{ m}^3.\text{m}^{-3}$).

Os sensores podem coletar dados a cada fração de segundos, mas eles foram definidos para este trabalho em intervalos de tempo diários. Para a análise, 42 estações das redes do CEMADEN e 12 da APAC foram selecionadas para caracterizar a umidade do solo no estado de Pernambuco. Para ambas as redes, foram comparados os dados do SMOS-L4 com uma resolução espacial de 1 km considerando apenas valores coletados na profundidade à 10 cm.

2.4 Dados SMOS-L4

O satélite Soil Moisture Ocean Salinity (Umidade do Solo e Salinidade Oceânica SMOS) da ESA foi lançado novembro de 2009 e mede a energia emitida pela superfície da terra na banda L de micro-ondas (1,4 GHz) na polarização HV desde 2010 (SILVA, 2011; KERR et al., 2016). No entanto, sua resolução espacial (cerca de 40-50 km) dificulta estudos em que os dados SMOS sejam aplicados em escala local ou regional. Uma linha de pesquisa na BEC (Barcelona Expert Center) desenvolveu melhorias dos algoritmos de fusão de dados para fornecer umidade do solo baseado em SMOS por *downscaling* (1 km). O conhecimento preciso do estado de umidade do solo nesta escala é essencial para a gestão da água, monitoramento de secas e/ou previsão de cheias.

A abordagem de *downscaling* deste novo produto SMOS-L4 usa um modelo linear que combina temperatura de brilho do SMOS, o NDVI e LST do MODIS para derivar a umidade do solo em escala fina. Dependendo das condições e tipos climáticos da superfície da terra, uma ligação entre a umidade do solo, NDVI e LST pode ser estabelecida para uma região de interesse (PILES et al., 2011).

Como o SMOS e o Terra/Aqua do MODIS tem resoluções temporais diferentes, presume-se que a umidade do solo persiste por várias horas antes e depois da próxima passagem do SMOS (PABLOS et al., 2014). A fórmula de ligação resultante é realizada para as duas resoluções, SMOS (~ 40 km) e de MODIS (1 km). A baixa resolução do modelo é executada primeiro para estimar os coeficientes de correspondência e então esses coeficientes são usados para calcular a umidade do solo em alta resolução. No novo produto SMOS-L4 SM, os dados ERAInterim LST são implementados no espaço MODIS LST/NDVI.

A vantagem é que as estimativas SMOS-L4 são independentes da cobertura de nuvem, portanto, a frequência e a precisão das medições de umidade do solo aumentam em comparação com a observação in situ (PILES et al., 2015; KHODAYAR, COLL, LOPEZ-BAEZA, 2019). Os dados estão disponibilizados no portal BEC (<http://cp34-bec.cmima.csic.es/data/data-access/>).

O SMOS possui duas órbitas, ascendente e descendente (LOUVET, et al., 2015). Na órbita ascendente (o sensor se move no sentido sul para o norte) passa no equador às 6 horas da manhã e na descendente (o sensor se move no sentido norte para o sul) às 6 horas da noite (PILES et al., 2014; SMOS-BEC, 2016). Neste trabalho foi realizada a união dessas duas órbitas de três formas diferentes. A primeira situação ocorreu com o registro de dados em ambas as órbitas, sendo realizada a média desses valores medidos. Quando o registro foi feito em apenas

em uma das órbitas, por ausência de dados na outra órbita, foi considerado apenas o valor disponível. E, a terceira situação foi caracterizada por não possuir valor em ambas as órbitas, quando o valor diário de umidade do solo foi considerado como falha.

2.5 Validação dos dados

As bases de dados que foram utilizadas das estações do CEMADEN e da APAC cobriu o período de julho de 2015 a abril de 2019. Devido à limitação no período de coleta de dados, optou-se por usar essa escala temporal para a pesquisa em virtude da maior consistência das informações, menor número de falhas e igualar o intervalo de tempo entre as estações.

As validações realizadas pelo método pixel-estação foram em todo Estado de Pernambuco, utilizando 54 estações nesse procedimento, sendo 12 estações da APAC e 42 estações do CEMADEN. As validações ocorreram relacionando as células, representada pelos pixels na resolução espacial de 1 km do SMOS-L4 e os pontos, representado pelas estações de umidade do solo da APAC e do CEMADEN. Para a extração dos dados de umidade do solo do SMOS onde estavam localizadas as estações foram utilizadas uma rotina criada no *software* OpenGrADS, versão 2.0.a9. Nos casos em que foi identificado mais de uma estação localizada em um mesmo pixel, realizou-se a média dos valores observados e posteriormente comparados ao valor do pixel.

As validações foram realizadas em escala diária e mensal, considerando que diversas aplicações, incluindo modelagem de seca e hidrológica, necessitando de dados mensais de umidade do solo. Antes das validações, os dados adquiridos pelos satélites passaram por uma triagem que removeram aquelas leituras consideradas inconsistentes ou inapropriadas, segundo os critérios dos desenvolvedores. O satélite possui variáveis específicas que auxiliam na detecção de dados inconsistentes e tomada de decisões.

Diferentes métricas de erro vêm sendo utilizadas para realizar as comparações estatísticas entre dados provenientes de diferentes sensores e dados obtidos em campo. Não apenas entre sensores e estações em superfície são realizadas as comparações, mas também entre os próprios satélites, visando verificar qual apresenta melhor desempenho (AL-YAARI et al., 2014; ANAM et al., 2017; NICLOS et al., 2016; WU et al., 2016).

Assim como realizado por Wu et al. (2016), nesta pesquisa se comparou os dados de umidade do solo de órbitas ascendente e descendente (em conjunto) do sensor SMOS com os dados obtidos pelas redes de monitoramento em campo. Quando uma estação esteve inserida na zona de transição ou intersecção entre dois, ou mais pixels, foi utilizada a função ‘k-Nearest Neighbor (kNN)’ para buscar o (pixel) vizinho mais próximo à estação.

2.6 Índices estatísticos

As principais métricas de erro, para avaliar o desempenho da validação de dados obtidos por sensoriamento remoto versus *in situ*, foram adotadas nesta pesquisa, que são elas: o coeficiente de correlação de Pearson (CC), desvio da raiz quadrada média (RMSD), tendenciosidade ou viés (Bias), desvio da raiz quadrada média não-tendenciosa (ubRMSD).

2.6.1 Coeficiente de correlação de Pearson (CC):

Avalia o grau de concordância entre os dados *in situ* e os dados do satélite SMOS (Equação 11). O coeficiente de correlação foi classificado segundo os critérios adotados por Shimakura (2006): muito fraco ($\pm 0,0$ a $\pm 0,19$), fraco ($\pm 0,20$ a $\pm 0,39$), moderado ($\pm 0,40$ a $\pm 0,69$), forte ($\pm 0,70$ a $\pm 0,89$) e muito forte ($\pm 0,90$ a $\pm 1,0$).

$$CC = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad (11)$$

em que: CC é o coeficiente de correlação de Pearson, adimensional; x_1, x_2, \dots, x_n , e y_1, y_2, \dots, y_n ; são os valores medidos de ambas as variáveis. Esse coeficiente varia entre -1 e 1, quanto mais próximo de 1 melhor será a correlação entre as amostras, podendo ser positiva ou negativa. O primeiro caso acontecerá se à medida que o x crescer o y também crescer e será negativa caso à medida que x crescer o y decrescer. Já se r for igual a zero, não existirá nenhuma associação linear (LIMA et. al., 2012; SHIMAKURA, 2006).

2.6.2 O viés (bias):

O viés é usado para medir a tendência do satélite em superestimar ou subestimar a umidade do solo em relação aos dados observados. Este critério pode ser afetado por erros

negativos e positivos com a mesma magnitude que resultam em uma compensação pelos erros, e quanto mais próximo o valor for de 0, melhor é o desempenho dessa estatística (Equação 12).

$$Bias = \frac{1}{N} \sum_{n=1}^N (in\ situ_n - sat\acute{e}lite_n) \quad (12)$$

2.6.3 Raiz do erro quadrático médio (RMSD):

A estatística é utilizada para quantificar diferenças entre as séries (satélite e campo), representando a magnitude média do erro (Equação 13). O uso do RMSD demonstra a magnitude mais realista de discordância entre os dados, quanto mais próximo o valor for de 0, melhor é o desempenho do modelo (KERR, 2007; LOEW e SCHELENZ, 2011).

$$RMSD = \sqrt{\frac{1}{N} \sum_{n=1}^N (in\ situ_n - sat\acute{e}lite_n)^2} \quad (13)$$

2.6.4 Desvio da raiz quadrada média não-tendenciosa (ubRMSD):

Como o RMSD pode ser gravemente comprometido se houver tendências na média e/ou diferenças na amplitude das flutuações dos dados (picos) fornecidos pelos satélites ao longo do tempo, pode se usar, também, o ubRMSD (Equação 14):

$$ubRMSD = \sqrt{\frac{1}{N} \sum_{n=1}^N \{[(sat\acute{e}lite_n - \overline{sat\acute{e}lite_n}) - (in\ situ_n - \overline{in\ situ_n})]^2\}} \quad (14)$$

As equações 14 e 12 estão relacionadas através de:

$$ubRMSD^2 = RMSD^2 - Bias^2$$

De modo que ubRMSD também pode ser representado como (Eq. 15):

$$ubRMSD = \sqrt{RMSD^2 - Bias^2} \quad (15)$$

2.7 Índices de seca

Vários métodos que utilizam dados de umidade do solo obtido por sensoriamento remoto, especialmente baseados em micro-ondas, vêm sendo utilizados para estudos de seca por índices. Sánchez et al. (2016) destacam que os índices de seca são usados para identificar, classificar e monitorar esse fenômeno, permitindo a avaliação quantitativa da intensidade, duração e extensão espacial de condições climáticas anômalas, portanto, dão suporte a sistemas de tomada de decisão.

Nesta pesquisa, trabalhou-se com o Soil Water Deficit Index (SWDI). O SWDI é um índice que pode ser aplicado para monitoramento de secas de curto prazo e tem sido considerado uma abordagem promissora ao incorporar as características físicas do solo para medir a disponibilidade de umidade do solo (SM) na zona radicular, dado que possui um maior significado do que outros índices de vegetação, variáveis climáticas e até mesmo alguns métodos baseados em SM (MARTÍNEZ-FERNÁNDEZ et al., 2016). Os resultados do SWDI foram comparados com outros índices de seca, tais como, o Atmospheric Water Deficit (AWD), Índice de Condição de Umidade do Solo (SMCI), Índice de Condição de Temperatura (TCI) e Índice de Condição de Vegetação (VCI).

2.7.1 Soil Water Deficit Index (SWDI)

Para o cálculo do SWDI, são necessários dados de propriedades físicas do solo, incluindo capacidade de campo, ponto de murcha permanente e capacidade de água disponível (CAD). O CEMADEN, durante a instalação de suas plataformas de coleta de dado, obteve esses parâmetros em cada ponto utilizando amostras deformadas, pelo método gravimétrico. Os dados referem-se a um valor médio representativo da camada de 0-40 cm, correspondente à profundidade de instalação das sondas de umidade do solo.

Os sensores remotos, no entanto, estimam a SM apenas em uma camada bastante superficial, de até 5 cm. Utilizar esses dados, obviamente, poderia induzir a erros de estimativa do SWDI. Foram utilizados dados globais de propriedades físicas do solo obtidos por reanálise através do Global Gridded Soil Information (SoilsGrid, <https://www.isric.org>). O projeto utiliza dados públicos de milhares de redes ao longo do globo, incluindo o Brasil, para compilar através

de dados matriciais diversas propriedades físicas e químicas dos solos. Os dados utilizados nesse estudo foram estimados por (ZHANG et al., 2018), a partir da rede global do SoilsGrid, utilizando funções de pedotransferência para uma grade de 1 km de resolução espacial.

O SWDI, sendo baseado na SM superficial, SM na capacidade de campo e SM na capacidade de água disponível, pode ser usado para capturar condições de seca agrícola através de princípios biofísicos. O SWDI é calculado da seguinte forma (Equação 16):

$$SWDI = \left(\frac{\theta - \theta_{CC}}{\theta_{CAD}} \right) \times 10 \quad (16)$$

em que θ é a SM à profundidade de 5 cm, θ_{CC} é a SM na capacidade de campo e θ_{CAD} é a SM correspondente à capacidade de água disponível. O valor de CAD é obtido através diferença da SM na capacidade de campo e ponto de murcha permanente. Os valores de SWDI são multiplicados por 10 para transformar o índice de uma mera magnitude fracionária para um intervalo com significado agrícola.

Quando o valor de SWDI é positivo, o solo tem excesso de água; quando é igual a zero, o solo encontra-se na capacidade de campo como conteúdo de água (sem déficit hídrico e sem seca). Os valores negativos indicam a seca agrícola e seu impacto dependerá da cultura e da fração da água total disponível no solo que pode ser esgotada da zona de raiz antes que ocorra o estresse de umidade. O déficit hídrico é absoluto (ponto de murcha permanente) quando o SWDI atinge valores ≤ -10 . Neste ponto, o conteúdo de água no solo está abaixo do limite inferior de água disponível para as plantas. O SWDI foi calculado diariamente, para cada pixel da grade do satélite selecionado para o estudo, durante os quatro anos de avaliação (2015 a 2019). Após isso, as imagens diárias foram agrupadas em composições médias de três dias, referentes à resolução espacial dos produtos.

2.7.2 Atmospheric Water Deficit (AWD)

O índice de seca agrícola AWD reflete as condições de armazenamento de água no solo e está intimamente associado com a umidade na camada superficial do solo. Por conta disso, o AWD é frequentemente comparado com o SWDI e serve como principal fonte de validação dos dados de seca obtidos por este índice (MARTÍNEZ-FERNÁNDEZ et al., 2016). Devido a essa

forte relação entre os dois índices, o AWD foi utilizado nesse estudo para comparações com o SWDI.

Novamente, o AWD (Equação 17) possui limitações em suas estimativas, já que utiliza dados de precipitação e evapotranspiração de referência (ET_o). Apesar de dados de precipitação em escala diária serem obtidos com facilidade por sensoriamento remoto, dados de ET_o ainda são difíceis de serem estimados através dessa técnica. Por conta disso, o AWD foi calculado pontualmente e não de forma espacial. Abordagem similar foi realizada por Pablos et al. (2017), que utilizaram dados de algumas estações em superfície para calcular o AWD e comparar diretamente com o SWDI obtido por sensoriamento remoto.

Apesar das discrepantes resoluções espaciais, os autores informam que essa estratégia é comumente utilizada na literatura para estudos de seca, onde dados orbitais de resolução espacial média e até mesmo baixa são comparados com bases de referência pontuais in situ. O AWD diário foi calculado utilizando dados de ET_o a partir de nove estações em superfície do INMET, com base na equação de Penman-Monteith, bem como dados de precipitação da mesma estação.

$$AWD_i = P_i - ET_i \quad (17)$$

em que, o P_i corresponde à soma (7 dias) da precipitação e ET_i denota a soma (7 dias) da evapotranspiração de referência para a semana. Para tornar as comparações possíveis, os dados de SWDI também foram acumulados a cada 7 dias.

2.8 Correlação de Pearson do SWDI com outros índices de seca

De forma a analisar o desempenho do SWDI em relação a sua percepção de seca foi realizada uma avaliação comparativa com outros índices agrícolas obtidos por sensoriamento remoto, o SMCI, VCI e TCI.

2.8.1 Índice de Condição de Umidade do Solo (SMCI)

O SMCI (Equação 16) é um índice de condição de umidade do solo que é mais adequado para monitorar as condições de seca de curto prazo em grandes regiões geográficas, quando

comparado a outros índices, o SMCI é particularmente sensível ao uso do solo (ZHANG et al., 2017). Zhang et al. (2017) identificaram uma boa correlação desse índice com a Precipitação Padronizada Índice (SPI) a curto prazo, no entanto, em regiões com presença de cobertura vegetal mais densa ou zonas mais úmidas essa correlação foi fraca, mas em áreas agrícolas ou menos vegetadas essa correlação com o SPI foi mais significativa.

Esse índice consiste em uma normalização da umidade do solo com valores relativos ao máximo absoluto (SSMmax) e ao mínimo (SSMmin) referente a todo o período de estudo. Dessa forma, obtém-se a normalização da umidade do solo variando de 0 (condição muito seca) a 100 (úmido, condição favorável) (SOUSA JÚNIOR e LACRUZ, 2015; ZHANG e JIA, 2013).

A escala de tempo utilizada para a obtenção desse índice foi mensal e o cálculo é feito conforme Equação 18:

$$SMCI = (SSM_i - SSM_{min}) / (SSM_{max} - SSM_{min}) \times 100 \quad (18)$$

onde:

- SSM_i é a umidade do solo relativa para o mês i;
- SSM_{min} é a umidade do solo relativa mínima referente a todo o período de estudo;
- SSM_{max} é a umidade do solo relativa máxima referente a todo o período de estudo.

2.8.2 Índice de Condição de Vegetação (VCI)

O Índice de Vegetação da Diferença Normalizada (NDVI) mostra a variação da condição da vegetação para uma região entre o intervalo de -1 a +1, mas não pode descrever durante um período específico (PANI et al. 2016). Kogan et al. (2003) introduziram o VCI para lidar com esse problema. Este índice normalizado indica a variação percentual da diferença entre o índice NDVI atual, o mínimo e máximo da série histórica em relação à faixa dinâmica (Equação 19). Um valor próximo a 100 por cento indica um período mais chuvoso, mas quando o valor cair abaixo de 40 por cento, uma condição de seca moderada começa a ser observada e quando o nível cai abaixo de 10, uma seca extrema é notada (BHUIYAN, 2008).

Para este estudo, foi utilizado a plataforma Google Earth Engine para aquisição dos dados de NDVI que foram coletados do MODIS (MOD13A2.006) com resolução temporal de 16 dias e espacial de 1000 metros, fornecido pela National Aeronautics and Space Administração (NASA). Antes dos cálculos, foi aplicado um filtro nas imagens para mascarar superfícies com água, pois, podem interferir nos resultados. Além disso, foi estabelecida outra filtragem selecionando, neste caso, apenas imagens com cobertura de nuvem inferior a 50%, limitando a ocorrência de dados espúrios. O cálculo do VCI foi realizado no *software* QGIS 3.2 para o período de 2015 – 2019.

$$VCI = (NDVI_i - NDVI_{min}) / (NDVI_{max} - NDVI_{min}) \times 100 \quad (19)$$

onde, $NDVI_{max}$ e $NDVI_{min}$ correspondem os valores extremos observados (pixel a pixel) por toda a série temporal.

2.8.3 Índice de Condição de Temperatura (TCI)

O TCI (Equação 20) é calculado de forma semelhante ao VCI, mas usando, em vez disso, a temperatura da superfície do solo (LST) como entrada. Vale ressaltar que eles são interpretados de formas diferentes, onde o VCI é interpretado na forma direta, pois valores baixos resultam em condições de estresse na vegetação. Na avaliação do TCI, quanto mais baixos seus valores, estes indicam valores altos e extremos de temperatura da superfície. Dessa forma, esses índices indicam condições de estresse térmico conforme KOGAN (1997). Nesta escala, valores tendendo a zero correspondem a áreas com baixos valores de NDVI. Para calcular o TCI, foram utilizadas imagens MODIS LST (MOD11A1.006) obtidas pela plataforma Google Earth Engine para o período de 2015 – 2019.

$$TCI = (LST_{max} - LST_i) / (LST_{max} - LST_{min}) \times 100 \quad (20)$$

onde, LST_{max} e LST_{min} correspondem os valores extremos observados (pixel a pixel) por toda a série temporal.

3. RESULTADOS E DISCUSSÃO

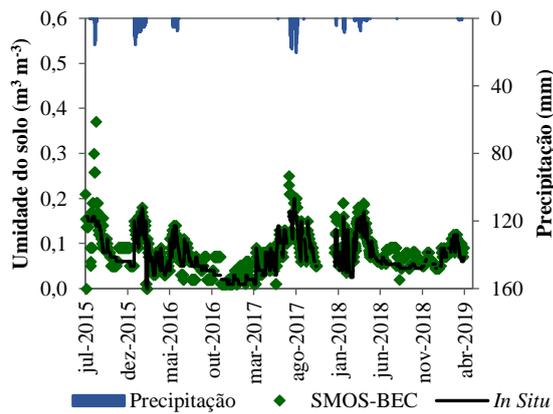
3.1 Avaliação e validação dos dados SMOS-L4 (1km) em Pernambuco

Para a validação dos dados de umidade do solo do SMOS-BEC com resolução de 1 km, foram comparados os valores obtidos por este sensor orbital e os medidos *in situ* pelas redes de observação da APAC e CEMADEN, adotando os intervalos de tempo diário e mensal. Para ilustrar melhor o desempenho do produto nas diferentes mesorregiões do Estado, foram selecionadas aleatoriamente duas estações que melhor representou a validação em dados diários.

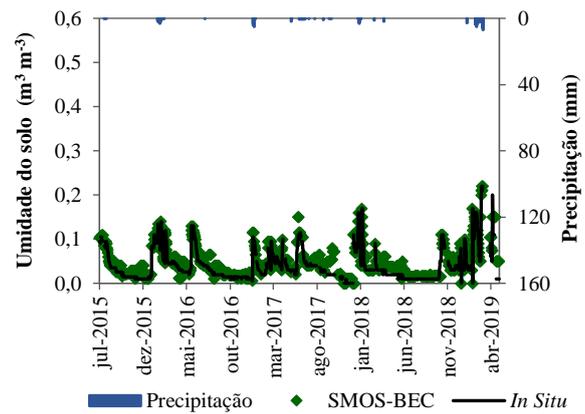
O SMOS-L4 conseguiu representar bem a variação temporal diária da umidade do solo (Figura 21), durante o período de julho de 2015 a abril de 2019. Os números também mostram que a SM por satélite respondeu bem aos eventos de precipitação, sendo sensíveis a qualquer variação desta. Para as estações da APAC, o melhor resultado foi observado para a estação de São Lourenço da Mata, onde os dados de satélite mostraram a mesma tendência dos dados *in situ*.

Já as estações do CEMADEN, onde estão localizadas em terras semiáridas (53% na região do Agreste e 47% na região do Sertão), tiveram muitos valores de umidade do solo em falta, como pode ser visto nas estações de Dormentes e Venturosa. Independentemente disso, os dados das estações estavam bem correlacionados aos dados de satélite. Vale destacar que nos dados originais foram encontrados pequenos picos aleatórios do SMOS, porém, grande parte deles foi filtrado e removido, conforme critérios baseados em interferência de radiofrequência e índice de qualidade dos dados, sugeridos pelo desenvolvedor.

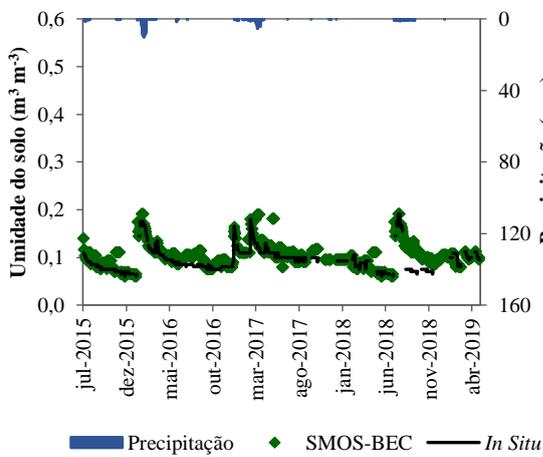
Segundo Portal et al. (2019), a validação e comparação de produtos de satélite SM usando dados de redes *in situ* é uma tarefa muito difícil, pois, muitas informações devem ser consideradas na interpretação dos resultados obtidos, principalmente que os valores contidos nesses pixels representam um valor médio de área, enquanto as medições *in situ* representam um ponto de dados isolado.



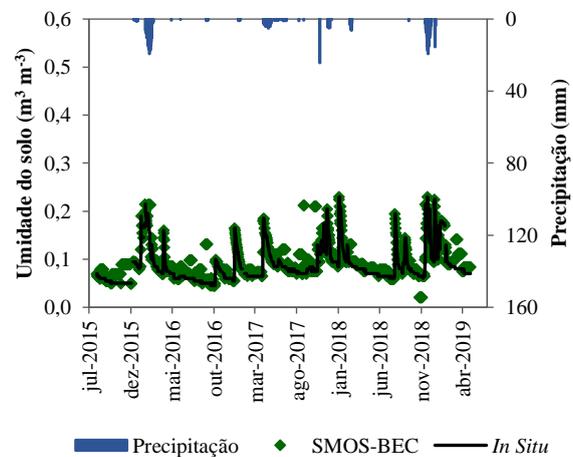
Arcoverde (Sertão)



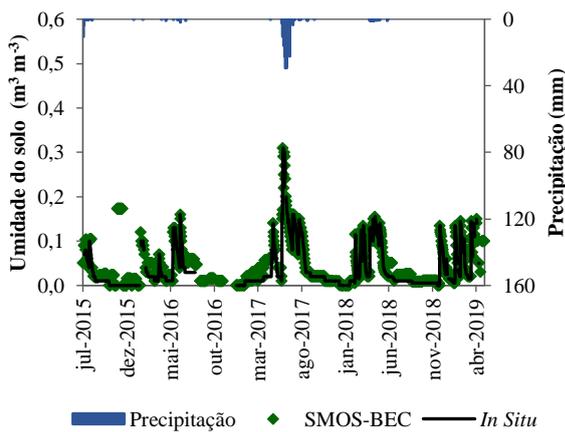
Ibimirim (Sertão)



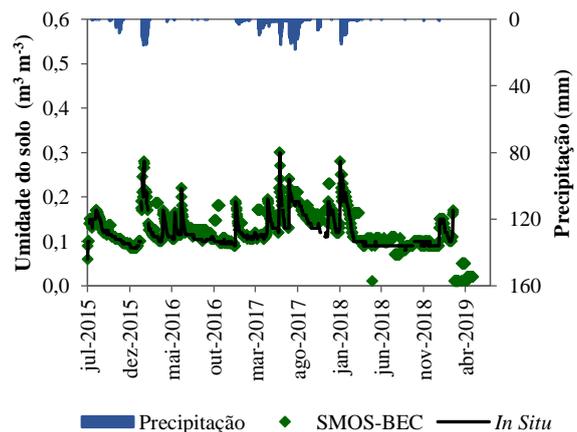
Dormentes (São Francisco)



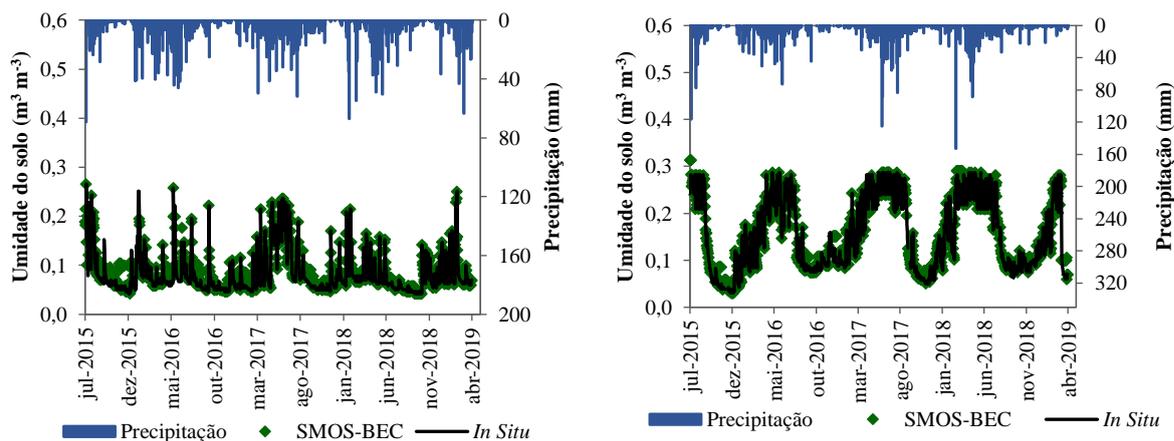
Petrolina 03 (São Francisco)



Venturosa (Agreste)



Brejo da Madre de Deus (Agreste)



Ipojuca (Zona da Mata)

São Lourenço da Mata (Zona da Mata)

Figura 21 - Comparação dos dados diários de umidade do solo medidos *in situ* e estimados por satélite (SMOS-BEC) para o período de julho de 2015 a abril de 2019.

Os diagramas de dispersão ou correlação (Figura 22), além de possibilitar detectar o grau de agregação entre os produtos orbitais e os dados mensurados *in situ*, também permitem identificar padrões de subestimativa ou superestimativa. As estações dos municípios de Ibimirim, Venturosa e São Lourenço da Mata tiveram os coeficientes de correlação igual ou superior a 0,90, e os pontos tenderam a estar sempre mais próximos da linha de ajuste (linha 1:1). Contudo, é importante destacar que todas as estações representaram bem as correlações do SMOS com os dados em campo.

Molero et al. (2016) validaram dados do SMOS em quatro áreas de estudo com características climáticas diferentes. Esses dados foram processados pelo algoritmo de desagregação fundamentado na mudança de escala física e teórica (DISPATCH), que gera dados de umidade do solo com resolução de 1 km. Os resultados mostraram que o produto melhorou a correlação espaço-temporal com medidas *in situ* para regiões semiáridas com variabilidade considerável do espaço de umidade do solo, devido à precipitação e irrigação. Nas regiões subúmidas, o desempenho do algoritmo não foi tão bom, exceto no verão, para o qual os resultados foram melhores.

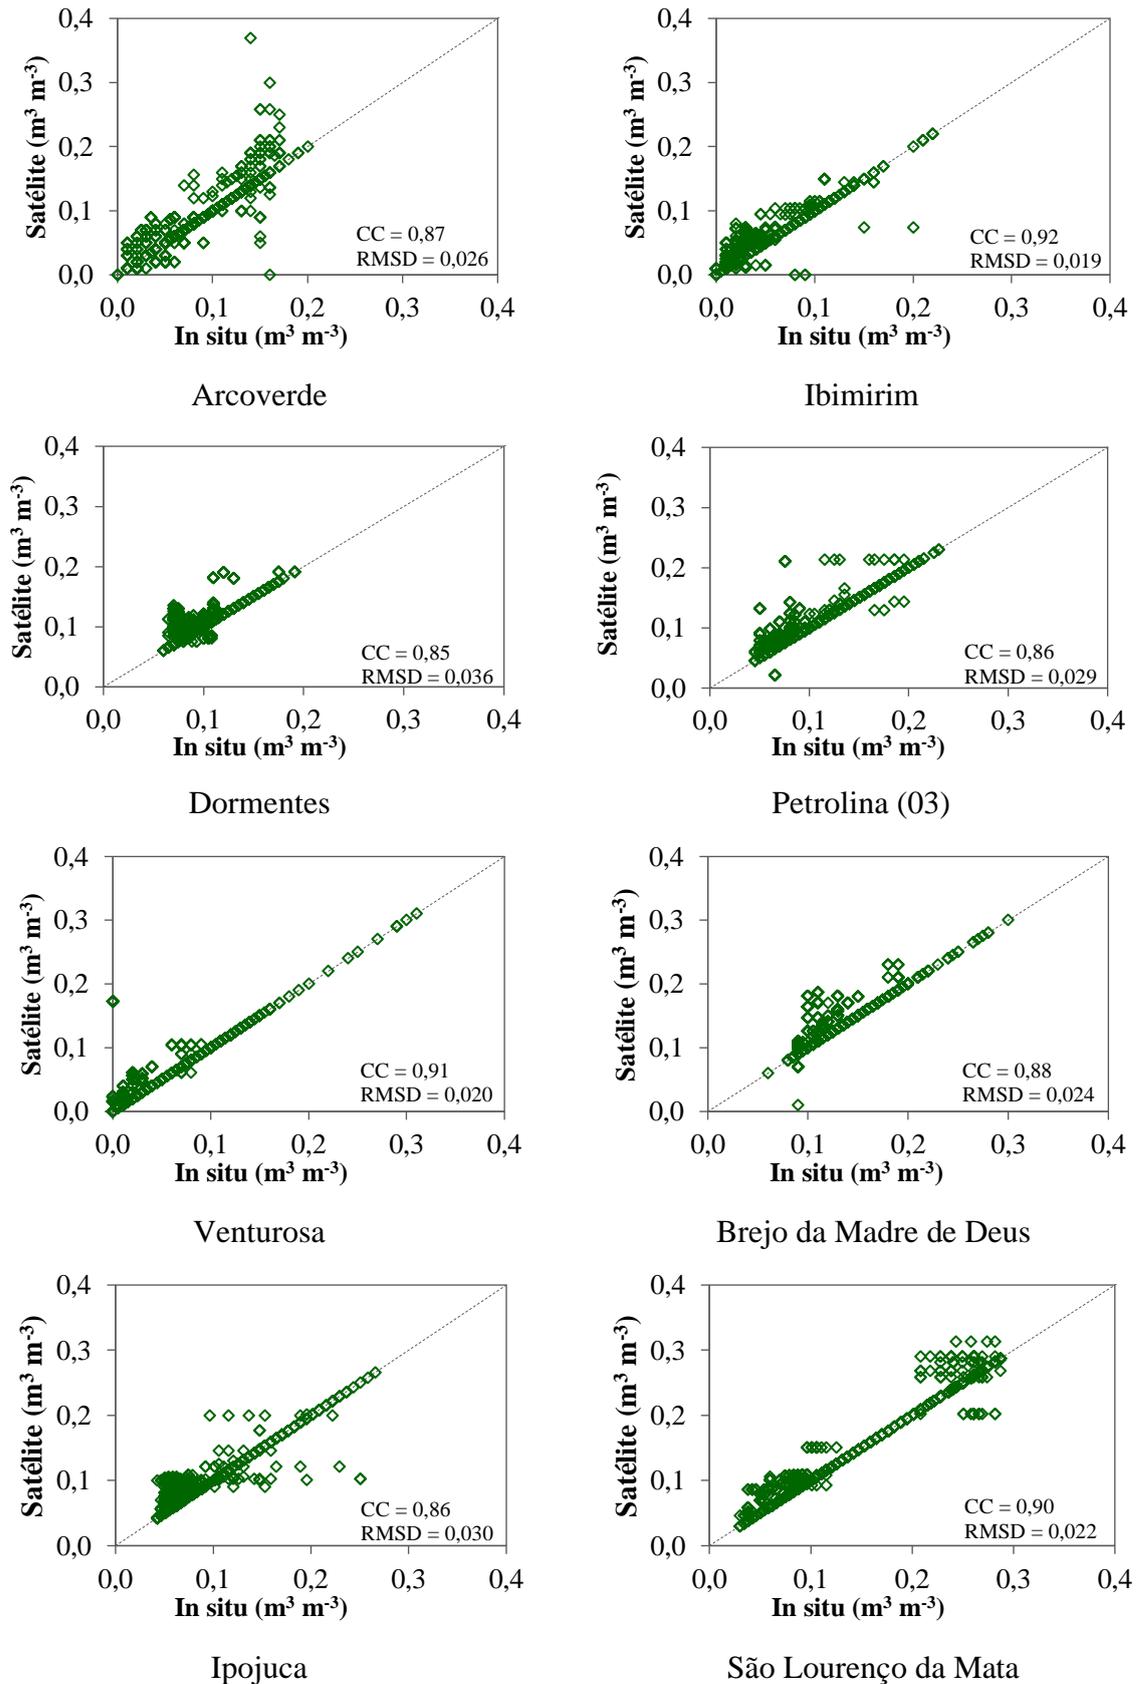
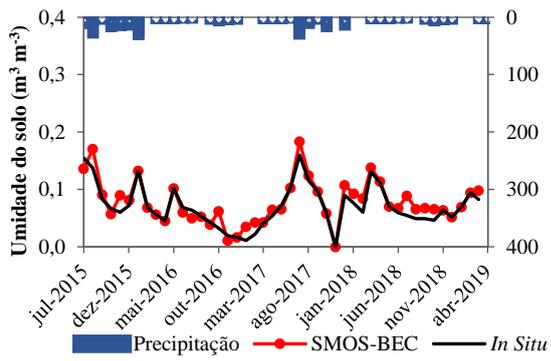


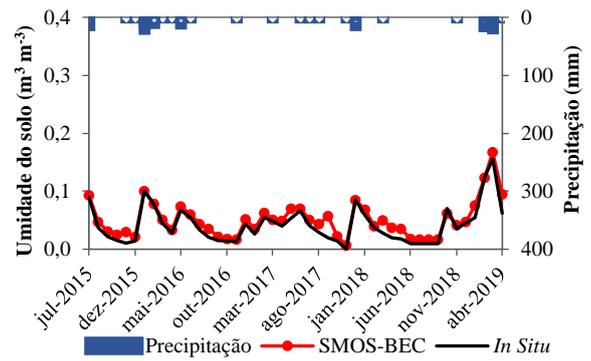
Figura 22 - Diagramas de dispersão dos dados diários de umidade do solo, estimados por sensoriamento remoto e obtidos in situ.

A Figura 23 ilustra os dados mensais de todas as estações, mostrando que houve um melhor ajuste dos dados do SMOS-L4 com os *in situ*, em comparação com a análise feita para os dados diários. A resposta da precipitação também foi mais expressiva em relação à variação de umidade, mostrando que, quando há déficit de precipitação os valores de umidade são quase nulos.

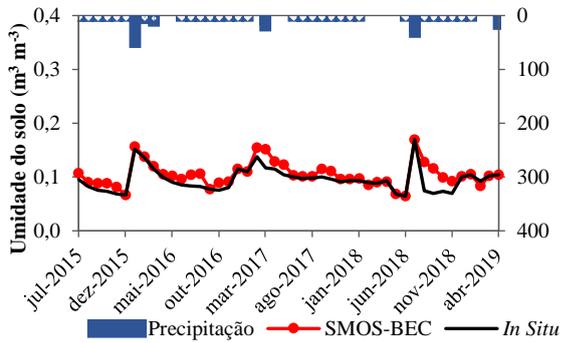
Khodayar, Coll e Lopez-Baeza (2019) estudaram a distribuição temporal e espacial da umidade do solo com produtos derivados de SMOS sobre o domínio de investigação usando uma abordagem multi-resolução para L3 (25 km), L2 (15 km) e L4 (1 km), e validaram com a rede de medições *in situ* da Valencia Anchor Station (VAS) para estimar a confiabilidade dos produtos SMOS SM. Os autores tiveram como seguintes conclusões: (a) Todos os produtos SMOS capturam corretamente os padrões temporais, mas os padrões espaciais não são reproduzidos com precisão pelas resoluções mais grosseiras, provavelmente em relação ao contraste com medições em campo em escala de pontos; (b) O potencial do SMOS-L4 é apontado para caracterizar adequadamente a variabilidade espaço-temporal de SM, refletindo padrões consistentes com amostras de *in situ*; (c) Dados desagregados em 1 km, são comprovadamente uma ferramenta adequada para a produção de mapas SM regionais com alta precisão, que podem ser usados como condições iniciais para simulações de modelos, previsão de cheias, monitoramento de safras, monitoramento de seca, estratégias de desenvolvimento de safras, entre outras.



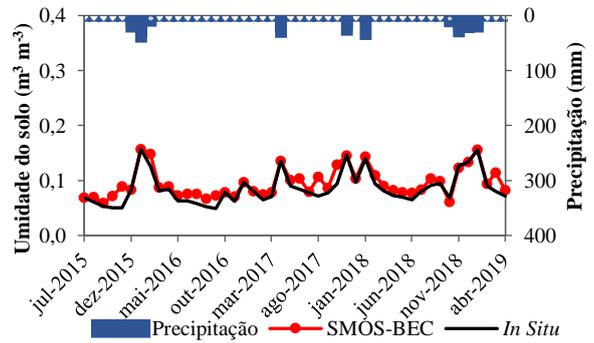
Arcoverde (Sertão)



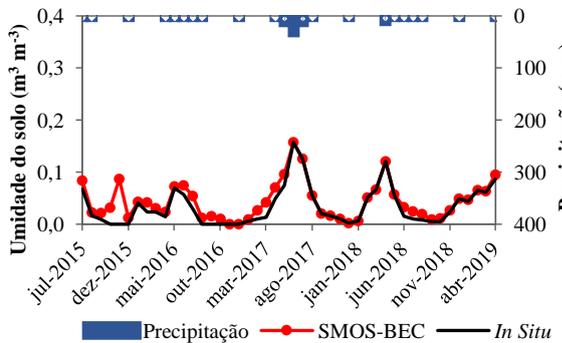
Ibimirim (Sertão)



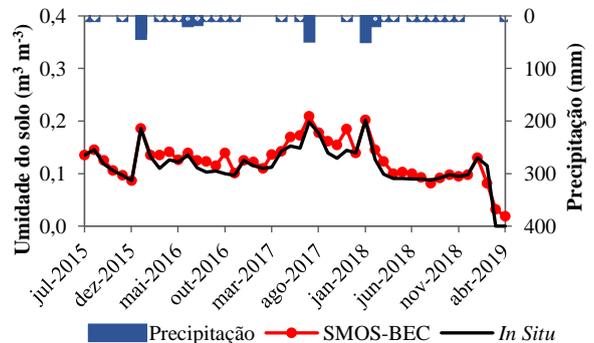
Dormentes (São Francisco)



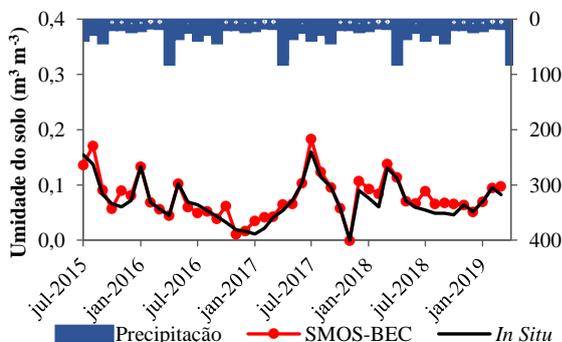
Petrolina 03 (São Francisco)



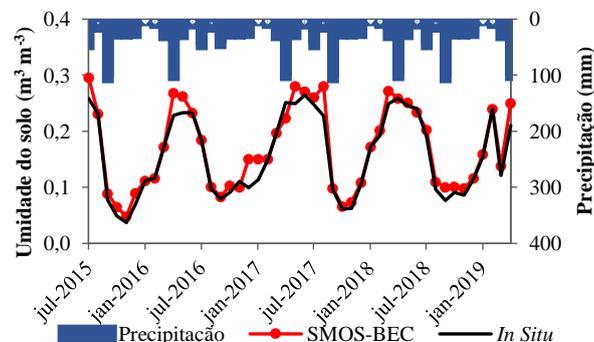
Venturosa (Agreste)



Brejo da Madre de Deus (Agreste)



Ipojuca (Zona da Mata)



São Lourenço da Mata (Zona da Mata)

Figura 23 - Comparação dos dados mensais de umidade do solo medidos in situ e estimados por satélite (SMOS-L4) para o período de julho de 2015 a abril de 2019.

Os índices estatísticos foram agrupados para uma análise por média em cada mesorregião. Em escala de tempo diária, foi percebido que todos os produtos apresentaram coeficientes de correlação (CC) superiores a 0,80, o que são relativamente elevados, nas quatro mesorregiões consideradas (Tabela 5). Para escala mensal, foi percebido que todos os produtos apresentaram os CC ainda melhores que os diários, chegando a 0,904 para a Zona da Mata. Vale destacar que as estações da Zona da Mata são as da APAC, e onde apresentam menores falhas em relação as estações do CEMADEN.

Souza et al. (2018) também validaram o SMOS em Pernambuco utilizando a rede do CEMADEN e APAC como referência, no entanto, utilizaram o SMOS-BEC com uma resolução de 25 km. Os autores obtiveram valores de CC em escala diária, superiores a 0,66 em todas as mesorregiões. Logo, é possível perceber o SMOS-L4 de 1 km se saiu melhor na validação que o de 25 km em todas as regiões do Estado de Pernambuco.

O RMSD dá uma ideia da magnitude dos erros, indicando tendências na média e/ou diferenças na amplitude das flutuações dos dados fornecidos pelos satélites. Por isso, visando remover essas tendências para tornar o padrão mais claro, utiliza-se o ubRMSD, sendo o RMSD não enviesado (sem tendência). Na região semiárida, especificamente falando da parte do Sertão e São Francisco, o produto possui valores de ubRMSD muito próximos a $\pm 0,04 \text{ m}^3 \cdot \text{m}^{-3}$ nos dados diários e levemente maiores nos mensais, correspondendo à precisão da estimativa do satélite. Embora sejam levemente maiores nos dados mensais, esses valores indicam o elevado potencial do produto. Trabalhos como o de Hajj et al. (2018) e Zhang et al. (2017) encontraram valores de ubRMSD bem maiores associados a menores coeficientes de correlação, mas ainda assim os autores indicarem a utilização dos dados estimados.

O conjunto de Bias calculado apresentou valores positivos e negativos. Os resultados foram principalmente negativos, o que revela uma leve subestimação dos dados do SMOS em relação a ambas as redes de observação para as validações por área e por pixel-estação. Houve apenas uma superestimação no agreste na validação de dados diários. Diante disso, o produto de satélite de umidade em estudo, tende a ter limitações na detecção de valores mais altos, possivelmente porque o seu algoritmo foi adaptado para homogeneização das leituras ao longo do semiárido.

Tabela 5. Valores estatísticos da avaliação dos dados estimados pelo SMOS-BEC em Pernambuco, em base diária e mensal.

SMOS-BEC	DIÁRIO				MENSAL			
	CC	Bias	RMSD	ubRMSD	CC	Bias	RMSD	UbRMSD
SAO	0,824	-0,006	0,054	0,036	0,857	-0,004	0,041	0,055
SER	0,832	-0,005	0,049	0,041	0,870	-0,003	0,038	0,063
AGR	0,801	0,035	0,060	0,026	0,827	-0,005	0,051	0,048
ZM	0,854	-0,008	0,043	0,051	0,904	-0,009	0,027	0,067

SAO = São Francisco; SER = Sertão; AGR = Agreste; ZM = Zona da Mata

3.2 Correlação do índice SWDI com o AWD

O SWDI requer dados orbitais de umidade do solo, além de outras propriedades que, nesse caso, foram obtidas a partir de grid global. Em decorrência disso, a validação para avaliar a consistência dos resultados gerados é necessária. Por padrão, utiliza-se como suporte o índice AWD, obtido a partir de dados de precipitação e ETo mensurados em superfície (BAI et al., 2018; MARTÍNEZ-FERNÁNDEZ et al., 2016).

A relação entre os dois é simples: a precipitação (AWD) é a via de entrada de água no solo, que causa aumento do conteúdo de água (aumenta SWDI). A evapotranspiração (AWD) é a via de saída, que causa redução do armazenamento de água e aumenta a demanda hídrica (reduz SWDI). Essa relação faz com que os dois índices, apesar de distintos, estejam intimamente correlatos, de modo que altos valores de coeficiente de correlação entre os dois sejam esperados (BAI et al., 2018; MARTÍNEZ-FERNÁNDEZ et al., 2016).

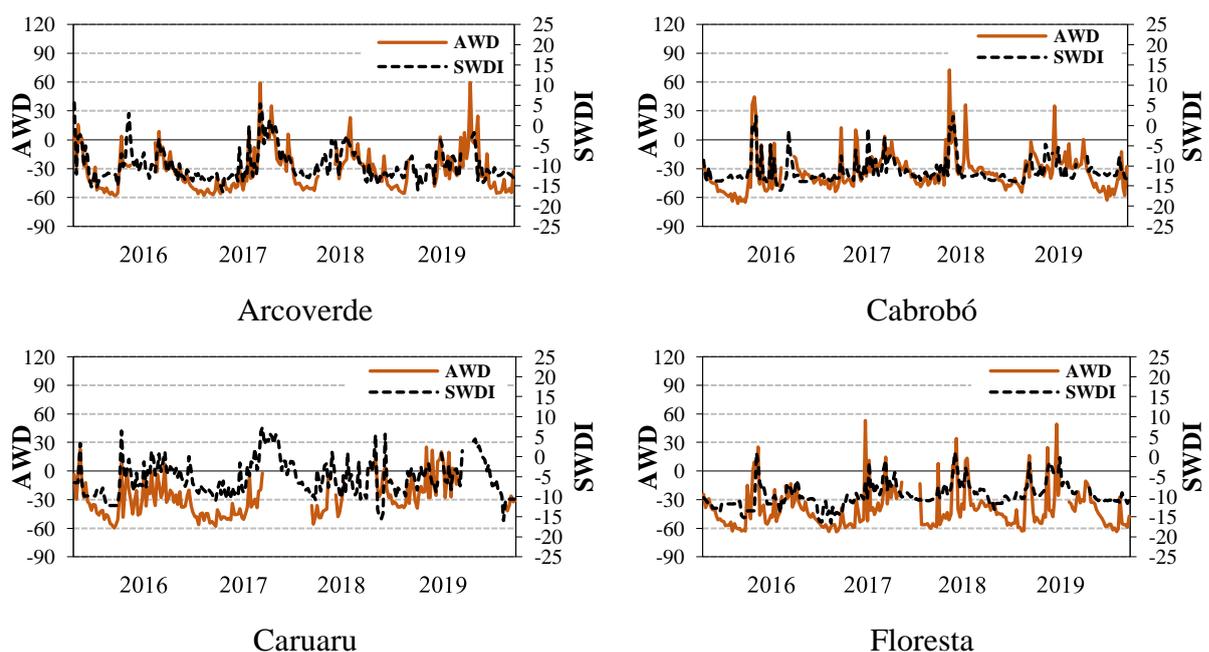
A Figura 24 ilustra a representação dos índices SWDI e AWD nas estações dos oito municípios considerados nas avaliações. A flutuação de ambos foi bastante similar, enquanto o SWDI representa a variação do armazenamento de água no solo, o AWD indica a variação do déficit hídrico na atmosfera, regulado pela precipitação (entrada) e evapotranspiração (saída). Essa alta similaridade mostra o grande potencial do satélite SMOS-L4 em capturar adequadamente as variações de umidade do solo nas diferentes mesorregiões do estado de Pernambuco.

Vale ressaltar que a maior parte do tempo, os valores mostraram-se negativos em ambos, prevalecendo em estações localizadas mais no semiárido, como pode ser visto nos municípios

de Ouricuri, Petrolina e Floresta. Segundo Rossato et al. (2017), a região semiárida no nordeste brasileiro é marcada pela precipitação inferior à evapotranspiração média anual, e que a tendência é de que esses índices sejam sempre negativos em virtude do desequilíbrio desse balanço.

Mishra et al. (2017) utilizaram o SWDI para avaliar a seca nos Estados Unidos, e o AWD como indicador de referência, comparando os resultados com o Índice Padronizado de Evapotranspiração (SPEI) e Índice de Severidade de Seca de Palmer (PDSI). Os autores mencionaram que a distribuição espacial da severidade da seca por todo país com base em SWDI e AWD parecem bastante semelhantes, atingindo resultados bastante satisfatórios, visto que, ambos foram capazes de capturar eventos severos e extremos de escassez de água no solo até em regiões montanhosas, grandes planícies, por toda costa oeste até parte sul e em alguns locais na Flórida.

Pablos et al. (2018) avaliaram o impacto da seca na umidade do solo da zona radicular (5 cm de profundidade) utilizando dados do SMOS. O índice avaliado também foi o SWDI que foi comparado com o AWD e calculados com dados oriundos de diferentes estações meteorológicas distribuídas na área noroeste da Espanha. Ambos demonstraram ciclos sazonais muito semelhantes, além de um grande potencial para o monitoramento desse tipo de evento nas diferentes estações do ano, sendo bem distintas na Europa.



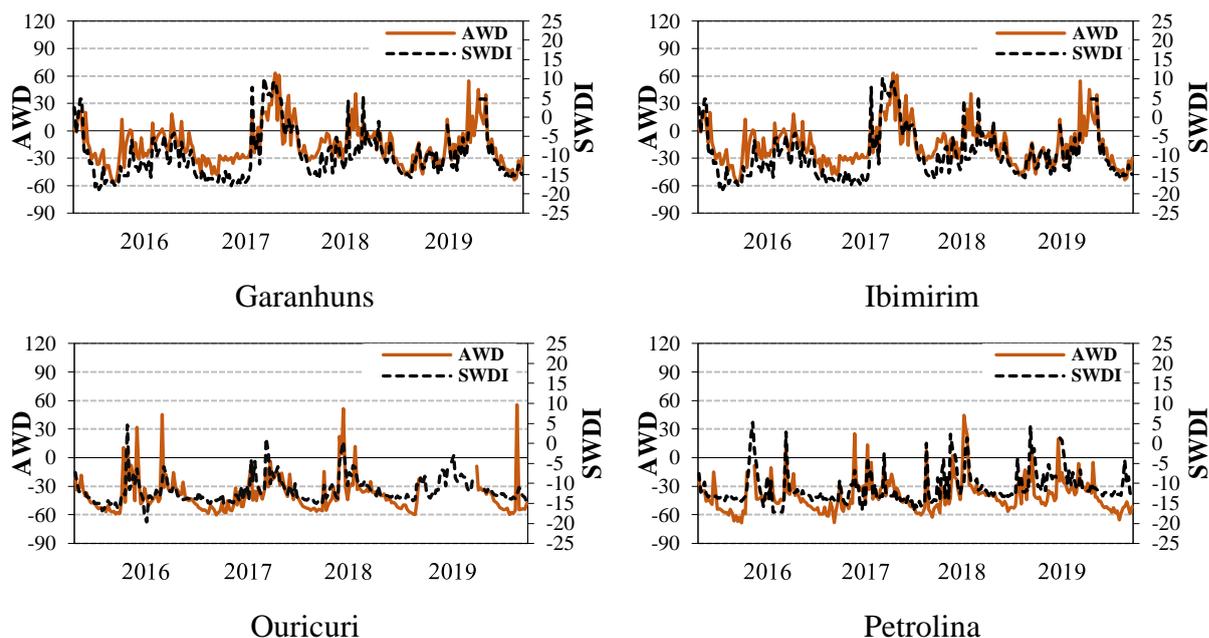


Figura 24. Variação semanal dos índices SWDI e AWD em algumas estações do Estado de Pernambuco

Os diagramas de dispersão referente à correlação entre SWDI-AWD com base em dados semanais das estações avaliadas (Figura 25) indicam forte agregação, com exceção das estações de Floresta e Ibimirim, com base no coeficiente de correlação entre as séries dos dois índices, que possuem escalas numéricas distintas. O AWD tende a apresentar valores relativamente positivos, mesmo quando o SWDI ainda está negativo, o que pode estar relacionado ao próprio processo de umedecimento e secamento do solo.

Além disso, em alguns momentos, o SWDI tende a ter uma resposta mais tardia. Nesse sentido, de acordo com Pablos et al. (2018), os valores maiores e a rápida resposta do AWD são justificáveis porque esse índice está diretamente ligado a processos que ocorrem na camada de superfície da atmosfera, por isso, o SWDI (sendo calculado para o solo) pode responder lentamente, nem sempre imediato.

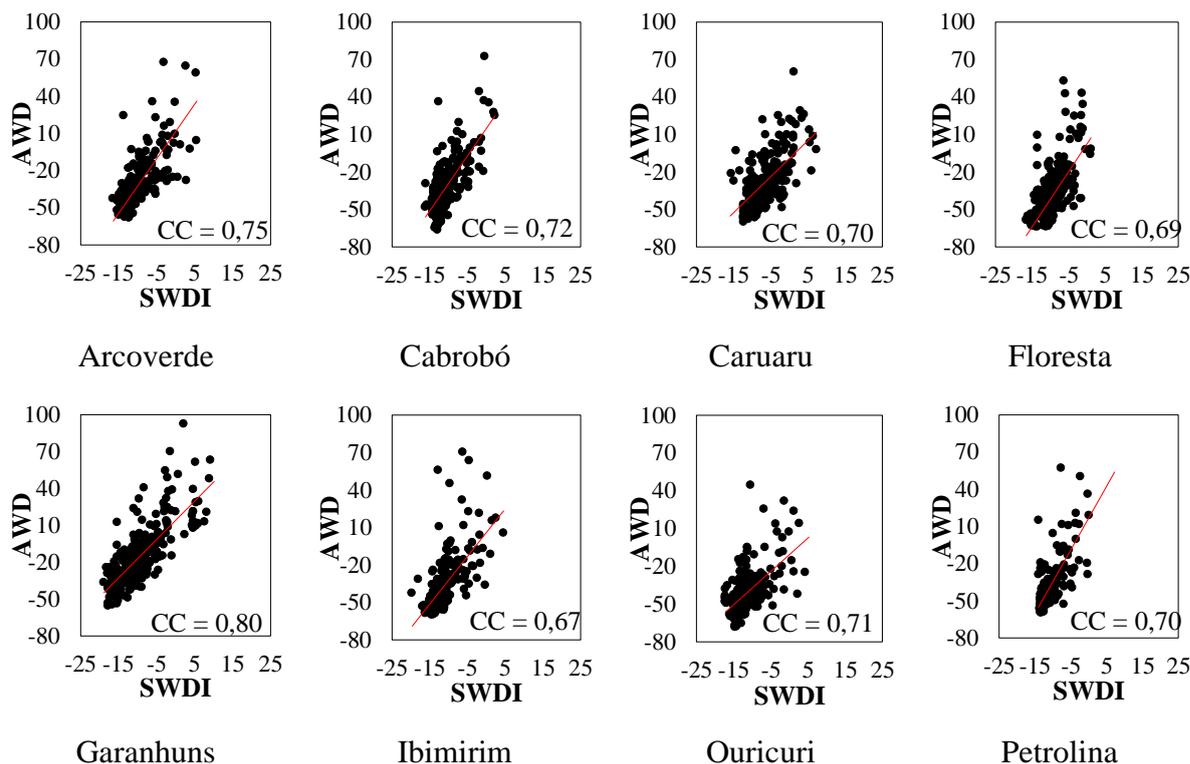


Figura 25. Coeficientes de correlação entre os índices SWDI e AWD em algumas estações do Estado de Pernambuco.

Todas as estações analisadas tiveram fortes correlações conforme o CC, indicando a grande relação entre os dois índices, evidenciando que o SWDI responde adequadamente a eventos de chuva, que causam aumentam do conteúdo de água no solo, bem como à evapotranspiração, que aumenta a demanda hídrica. O maior percentual do CC foi encontrado na estação do município de Garanhuns com $CC = 0,80$, e o menor para cidade de Ibimirim ($0,67$). É importante frisar que um forte CC está atrelado a menor quantidade de dados faltosos das variáveis utilizadas.

Zhu et al. (2019) utilizaram o SWDI para monitorar a seca em escala semanal na Bacia do rio Xiang e comparou com o índice AWD. Os autores observaram bons valores de correlação variando entre 0,60 e 0,79, indicando que foram fundamentais na detecção de eventos severos e extremos e de grande importância para um monitoramento contínuo da seca.

Fernández et al. (2016) calcularam o SWDI através de dados de satélite SMOS L2, durante o período de 2010 a 2014, para o monitoramento de seca agrícola na Bacia de Duero localizada na região semiárida na Espanha. Com base na análise comparativa dos dois índices

agrícolas, Índice de Umidade da Colheita (CMI) e AWD, os autores obtiveram bons resultados de CC (valores maiores que 0,80), mas a concordância com o AWD foi melhor. Esse resultado comprovou que o SMOS-SWDI demonstra bem a dinâmica do balanço hídrico do solo e pode rastrear adequadamente a seca agrícola.

3.3 Correlação dos índices de seca com o SWDI

Os dados dos pixels de todos os índices, que cobre todo o Estado, foram agrupados, de forma a analisar o SWDI em relação a sua percepção de seca em Pernambuco, o seu desempenho foi avaliado em comparação a outros índices agrícolas obtidos por sensoriamento remoto, sendo o SMCI, VCI e TCI. Conforme os diagramas de dispersão, é notória a boa correlação, com CC acima de 0,70, entre os índices com o SWDI.

Na Figura 26 é importante destacar que à medida que os valores de SWDI tendem a ficar negativos os outros índices acompanham tendência de diminuir os valores, ficando mais evidente essa similaridade entre os anos de 2016 e 2017, onde foram encontrados baixos valores de SMCI, VCI e TCI. Vale ressaltar que, por mais que os dois últimos não utilizem a variável umidade do solo para o cálculo, a precipitação torna-se importante para o entendimento, pois quando existe grande período de ausência de chuva, menor fica a área vegetada e consequentemente maior é a temperatura do solo.

Khan et al. (2020) observaram a variação das secas, espacialmente e temporalmente, na área de sequeiro do planalto de Potohar, Punjab, Paquistão, no período de 2000 a 2015, por meio de dados de satélite. Os autores concluíram que o principal fator envolvido na severidade da seca é um grupo combinado de fatores e que todos devem ser considerados, ou seja, só o estudo da umidade do solo não é suficiente para afirmar o entendimento do processo de seca em uma determinada região.

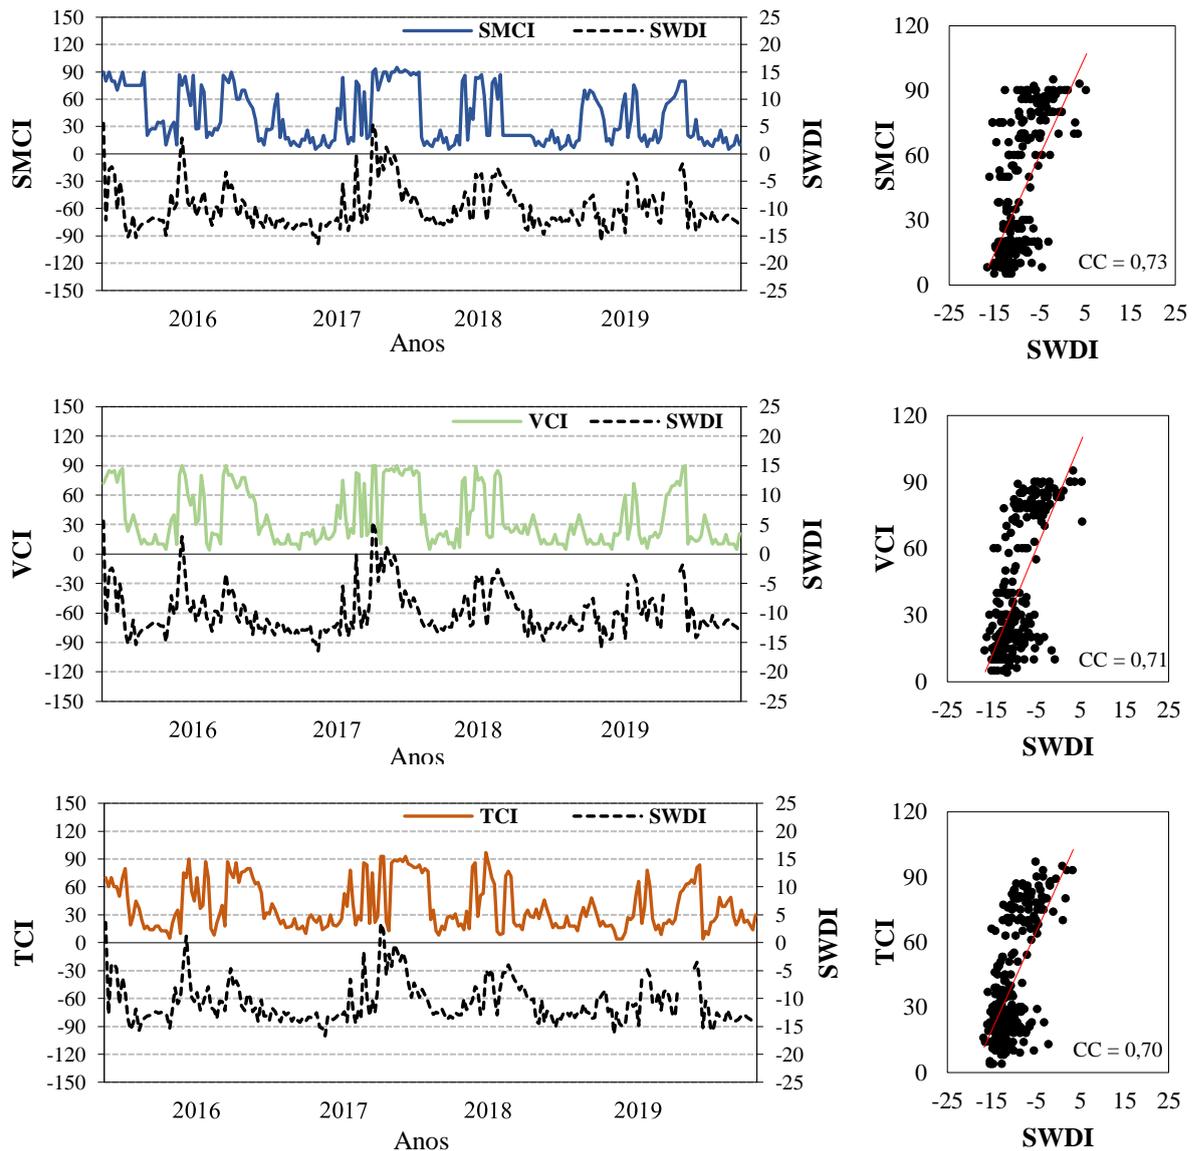


Figura 26. Variação mensal do SWDI e os índices SMCI, VCI e TCI para o estado de Pernambuco.

Com base na distribuição espacial do SWDI (Figura 27), houve um grande impacto no armazenamento de água no solo no ano de 2015, pela ausência de chuvas no terceiro e quarto trimestres em que quase todo o estado, resultando em condições de estresse hídrico extremo, com SWDI médio de -12,80 e -13,22, respectivamente. Esses valores estão abaixo do limiar ($< -10,00$), caracterizando a umidade do solo equivalente ao ponto de murcha permanente. Esse fato sucede a seca iniciada em 2012, que permaneceu bastante severa em todo o Nordeste até o final de 2015.

No segundo semestre dos demais anos, o SWDI médio também esteve abaixo de -10, ou seja, esses dados indicam que o SWDI tende a alertar sobre a disponibilidade hídrica extrema no solo apenas no segundo semestre de cada ano, que coincide com a estação seca. No primeiro semestre, embora os valores sejam bastante negativos e representem risco, não chegam a ser extremos do ponto de vista agrícola em toda a área, já que ainda há armazenamento de água no solo para suprimento vegetal, embora retida a altas tensões.

O monitoramento da seca agrícola para a bacia de Duero na Espanha, situada em uma região semiárida, na Península Ibérica foi realizado por Sánchez et al. (2016) durante o período de 2010 a 2014. Os autores compararam estatisticamente o resultado da série do índice Soil Moisture Agricultural Drought Index (SMADI), calculado com base nos produtos de NDVI e LST-Dia, com dois índices de seca: SWDI e CMI. O índice SMADI apresentou correlação significativa de -0,75 e -0,71 com o SWDI e o CMI, respectivamente. A correlação entre os índices é negativa, devido à descrição diferente da seca usada no SWDI (valores negativos indicam condições de seca), que vale para o CMI e para o SMADI, onde valores positivos indicam condições de seca.

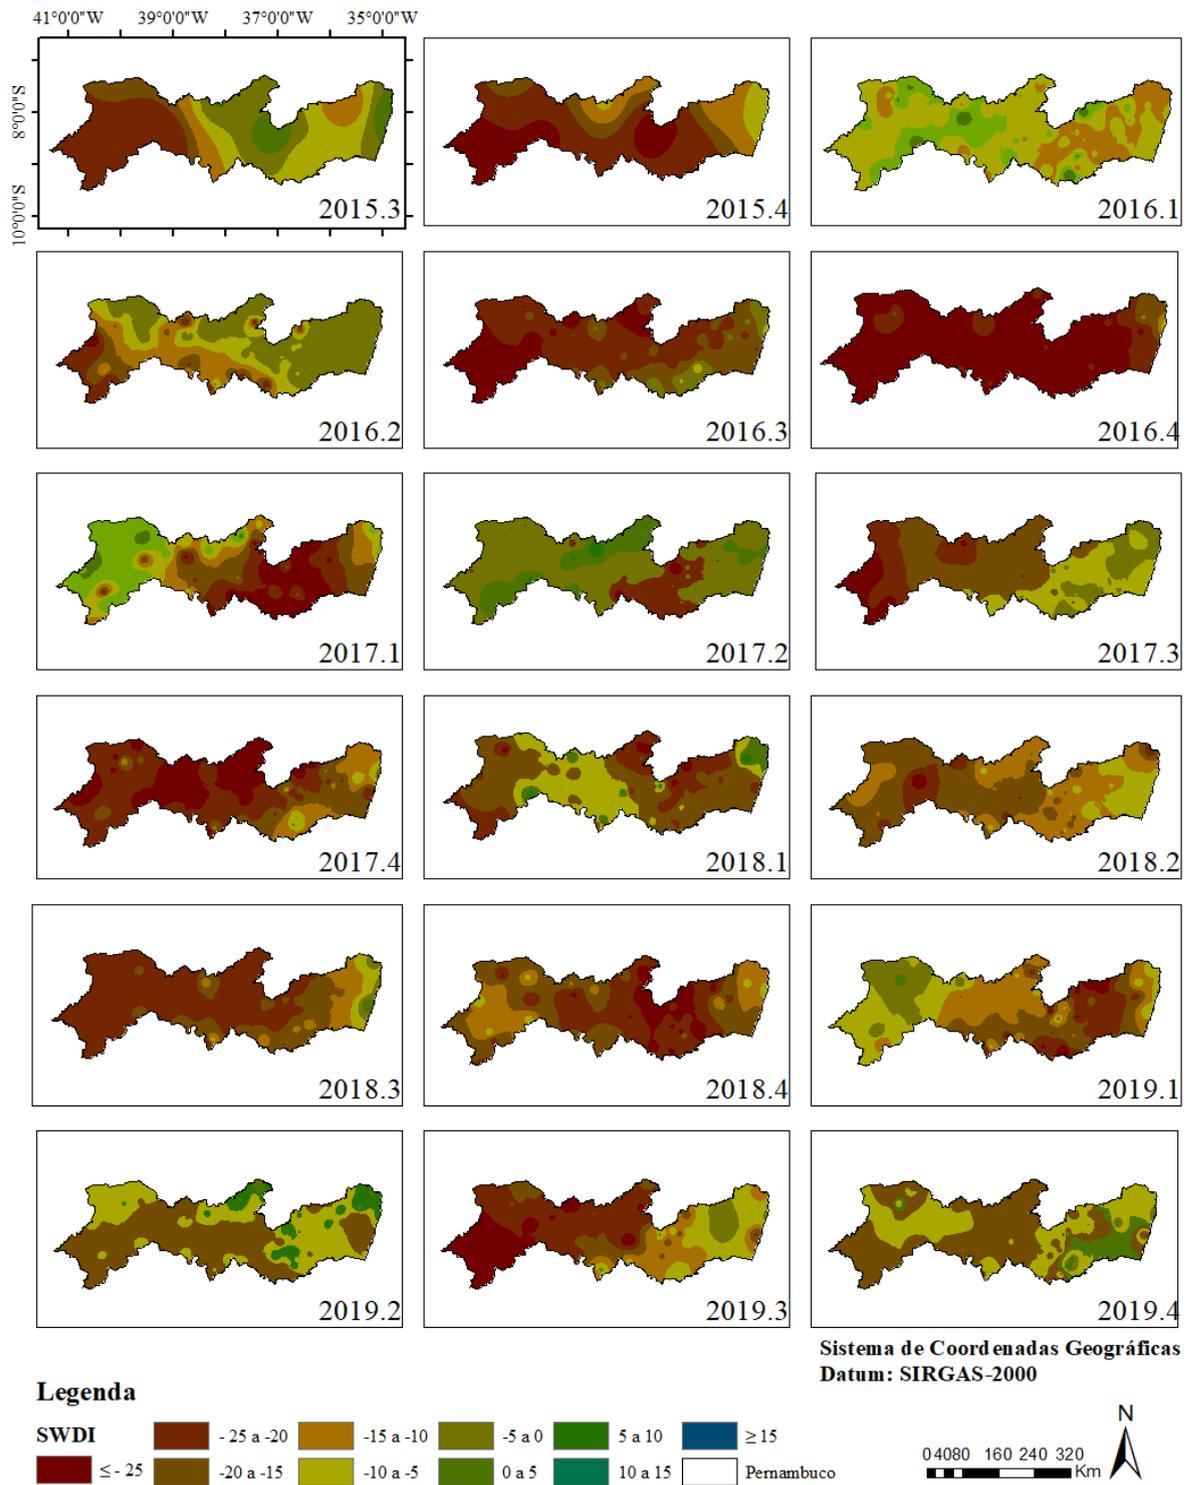


Figura 27. SWDI trimestral para o Estado de Pernambuco durante o período de julho de 2015 a junho de 2019.

Os dados do SMOS-BEC, com uma resolução de 1 km possui uma série de dados de umidade do solo relativamente curta, pois, se trata de uma nova forma em monitorar essa variável em escala global e que se popularizou recentemente. Mesmo assim, a depender do

índice utilizado, como é o caso do SWDI, a pouca quantidade de dados já é suficiente para o monitoramento do déficit hídrico.

A distribuição espacial e temporal do VCI ilustrada na Figura 28, sugere que a seca ocorre com mais frequência nos últimos trimestres em quase todo Estado de Pernambuco, pois a zona da mata é a única região que consegue prevalecer valores altos do índice. É importante destacar que os valores de VCI são representados em porcentagem, sendo assim, quando o valor estiver abaixo dos 10 por cento, a situação aponta uma seca extrema no local de estudo, enquanto abaixo de 40 mostra o início de seca (ROY e KOGAN, 2003). No primeiro trimestre de 2017, foi a única situação onde ocorreu o inverso, sendo a região semiárida com altos valores.

A vantagem do VCI é que ele pode ser facilmente calculado por não exigir dados observados de uma estação e, como um produto de seca baseado em satélite, pode fornecer dados quase em tempo real sobre o globo em uma resolução espacial relativamente alta. Vaani e Porchelvan (2018) utilizaram o VCI para o monitoramento espaço-temporal de seca agrícola no Estado de Tâmil Nadu, Índia. Os mapas gerados pelo índice foram essenciais para observar o nível de severidade da seca, mostrando quais os distritos que estavam mais sujeitos a condições mais moderada a severa durante um período de vinte anos, ajudando assim, a desenvolver várias estratégias para melhorar a produtividade agrícola naquela região.

Liang et al. (2017) também utilizou o VCI como um indicador de seca para avaliar as variações espaço-temporais desse fenômeno em diferentes regiões da China com base na análise da frequência, taxa de tendência e características temporais. Os autores frisaram que, por ser um índice que depende do estado da vegetação para descrever a seca, refletindo na precipitação, temperatura entre outras variáveis, os estudos devem considerar como combinar diferentes tipos de índices de seca para obter resultados de monitoramento mais precisos.

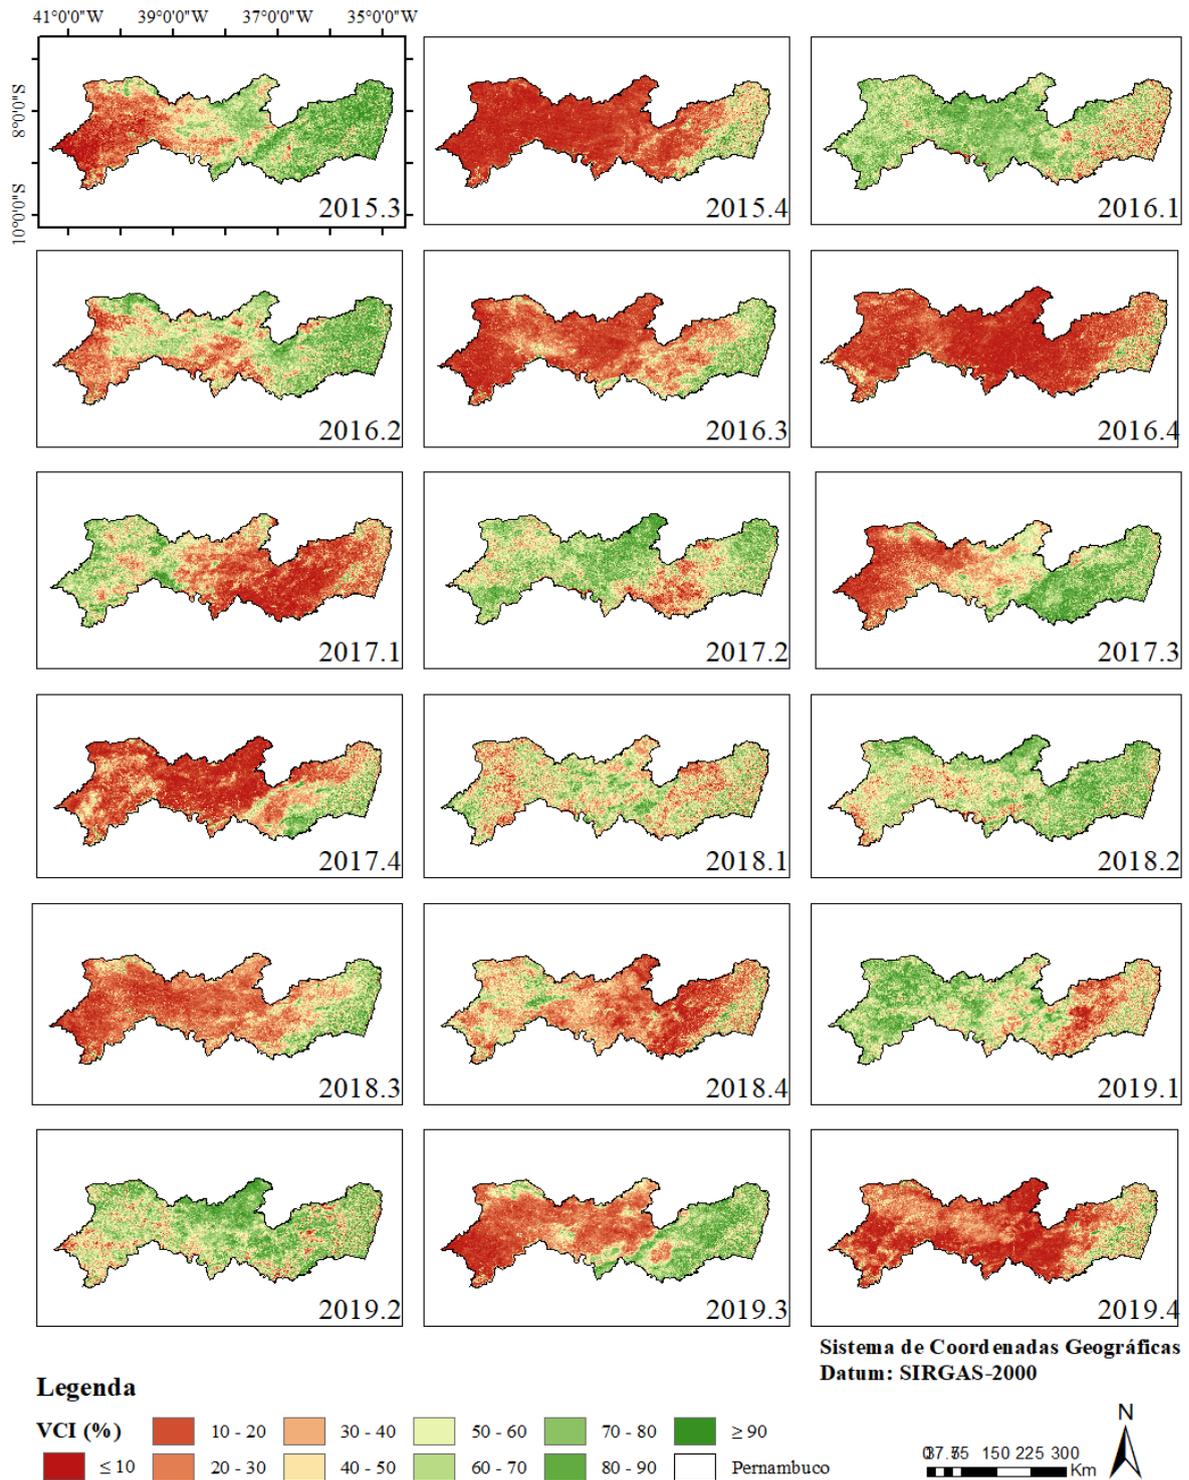


Figura 28. VCI trimestral para o Estado de Pernambuco durante o período de julho de 2015 a junho de 2019.

Na Figura 29 podemos observar a distribuição espacial e variações do TCI, indicando uma similaridade do que foi observado no comportamento do VCI. Porém, no primeiro trimestre de 2015, que equivale aos meses de junho, julho e agosto foi observado um comportamento inesperado em todo estado, mostrando que na zona da mata houve as maiores

temperaturas em toda a série. Apenas uma pequena parte do sertão teve baixas temperaturas, chegando um valor de TCI a 89%. É importante destacar que a quanto menor for o valor em porcentagem, mais altas são as temperaturas do solo, indicando que existe ausência de água na superfície.

Gomes et al. (2019) avaliou a inter-relação entre a variabilidade do NDVI, VCI e o TCI sobre o Nordeste do Brasil, utilizando o banco de dados NOAA-NESDIS, obtidos na série histórica de 1982 a 2011. Os autores encontraram uma forte correlação positiva entre os dois últimos índices na região semiárida do NEB, onde em alguns lugares da área de estudo houve uma pequena variação de 10%, o que não comprometeu essa boa similitude.

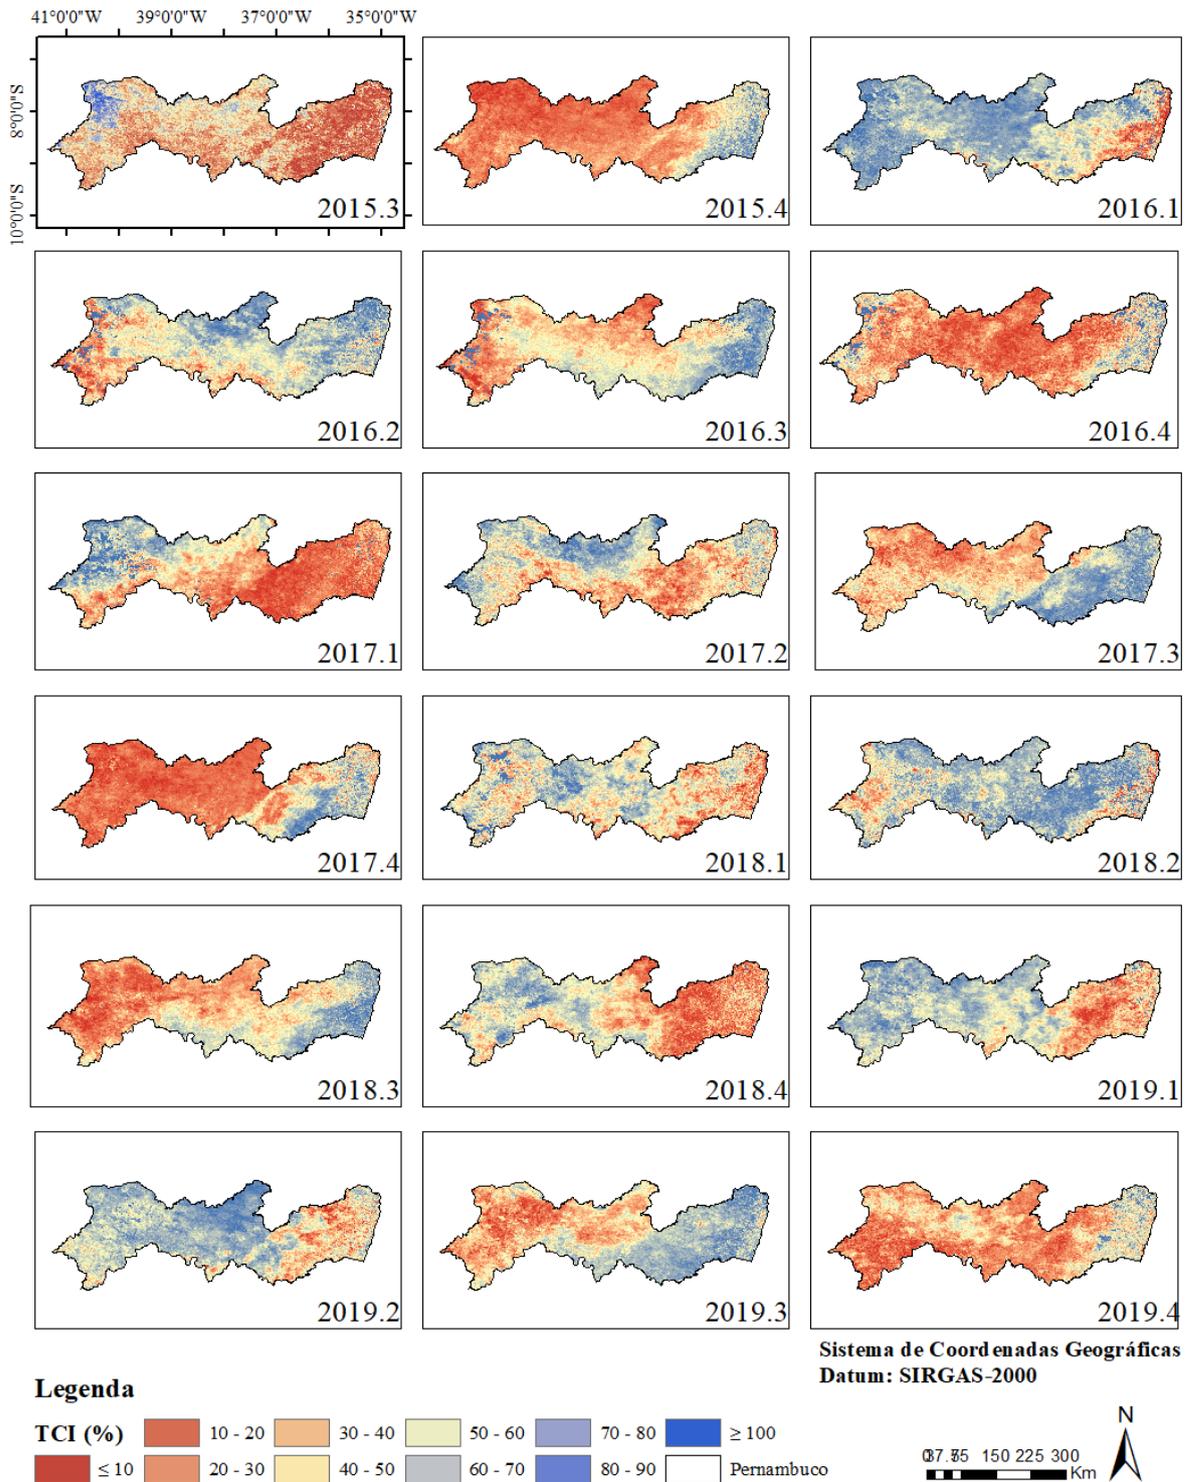


Figura 29. TCI trimestral para o Estado de Pernambuco durante o período de julho de 2015 a junho de 2019.

O SMCI (Figura 30) verifica o quanto a seca pode atingir determinada região, com base em dados de umidade do solo. Nesse estudo, apenas foi utilizado dados do SMOS-BEC (1 km) para analisar seu desempenho e sua relação com os outros índices calculados. Para esse índice,

os valores também variam entre 0 e 100 para cada pixel com base no mínimo absoluto e valor máximo absoluto, em que quanto mais próximo de 0 indica condição de seca e quanto mais próximo de 100 indica condição de maior umidade, seguindo o mesmo critério do VCI e TCI.

O SMCI é concordante com os resultados apresentados acima dos outros índices, obtendo os valores mais baixos na zona semiárida em quase todo o período de estudo, destacando que a região do Sertão do São Francisco é a que mais sofre com os ventos de seca no Estado. Vale destacar que as partes menos secas ficam concentradas no norte da Zona da Mata e sul do Agreste.

Um estudo feito por Inocêncio, Ribeiro Neto e Souza (2019) avaliou a seca agrícola calculada a partir de dados de umidade do solo da Iniciativa de Mudança Climática da Agência Espacial Europeia (ESA CSI SM), que correspondeu ao período de 30 anos, abrangendo os anos de 1988 a 2018. Os autores trabalharam com dois índices de seca, o SSMI e o SMCI, obtidos para três bacias hidrográficas localizadas em Pernambuco, sendo cada uma situada em uma região climática do Estado. Para a região do Sertão a bacia estudada foi a do Pajeú, no qual foi observado pelos autores que ambos os índices trabalhados indicaram que o período de 2012 a 2017 foi o que mais se destacou em relação à magnitude do período seco, quando comparado a todo período estudado, sendo o índice SMCI que evidenciou de forma mais intensa essa condição muito seca.

Bandad e Rahmani (2019) avaliaram os índices PDSI (Índice de Severidade de Secas de Palmer) e o Padronizar o Índice de Precipitação (SPI) com VCI e o SMCI, para poder prever mudanças no padrão de fluxo nos Estados Unidos. Os resultados mostram que SMCI se correlaciona significativamente com PDSI, SPI e o VCI.

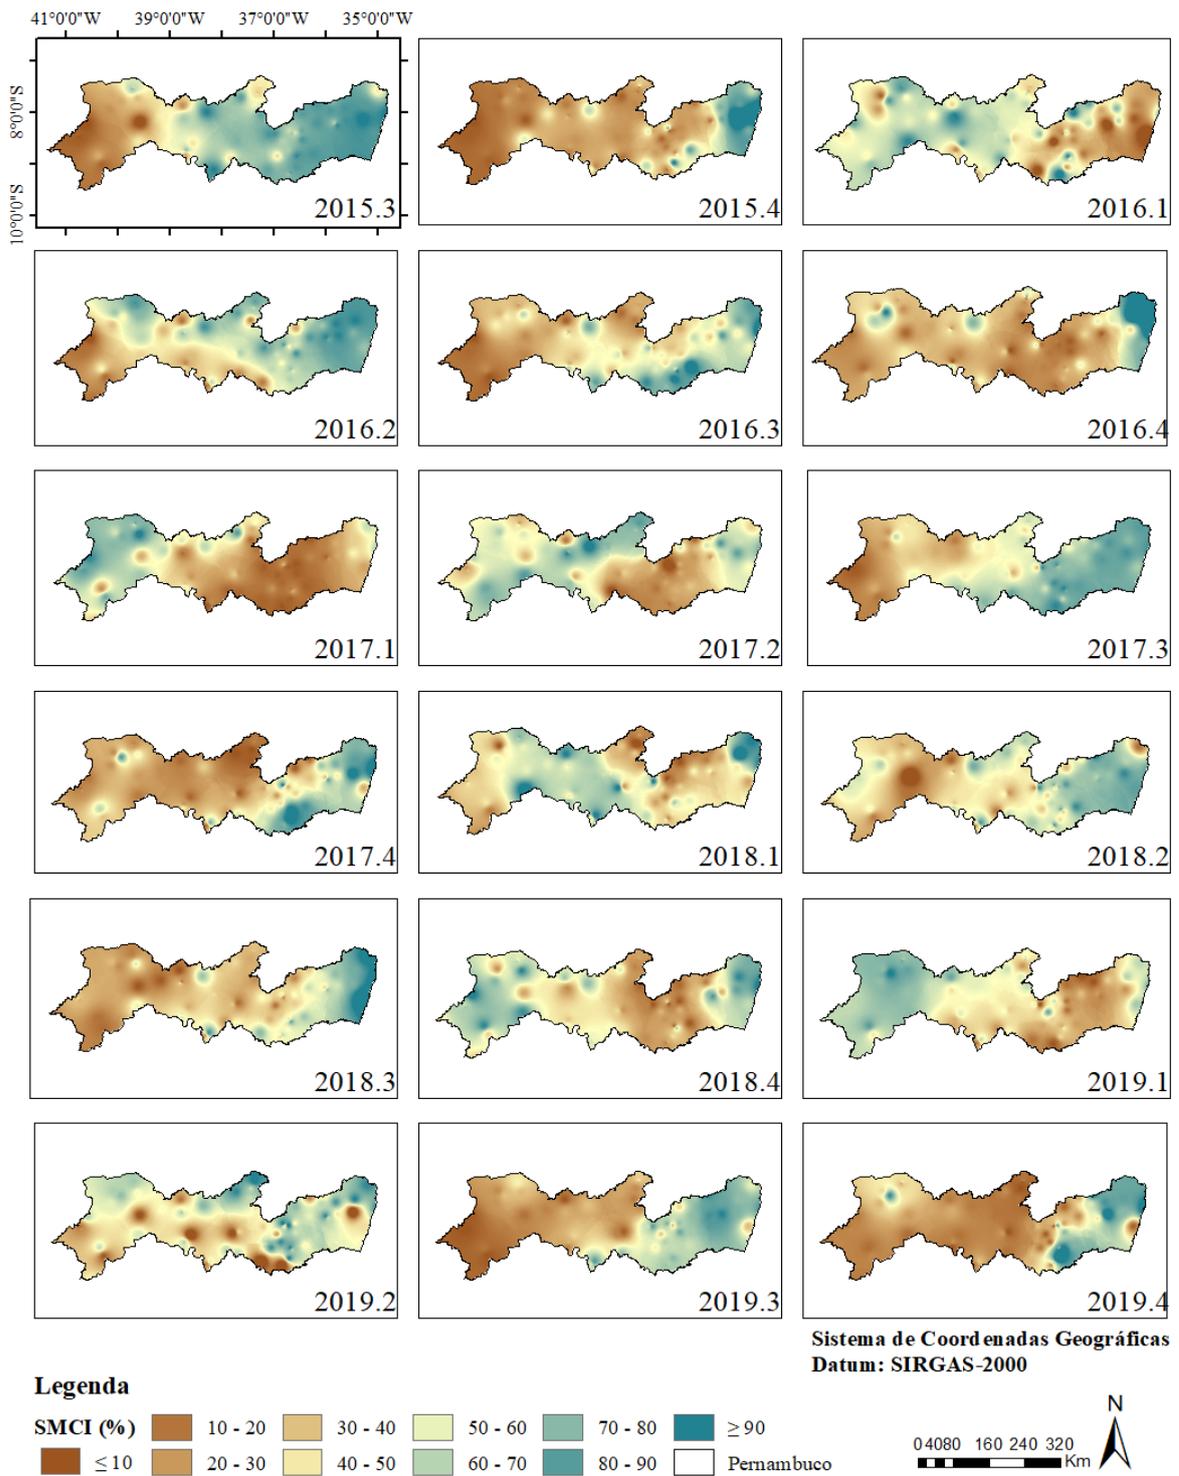


Figura 30. SMCI trimestral para o Estado de Pernambuco durante o período de julho de 2015 a junho de 2019.

4. CONCLUSÕES

O SMOS-L4 conseguiu representar a variação da umidade do solo temporal e espacialmente, com boa sensibilidade a eventos de precipitação e extremos de seca, indicando o potencial do instrumento para monitoramentos contínuos. Nesse sentido, O SWDI, derivado do SMOS-BEC (1 km), possui elevado potencial para o monitoramento da seca agrícola, indicando condições críticas de água no solo, com impacto direto no desenvolvimento vegetal.

A partir dos resultados obtidos de coeficiente de correlação, é correto inferir que o Soil Water Deficit Index (SWDI) tem comportamento semelhante aos outros índices de seca avaliado que considera como variáveis a precipitação e evapotranspiração (AWD), umidade do solo em campo (SMCI), índice de vegetação (VCI) e temperatura do solo (TCI). O SWDI pode ser monitorado continuamente para suporte ao manejo agrícola (irrigação), auxiliando no uso mais racional dos recursos hídricos e emitindo alertas que podem favorecer a mitigação de impactos decorrentes de eventos extremos de seca, evidenciando condições em que a demanda hídrica é elevada.

**CAPÍTULO IV: MODELAGEM DOS IMPACTOS DAS MUDANÇAS CLIMÁTICAS
NA BACIA HIDROGRÁFICA DO RIO PAJEÚ**

MODELAGEM DOS IMPACTOS DAS MUDANÇAS CLIMÁTICAS NA BACIA HIDROGRÁFICA DO RIO PAJEÚ

RESUMO: As mudanças climáticas podem impactar na intensidade e severidade das secas no semiárido nordestino. O objetivo desse estudo foi analisar o comportamento da seca e suas ocorrências futuras, com base nos índices de seca, na bacia hidrográfica do rio Pajeú, localizada no nordeste de Pernambuco, por dados futuros dos modelos climáticos e modelo hidrológico. O modelo Soil and Water Assessment Tool (SWAT) com modelos climáticos regionalizados Eta-MIROC e Eta-BESM foram usados para calcular o Índice de Precipitação Padronizada (SPI), Índice de Precipitação e Evapotranspiração Padronizado (SPEI) e o Índice de Umidade do Solo Padronizado (SSMI). O SWAT foi calibrado por meio do Sistema de Unidade de Respostas Hidrológicas para as Bacias Hidrográficas de Pernambuco (SUPER) e antes do uso dos dados de umidade do solo gerado pelo modelo, foram validados na bacia utilizando estações do Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN). Os dados de precipitação e temperatura do ar, simulados pelos modelos regionais (Eta), foram disponibilizados pelo Instituto Nacional de Pesquisas Espaciais (INPE), e a correção de tendência foi realizada para os dados históricos e futuros utilizando o método Linear Scaling (LS). Como resultados, a bacia certamente sofrerá com menos chuvas e maiores temperaturas para ambos os cenários de emissão e modelos climáticos. Os dados de umidade gerados pelo modelo hidrológico tiveram boa correlação com os dados de estações do CEMADEN. Os índices SPI, SPEI e SSMI foram capazes de mostrar, de forma espacial e temporal, que a bacia sofrerá com a seca até o fim do século, principalmente nas últimas décadas, e a região sul da bacia está mais susceptível em sofrer com as mudanças climáticas, em todos os cenários de emissão de gases do efeito estufa. Essas investigações futuras auxiliam em uma melhor gestão hídrica e no planejamento de medidas mitigadoras dos possíveis impactos na bacia hidrográfica do rio Pajeú, localizada no semiárido.

Palavras-chave: modelos climáticos, precipitação, SWAT, umidade do solo.

MODELING THE IMPACTS OF CLIMATE CHANGE IN THE PAJEÚ RIVER HYDROGRAPHIC BASIN

ABSTRACT: Climate change can impact the intensity and severity of droughts in the northeastern semiarid. The objective of this study was to analyze the behavior of drought and its future occurrences, based on drought rates, in the basin of the Pajeú River, located in the northeast of Pernambuco, through future data from climate models and hydrological model. The Soil and Water Assessment Tool (SWAT) model with Eta-MIROC and Eta-BESM regionalized climate models were used to calculate the Standardized Precipitation Index (SPI), Standardized Precipitation and Evapotranspiration Index (SPEI) and the Moisture Index of the Standardized Ground (SSMI). The SWAT was calibrated using the Hydrological Response Unit System for the hydrographic basins of Pernambuco (SUPer) and before using the soil moisture data generated by the model, they were validated in the basin using stations from the National Monitoring Center and Water Alerts. Natural Disasters (CEMADEN). The precipitation and air temperature data simulated by the regional Eta models are made available by the National Institute for Space Research (INPE), and the trend correction was carried out for historical and future data using the Linear Scaling (LS) method. As a result, the basin will certainly suffer from less rainfall and higher temperatures in the future for both emission scenarios and climate models. The humidity data generated by the hydrological model had a good correlation with the data from CEMADEN stations. The SPI, SPEI and SSMI indices were able to show, in a spatial and temporal way, that the basin will suffer from drought until the end of the century, mainly in the last decades, and the southern region of the basin is more susceptible to suffer with the changes climate change in all greenhouse gas emission scenarios. These future investigations assist in better water management and in the planning of measures to mitigate the possible impacts on the hydrographic basin of the Pajeú River, located in the semiarid region.

Keywords: climate models, precipitation, SWAT, soil moisture.

1. INTRODUÇÃO

A seca é um dos desastres naturais mais prevalentes, afetando negativamente os recursos hídricos, o meio ambiente, a agricultura e a economia (CUNHA et al., 2019; STERNBERG, 2011; VASILIADES e LOUKAS, 2009; KANG e SRIDHAR, 2017). Para identificar e compreender as características específicas da seca em uma determinada região, observações espaço-temporais de variáveis hidrológicas, como precipitação, umidade do solo e evapotranspiração são necessários (MO, 2008). O conhecimento dos impactos de mudanças climáticas no ciclo hidrológico de uma bacia hidrográfica fornece bases para o planejamento dos seus recursos hídricos, pelo qual se contemplem medidas adaptativas, gerenciamento de riscos, prevenção e mitigação de eventos extremos e diretrizes e/ou políticas para a gestão da seca (TAKEUSHI e MASOOD, 2016).

O modelo Soil and Water Assessment Tool (SWAT) (ARNOLD et al., 1998) é um método eficaz para simular e quantificar o impacto das mudanças climáticas no ciclo hidrológico e nas condições de seca (WU e JOHNSTON, 2007; KANG e SRIDHAR, 2017). Além disso, o SWAT foi aplicado com sucesso para avaliar vários tipos de secas, incluindo meteorológicas, agrícolas e hidrológica (WANG et al., 2011). É possível que modelos hidrológicos possam servir de base para avaliar as condições de seca por meio do desenvolvimento de vários índices, mitigação e estratégias de gestão (NARASIMHAN e SRINIVASAN, 2005).

O índice de seca SPI, Índice de Precipitação Padronizado (MCKEE et al., 1993) baseia-se unicamente na precipitação pluviométrica, outros índices requerem mais variáveis climáticas ou hidrológicas frequentemente indisponíveis, com registros menos longos e muitas vezes com menor representatividade espacial. O Standardized Soil Moisture Index (SSMI) é um índice agrícola para obtenção normalizada da umidade do solo, seguindo a metodologia também proposta por McKee et al. (1993). Vicent-Serrano (2010) e Blain (2011) desenvolveram um índice de seca padronizado em escala espaço-temporal, com base no modelo paramétrico log-logistic, chamado Índice de Precipitação e Evapotranspiração Padronizado (SPEI). Segundo esses autores, o SPEI pode incorporar estudos relativos ao aquecimento global, visto que o mesmo tem a habilidade de estimar uma possível intensificação da demanda hídrica atmosférica associada à elevação da temperatura global.

As variações climáticas históricas e suas projeções para o futuro a partir de modelos matemáticos complexos que por meio de parametrizações dos sistemas que compõem a atmosfera, a biosfera, a hidrosfera, a criosfera e a geosfera, fornecem os resultados a serem analisados (MILLER, 2011). As principais ferramentas utilizadas pelos centros de pesquisa do clima para projetar cenários de fenômenos meteorológicos futuros são os modelos de circulação geral (GCMs) (MARENGO, 2008). Os GCMs são representações dos processos físicos na atmosfera, no oceano e na superfície da terra, que simulam a resposta do clima global terrestre ao aumento nas concentrações de Gases de Efeito Estufa (GEE). Esses modelos descrevem a atmosfera utilizando um grid tridimensional sobre o planeta, tendo resolução global variando entre 250 e 600 km (MELLO et al., 2008).

Segundo Chou et al. (2014), estes modelos apresentam resoluções grosseiras, o que limita a simulação climática dos processos de mesoescala e na representação da topografia, uso do solo e a distribuição oceano/continente. Para se alcançar uma melhor resolução espacial e, conseqüentemente, uma simulação climática mais eficiente, são adotadas técnicas de regionalização, conhecidas como *downscaling*, sendo: refinamento de parte da grade (grid) da resolução do modelo global; acoplamento de Modelos Climáticos Regionais (MCRs) aos MCGs.

Para aplicação de um dado modelo climático, é necessária a escolha de um cenário futuro sobre o clima. A partir do quinto relatório (AR5), os cenários são organizados conforme os Caminhos Representativos de Concentração (RCP) os quais são expressos em concentrações de gases do efeito estufa em vez de níveis de emissões (IPCC, 2014). Sendo classificados como um cenário de mitigação rigoroso (RCP 2.6), dois cenários intermediários (RCP 4.5 e 6.0) e um cenário com emissões de GEE muito altas (RCP 8.5).

Atualmente, modelos hidrológicos têm sido utilizados para realizar projeções dos impactos das mudanças climáticas em uma determinada região, principalmente em bacias hidrográficas, a partir de cenários climáticos fornecidos por GCMs e/ou RCMs (AMIM et al., 2017; CHILKOTI, BOLISSETTI e BALACHANDAR, 2017; ZHANG et al., 2015). Diante disso, o objetivo do trabalho foi avaliar e analisar o comportamento da seca e suas ocorrências futuras, com base nos índices SPI, SPEI e SSMI na bacia hidrográfica do rio Pajeú localizada no semiárido de Pernambuco, utilizando dados de projeções dos modelos climáticos com o modelo hidrológico SWAT.

2. MATERIAL E MÉTODOS

2.1 Área de estudo

A bacia hidrográfica do rio Pajeú situa-se na zona fisiográfica do Sertão de Pernambuco entre as coordenadas de 07°16'20" e 08°56'01" de latitude Sul, e 36°59'00" e 38°57'05" de longitude Oeste (Figura 31). A área pesquisada está localizada na microrregião do Sertão do Pajeú, parte das microrregiões do Sertão do Moxotó, do Salgueiro e de Itaparica compondo a Unidade de Planejamento Hídrico 9 (UP9) (SECTMA, 1998; RIBEIRO, 2016).

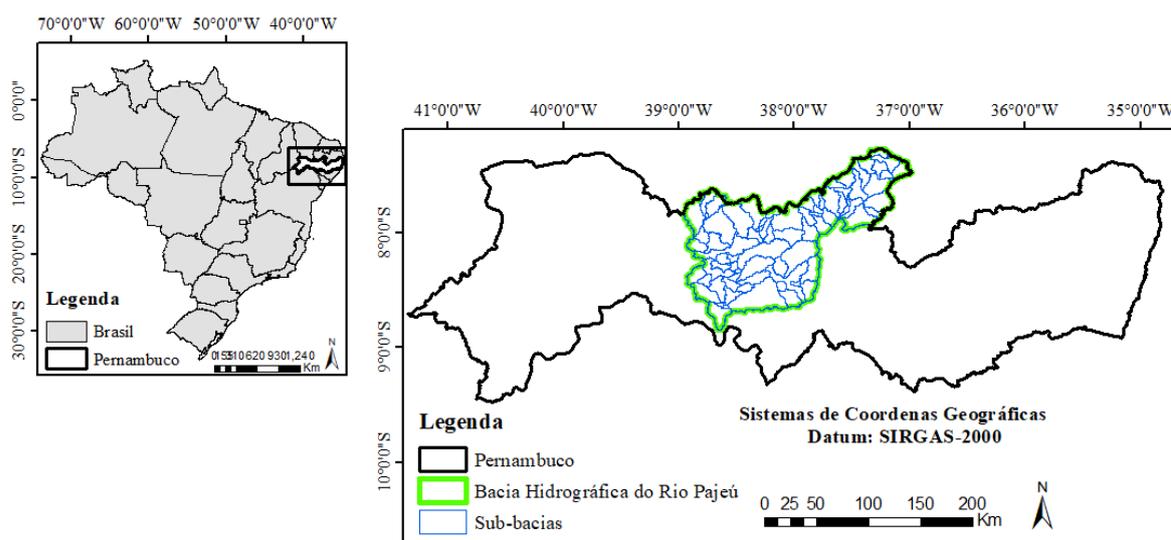


Figura 31 - Mapa de localização da bacia hidrográfica do rio Pajeú.

A bacia hidrográfica do rio Pajeú possui uma área aproximada de 16.685 km², sendo a maior do estado de Pernambuco com 16,97% do seu território. A sua rede de drenagem abrange as sedes municipais de Carnaíba, Carnaubeira da Penha, Floresta, Iguaraci, Itacuruba, Mirandiba e São José do Belmonte, já os municípios de Afogados da Ingazeira, Betânia, Brejinho, Calumbi, Flores, Ingazeira, Itapetim, Quixabá, Santa Cruz da Baixa Verde, Santa Terezinha, São José do Egito, Serra Talhada, Solidão, Tabira, Triunfo e Tuparetama estão totalmente inseridos e Belém do São Francisco, Custódia, Ibimirim e Salgueiro estão parcialmente incluídos, totalizando 27 municípios com uma população em torno de 630 mil habitantes (IBGE, 2014; RIBEIRO, 2016).

Nesta pesquisa foram utilizados dados de precipitação mensal da série histórica de 1961 a 2019 (58 anos) de 12 estações pluviométricas distribuídas na bacia hidrográfica do rio Pajeú (Figura 32). As estações foram selecionadas pela disponibilidade por municípios que compõem a bacia hidrográfica e pelo maior quantitativo de dados pluviométricos. Essas informações foram obtidas por meio da Agência Pernambucana de Águas e Clima (Apac) e da Agência Nacional das Águas (Ana).

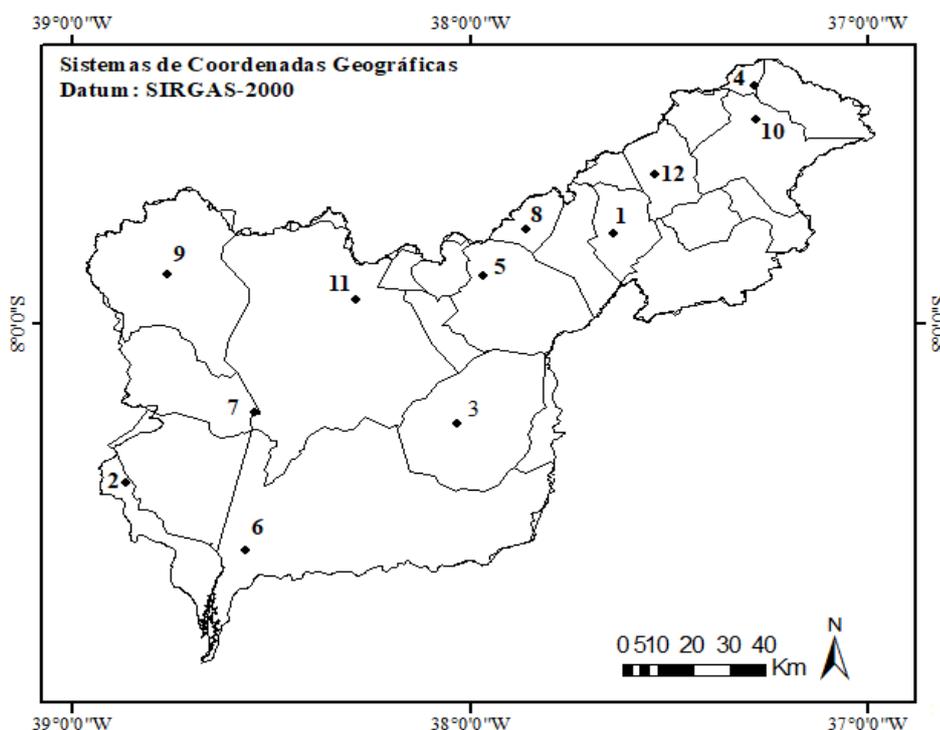


Figura 32. Configuração espacial da rede pluviométrica da bacia hidrográfica do rio Pajeú.

A Tabela 6 apresenta as estações utilizadas por município com seus correspondentes códigos, agências consultadas, municípios, coordenadas geográficas e altitudes.

Tabela 6. Distribuição das estações meteorológicas utilizadas na pesquisa

Nº	Agência	Código	Município	Latitude	Longitude	Altitude (m)
1	Ana	737023	Afogados da Ingazeira	-7°44'20"	-37°38'54"	525
2	Ana	838004	Belém do São Francisco	-8°45'54"	-38°57'38"	399
3	Apac	93	Betânia	-8°16'15"	-38°01'59"	443
4	Apac	473	Brejinho	-7°20'52"	-37°17'05"	742
5	Ana	737027	Flores	-7°52'04"	-37°58'21"	460
6	Ana	838020	Floresta	-8°36'00"	-38°35'00"	317
7	Ana	838002	Mirandiba/Açude Serrinha	-8°14'23"	-38°31'40"	375
8	Apac	238	Quixaba	-7°43'00"	-37°52'00"	718
9	Ana	738029	São José do Belmonte	-7°52'00"	-38°47'00"	460
10	Apac	92	São José do Egito	-7°26'40"	-37°16'50"	625
11	Ana	838031	Serra Talhada	-8°00'02"	-38°14'41"	435
12	Apac	74	Tabira	-7°35'18"	-37°32'13"	579

Com forma alongada, 355 km extensão, perímetro de 1.041,74 km e largura muito variada (45,4 km no alto Pajeú, 69,7 km no médio Pajeú e 104,2 km no baixo Pajeú), a bacia apresenta um relevo variado. Os dados de uso e cobertura da terra foram obtidos em formato de mapa, com escala de 1:100.000, no site do IBGE (<https://downloads.ibge.gov.br/>), para o ano de 2014, como pode ser visto na Figura 33.

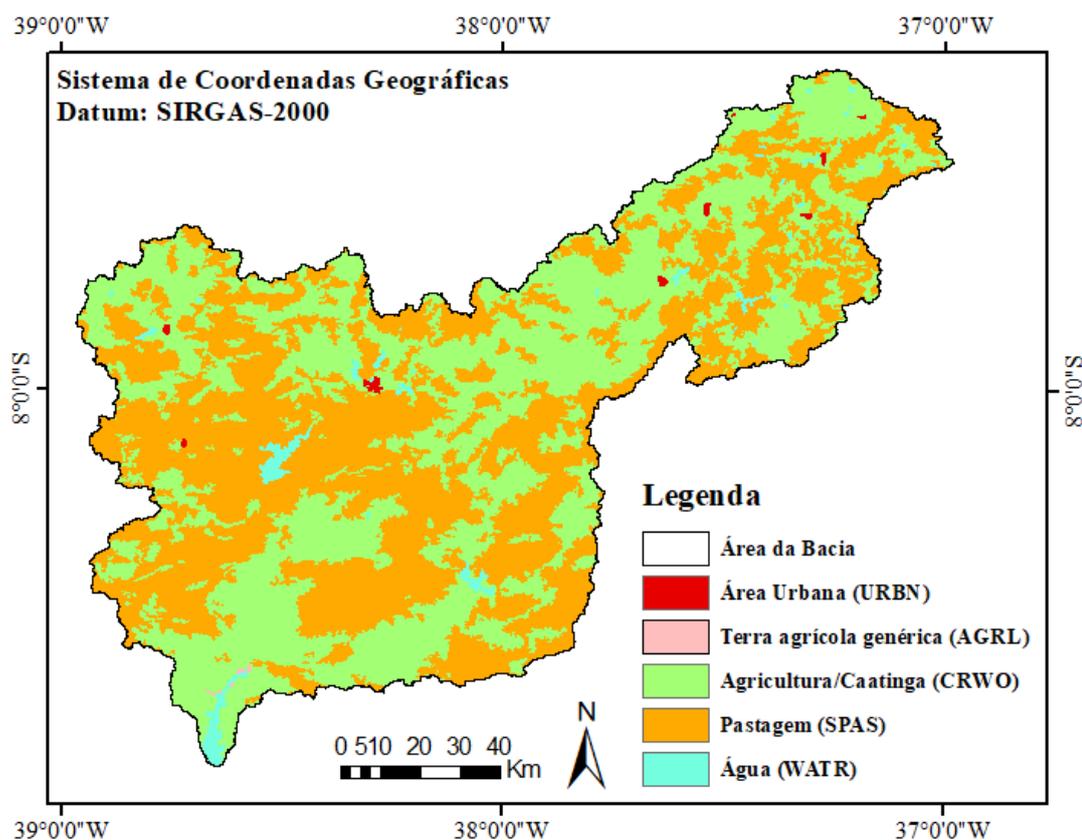


Figura 33. Mapa de uso e cobertura do solo da Bacia Hidrográfica do rio Pajeú.

A bacia possui uma diversidade de solos (formação e ocorrência de classes) devido à heterogeneidade do material geológico (rochas gnaíssicas, graníticas, máficas e ultramáficas, e rochas sedimentares, arenitos). O mapa de tipos de solo foi obtido no banco de dados do Instituto Brasileiro de Geografia e Estatística (IBGE), em formato tiff, com escala de 1:250:000, no site do IBGE (<https://downloads.ibge.gov.br/>). Já os dados relativos às características físico-químicas de cada tipo de solo foram obtidos da base de dados da EMBRAPA Solos (https://www.bdsolos.cnptia.embrapa.br/consulta_publica.html).

Os solos da região possuem uma variação considerável de fertilidade e profundidade, visto que tanto a pedogênese quanto o intemperismo das rochas são processos lentos

influenciados pelo clima e relevo local (FEITOSA, 2012). Diante disso, os solos da bacia hidrográfica são representados por várias classes destacando-se na Figura 34, os Argissolos, Luvisolos e Neossolos. A distribuição dos solos na área está relacionada aos domínios morfoestruturais mais elevados do Planalto da Borborema e às áreas rebaixadas e aplainadas da Depressão Sertaneja.

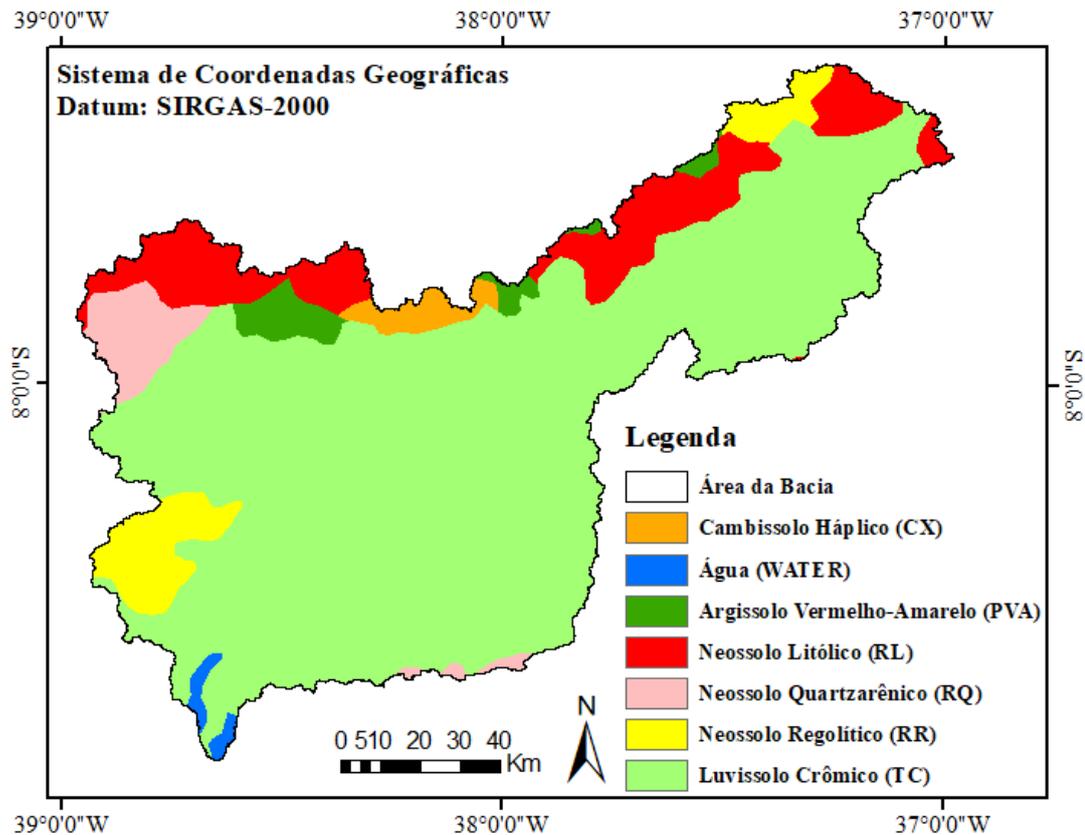


Figura 34. Mapa pedológico da Bacia Hidrográfica do rio Pajeú

2.2 O modelo SWAT

O Soil and Water Assessment Tool (ARNOLD et al., 1998) é um modelo espacialmente distribuído, de tempo contínuo, desenvolvido para avaliar os efeitos de práticas de manejo do solo e uso da terra sobre fontes de poluição difusas nos recursos hídricos de grandes bacias (ARNOLD et al., 2012). O SWAT tem sido amplamente utilizado em pesquisas de simulações hidrológicas e de qualidade da água, bem como mudanças climáticas e impactos na seca (SENENT-APARICIO et al., 2017; SHIFERAW et al., 2018; SANTOS et al., 2019; SOUSA et al., 2019, ANDRADE et al., 2020).

O modelo pode simular bacias complexas, com diferentes usos do solo, topografia e condições climáticas, a partir da discretização da bacia em sub-bacias e Unidades de Resposta Hidrológica (URH), sendo áreas no interior das sub-bacias que são formadas pela mesma cobertura da terra, solo e manejo. O modelo define as URHs para que cada unidade de resposta hidrológica tenha uma Curva Número (CN) única associada. O ciclo hidrológico é simulado no SWAT com base no balanço hídrico (Equação 21).

$$SW_t = SW_0 + \sum_{i=1}^t R_{day} - Q_{surf} - E_a - w_{seep} - Q_{gw} \quad (21)$$

em que: SW_t : quantidade final de água no solo (mm H₂O); SW_0 : umidade do solo inicial no dia i (mm H₂O); t : tempo (dias); R_{day} : quantidade de precipitação no dia i (mm H₂O); Q_{surf} : escoamento superficial total no dia i (mm H₂O); E_a : quantidade de evapotranspiração no dia i (mm H₂O); w_{seep} : quantidade de água que entra na zona de aeração do perfil do solo no dia i (mm H₂O); Q_{gw} : quantidade de retorno do fluxo de água no dia i (mm H₂O).

2.3 Calibração e validação do modelo hidrológico

A calibração e validação do modelo hidrológico na bacia de estudo foi realizada por meio do Sistema de Unidade de respostas hidrológicas para as bacias hidrográficas de Pernambuco (SUPER). O SUPER é um sistema interativo de modelagem hidrológica e de qualidade de água que utiliza como mecanismo de modelagem a ferramenta de avaliação do solo e da água do SWAT. Este sistema foi desenvolvido por meio de uma grande parceria entre a UFPE, UFRPE, UFCG, ITEP e a Texas A&M University para dar suporte a decisões econômicas e políticas, a partir de simulações em tempo real, e a curto, médio e longo prazo.

O modelo foi calibrado por Viana et al. (2020) para a bacia hidrográfica do Rio Pajeú, utilizando os dados climáticos da série de 1961 a 2017 obtidos através de dois bancos de dados, o da APAC para dados de precipitações diárias, e do INMET para dados meteorológicos completos. Os dados de vazão foram obtidos de cinco postos fluviométricos, seguindo o mesmo período dos dados climáticos, baixados pelo site da ANA (Agência Nacional de Águas) (<http://hidroweb.ana.gov.br/>), considerado os dados disponíveis no período de 1961 a 2017.

A calibração do modelo consiste em sua parametrização para um dado local, o que reduz a incerteza de previsão. O processo de calibração ocorre a partir da seleção cuidadosa dos

valores dos parâmetros de entrada do modelo (dentro da sua respectiva faixa de incerteza), comparam-se as saídas do modelo (previsão) com dados observados para as mesmas condições (ABBASPOUR et al., 2015).

Os dados de saída de umidade do solo do modelo SWAT (SM-SWAT) foram validados com dados de estações do CEMADEN, que utilizam sensores com precisão de $0,03 \text{ m}^3 \cdot \text{m}^{-3}$, na bacia entre os períodos de 2015 a 2017 até a camada de 20 cm, pois, esses sensores instalados em campo só conseguiram obter informações de umidade do solo até essa profundidade. Vale destacar que o intervalo de anos utilizados foi curto, porque essas estações possuem falhas e esse período de dois anos analisado possui uma série mais consistente e de maior qualidade. A SM-SWAT (mm) foi transformada em $\text{m}^3 \text{ m}^{-3}$, e esses dados do modelo foram extrapolados para a sub-bacia em que a estação está localizada.

Para a análise comparativa entre os dados de umidade do solo fornecido pelas estações do CEMADEN e dos dados gerados pelo modelo SWAT, foram utilizados: (a) Coeficiente de Correlação (CC), (b) Bias e (c) Raiz quadrada do erro médio (RMSE). O CC (Equação 22) mede o grau de correlação entre duas variáveis, variando de -1 a 1. O valor sendo igual a 1, significa que as variáveis são diretamente proporcionais, ou seja, quando o valor de uma cresce, a outra também tem esse comportamento. Porém, ocorre o oposto quando o valor é -1, ou seja, as variáveis são inversamente proporcionais.

$$CC = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})(y_n - \bar{y})}{\sigma_x \sigma_y} \quad (22)$$

em todos os casos, considera-se que: em que x e y correspondem a umidade do solo estimada pelo SWAT e mensurada em campo, respectivamente, e \bar{x} e \bar{y} representam a média dessas variáveis; σ_x e σ_y são os desvios-padrão dos dados SM-SWAT e de campo, respectivamente e N é o total de dados de um determinada estação. O coeficiente de correlação foi classificado segundo os critérios adotados por Shimakura (2006): muito fraco ($\pm 0,0$ a $\pm 0,19$), fraco ($\pm 0,20$ a $\pm 0,39$), moderado ($\pm 0,40$ a $\pm 0,69$), forte ($\pm 0,70$ a $\pm 0,89$) e muito forte ($\pm 0,90$ a $\pm 1,0$).

O RMSE (Equação 23) representa a raiz do erro médio quadrático da diferença entre o valor estimado e o valor observado, neste estudo, dados do SM-SWAT e de campo, respectivamente. O uso do RMSE ajuda a demonstrar uma magnitude mais realista de

discordância entre os dados, quanto mais próximo o valor for de 0, melhor é o desempenho dessa estatística (KERR, 2007; LOEW e SCHELENZ, 2011).

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (y_n - x_n)^2} \quad (23)$$

Por fim, o Bias (RB) (Equação 24) é um índice estatístico capaz de informar se os dados observados estão sendo subestimados ou superestimados em relação à predição, neste caso, SW-SWAT. Observa-se que quando o valor é negativo, ocorre subestimação e o oposto ocorre quando o valor é positivo. Quanto mais próximo de 0, mais similares são as variáveis estudadas.

$$RB = \frac{1}{N} \sum_{n=1}^N (y_n - x_n) \quad (24)$$

2.4 Projeções climáticas

As projeções do clima para a área de estudo foram obtidas junto à plataforma PROJETA – Projeções de Mudanças do Clima para a América do Sul Regionalizados pelo Modelo Eta. Esse é um projeto do Centro de Previsão do Tempo e Estudos Climáticos (CPTEC) do Instituto Nacional de Pesquisas Espaciais (INPE) que disponibiliza diversas variáveis meteorológicas geradas por *downscaling* pelos MCR's Eta para diferentes MCG's.

O Eta é um MCR desenvolvido através de uma parceria entre a Universidade de Belgrado e o Instituto de Meteorologia de Iugoslávia, tendo sido empregado pela primeira vez pelo CPTEC/INPE em 1997, para subsidiar a previsão do tempo que vinha sendo realizada a partir de um MCG (CHOU, 1996). Atualmente, é utilizado para *downscaling* de MCG's (MESINGER et al., 2012) em inúmeros estudos sobre mudanças climáticas (CHOU et al., 2014; VIOLA et al., 2015; LYRA et al., 2018, ANDRADE et al., 2020).

Neste estudo foram utilizadas as simulações dos modelos BESM e MIROC5 regionalizadas pelo modelo Eta para os dados históricos diários que compreende 1 de janeiro de 1961 a 31 de dezembro de 2019. Quanto às projeções futuras, foram empregados dados diários para o período completo (2020 – 2099), tendo sido este período dividido em três futuros, conforme sugere o CPTEC/INPE: 2020 a 2040, 2041 a 2070 e 2071 a 2099. As seguintes

variáveis simuladas foram empregadas: i. Precipitação total – PREC ii. Temperatura máxima do ar a 2 m da superfície – MXTP iii. Temperatura mínima do ar a 2 m da superfície – MNTP.

2.5 Correção de tendência

A correção de tendência é geralmente adotada para reduzir diferenças e incertezas entre dados simulados e observados usando relações empíricas em diversas escalas. De acordo com Chen et al., (2016) as saídas dos MCGs e MCRs, como dados de precipitação e temperatura, não são utilizadas diretamente na modelagem hidrológica porque contêm erros sistemáticos, gerando desvios significativos entre dados simulados e observados.

Os dados de PREC, MXTP e MNTP simulados pelo modelo Eta-BESM e Eta-MIROC passaram por uma correção de tendência, pelo método Linear Scaling (LS) por meio do *software* Climate Model for Hydrologic Modeling (CMHyd). Este método foi selecionado, após revisão do estudo de Teutschbein e Seibert (2010), que avaliaram cinco métodos de correção de tendência para a precipitação e quatro técnicas de correção de tendência para a temperatura, e segundo os autores, esse método foi considerado o mais adequado para a correção de dados de precipitação e temperatura.

O método LS trabalha com valores mensais de correção estabelecidos sobre as diferenças entre dados simulados observados e históricos (TEUTSCHBEIN e SEIBERT, 2010; OLIVEIRA et al., 2017). O método pode ser descrito pelas equações (Equações 25 – 26):

$$P_{scen}^*(d) = P_{scen}(d) \cdot \left[\frac{\mu_m(P_{obs}(d))}{\mu_m(P_{contr}(d))} \right] \quad (25)$$

$$T_{scen}^*(d) = T_{scen}(d) + \mu_m(T_{obs}(d)) - \mu_m(T_{contr}(d)) \quad (26)$$

onde P (d) e T (d) são precipitação e temperaturas diárias, respectivamente; μ_m é a média da variável m no mês; e 'contr', 'scen' e 'obs' referem-se ao controle (período de referência), cenários e dados observados, respectivamente.

Na abordagem LS, os dados de simulação corrigidos por tendência devem concordar, em seus valores médios mensais, com os dados observados. As variáveis de precipitação e

temperatura são ajustadas por um fator baseado na razão da média mensal a longo prazo observado e nos dados do controle. Espera-se que esses fatores continuem invariáveis sob condições futuras (LENDERINK et al., 2007; TEUTSCHBEIN e SEIBERT, 2012).

Após a correção de tendência dos dados históricos e futuros, o Índice de Precipitação Padronizada foi calculado utilizando, apenas os dados de precipitação para caracterizar a climatologia na bacia. Os dados foram interpolados pelo método de Krigagem (MATHERON, 1969), em grade regular na resolução espacial de 20 km.

2.6 Índice de Precipitação Padronizada – SPI

Neste estudo, foram utilizadas escalas de tempo do SPI de 6 e 12 meses, onde foram calculadas médias móveis das séries temporais do SPI centrada nos doze meses do ano. De acordo com Santos et al. (2013), o SPI correspondente a um curto período é importante para o monitoramento de precipitações sazonais e seca agrícola; a escala semestral (SPI-6) representa eventos de média duração e é importante para monitoramento da transição entre as estações seca e chuvosa; SPI de maior duração, como o anual (SPI-12 ou mais) reflete padrões de precipitação de longo prazo, sendo utilizado para monitorar a variabilidade anual e interanual.

Com relação aos tipos de seca, o SPI pode ser utilizado em diversas aplicações. Um analista, por exemplo, pode utilizar os SPI de 1 a 2 meses para análise da seca meteorológica. Já para a seca agrícola, podem ser considerados os SPI a partir de 1 a 6 meses. SPI de 6 ou mais meses são voltados principalmente para análises de secas hidrológicas e aplicações. Para calcular os parâmetros da distribuição do SPI, é aconselhável utilizar o maior período de dados disponíveis.

Conforme Rodrigo et al. (2017), o cálculo do SPI tem início com a determinação de uma função de densidade de probabilidade que descreve as séries temporais. A distribuição gama possui bom ajuste para variáveis contínuas com limite inferior igual a zero e não têm limite superior, por isso é bastante utilizado para estudo de séries históricas de precipitação. A função gama é obtida através da equação 27 (WILKS, 2006):

$$g(x) = \frac{x^{\alpha-1} e^{-\frac{x}{\beta}}}{\beta^{\alpha} \Gamma(\alpha)} \text{ para } x > 0 \quad (27)$$

em que: $\alpha > 0$ é o parâmetro de forma; $\beta > 0$ o parâmetro de escala, $x > 0$ a precipitação (mm) e $\Gamma(\alpha)$ a função gama completa.

Para obtenção dos parâmetros α e β da distribuição gama, foi utilizada a equação 28:

$$\alpha = \frac{1}{4A} \left(\sqrt{1 + \frac{4A}{3}} \right) e^{\hat{\beta}} = \frac{\bar{x}}{\alpha} \quad (28)$$

em que \bar{x} = precipitação média.

$$A = \ln(\bar{x}) - \frac{\sum \ln(x)}{n}$$

em que n é o número de observações.

Assim, a distribuição cumulativa é transformada em distribuição de probabilidade normal (média igual a zero e desvio padrão igual a 1). Em seguida, a probabilidade de ocorrência de cada valor mensal é estimada. A essa probabilidade é aplicada a função normal inversa para calcular o SPI, que é uma variável reduzida Z_i da distribuição normal da precipitação, descrita na equação 29:

$$SPI = Z_i = \frac{(P_i - \bar{P}_i)}{\sigma_i} \quad (29)$$

em que i é a escala de tempo (6 e 12 meses); P_i é a precipitação observada (mm); e \bar{P}_i e σ_i respectivamente, a média e o desvio padrão da série ajustada.

Os valores de SPI foram classificados conforme Mckee, Doesken, Kleist (1993). Não apenas os períodos secos serão caracterizados, mas também os chuvosos (Tabela 7).

Tabela 7. Classificação dos períodos secos e chuvosos do SPI segundo Mckee, Doesken, Kleist (1993)

Valores de SPI	Classes
< -2,0	Seca extrema
-1,99 a -1,50	Seca severa
-1,49 a -1,00	Seca moderada
-0,99 a -0,49	Seva leve
-0,49 a 0,49	Seca normal
0,49 a 0,99	Levemente úmido
0,99 a 1,49	Moderadamente úmido
1,49 a 1,99	Severamente úmido
> 2,0	Extremamente úmido

2.7 Índice de Evapotranspiração de Precipitação Padronizada (SPEI)

O Índice de Evapotranspiração de Precipitação Padronizada (do inglês, Standard Precipitation Evapotranspiration Index (SPEI)) é uma variação do SPI que analisa, além da precipitação, o efeito da temperatura nos episódios de seca a partir da estimativa da evapotranspiração potencial. Vicente-Serrano et al. (2010) sugerem que o efeito da temperatura seja observado através da estimativa da evapotranspiração potencial. Assim, o SPEI reflete um déficit hídrico estimado pela diferença entre a precipitação e a evapotranspiração potencial no período considerado.

Estudos realizados por Beguería et al. (2014) e Mcevoy et al. (2012) encontraram resultados semelhantes para o SPEI utilizando os métodos de Thornthwaite e Penman–Monteith, sendo o primeiro o mais indicado para o cálculo na ausência de dados meteorológicos mais detalhados. Dessa maneira, adotou-se para o cálculo da evapotranspiração potencial o método de Thornthwaite (1948) como sugerido por Vicente e Serrano et al. (2010), o qual está detalhado na equação 30, abaixo:

$$ETp = 16K * \left(\frac{10T}{I}\right)^m \quad (30)$$

em que T_i é a temperatura média mensal i , em °C, e I é calculado pela soma mensal deste, conforme equação 31:

$$I = \left(\frac{T_i}{5}\right)^{1,514} \quad (31)$$

O expoente m na equação (30) é um coeficiente que varia com o I, podendo ser calculada pela equação $m = 6.75 \cdot 10^{-7} \cdot I^3 - 7.71 \cdot 10^{-5} \cdot I^2 + 1.79 \cdot 10^{-2} \cdot I + 0.492$. Tem-se ainda para o cálculo da evapotranspiração, K (equação 32), um coeficiente de correção, calculado em função da latitude de cada mês. N e NDM, correspondem ao número máximo médio de horas de sol para cada mês, e o número de dias do mês, respectivamente.

$$K = \left(\frac{N}{12}\right) \left(\frac{NDM}{30}\right) \quad (32)$$

O parâmetro N é então calculado de acordo com a equação 33, que varia com W_s (equação 34) (média mensal do ângulo horário do nascer do sol). Tanto a latitude φ , como a declinação solar δ estão em radianos.

$$N = \left(\frac{24}{\pi}\right) W_s \quad (33);$$

$$W_s = \arccos(-\tan \varphi \tan \delta) \quad (34)$$

φ é a latitude, em radianos, e δ é a declinação do sol, em radianos, calculada pela equação 35:

$$\delta = 0,4093 \operatorname{sen} \left(\frac{2\pi J}{365} - 1,405 \right) \quad (35)$$

onde temos que J é o dia juliano médio do mês.

Para o cálculo do SPEI foi utilizada a distribuição Generalizada de Extremos (GEV), como sugerida por Stagge e Tallaksen (2014), uma vez que o balanço hídrico não é limitado a zero (a evapotranspiração pode ser maior que a precipitação, gerando valores negativos). A distribuição GEV possui a seguinte estrutura (equação 36):

$$FDP = \frac{1}{\sigma} * \left[1 - \varepsilon * \left(\frac{x - \mu}{\sigma} \right) \right]^{\left(\frac{1}{\varepsilon - 1} \right)} * \exp \left\{ - \left[\frac{x - \mu}{\sigma} \right]^{\frac{1}{\varepsilon}} \right\} \quad (36)$$

em que ε , σ e μ são, respectivamente, os parâmetros de forma, escala e posição. Se o valor de $\varepsilon < 0$, a GEV representa a forma assintótica de valores mínimos e existe se $x > (x-\mu) \varepsilon$. Se $\varepsilon > 0$, GEV representa uma distribuição de máximos se $x < (x-\mu) \varepsilon$ (NAGHETTINI, 2017). Após a aplicação desta distribuição, o procedimento para cálculo do SPEI é o mesmo do SPI. Vicente-Serrano et al. (2010) não apontam uma classificação específica para o SPEI, mas compara os resultados ao SPI correspondente. Dessa maneira, adotou-se os mesmos intervalos e a mesma classificação segundo os critérios do SPI.

2.8 Índice de Umidade do Solo Padronizado – (SSMI)

O SSMI é um índice agrícola para obtenção da umidade normalizada do solo, que denota o quanto o valor dessa variável se distancia da média, devido ao desvio padrão de uma série de dados, baseando-se, portanto, na distribuição normal padrão.

O SSMI foi obtido a partir de dados padronizados de umidade do solo seguindo a metodologia proposta por McKee et al. (1993) para o cálculo do Índice de Precipitação Padronizado (SPI), sendo obtido por meio das seguintes etapas: 1) obtenção de séries temporais de dados mensais de umidade do solo; 2) aplicar a função de probabilidade adequada para os dados obtidos no ‘item’ 1 para escolher períodos acumulados, por exemplo, 6 ou 12 meses; 3) obtenção da probabilidade cumulativa; 4) aplicação da função inversa para obter os valores padronizados de distribuição normal, ou seja, valores com média 0 e desvio padrão 1.

No estudo foram utilizadas as escalas de 6 e 12 meses. A função de probabilidade adotada para o SSMI foi a log-logística, semelhante ao SPEI e utilizada por Oertel et al. (2018), que considera que a série de dados de umidade do solo se ajusta bem a esta função de distribuição.

3. RESULTADOS E DISCUSSÃO

3.1 Correção de tendência pelo método Linear Scaling

Os gráficos relativos às correções de viés dos dados históricos, projetados pelos modelos Eta-BESM e Eta-MIROC5 pelo método de Linear Scaling, são apresentados na Figura 35. No

total foram corrigidas doze estações pluviométricas, mostrando que o método corrigiu adequadamente os dados históricos brutos dos modelos climáticos entre o período de 1961 – 2019. Esta abordagem mostrou ser eficaz para o estudo de dados de precipitação em trabalhos anteriores (PIANI et al., 2010; TEUTSCHBEIN e SEIBERT, 2012). Em algumas estações, essa correção deixou os dados muito próximos dos observados, como pode ser visto nos postos dos municípios de Flores, Mirandiba, São José do Egito e Serra Talhada.

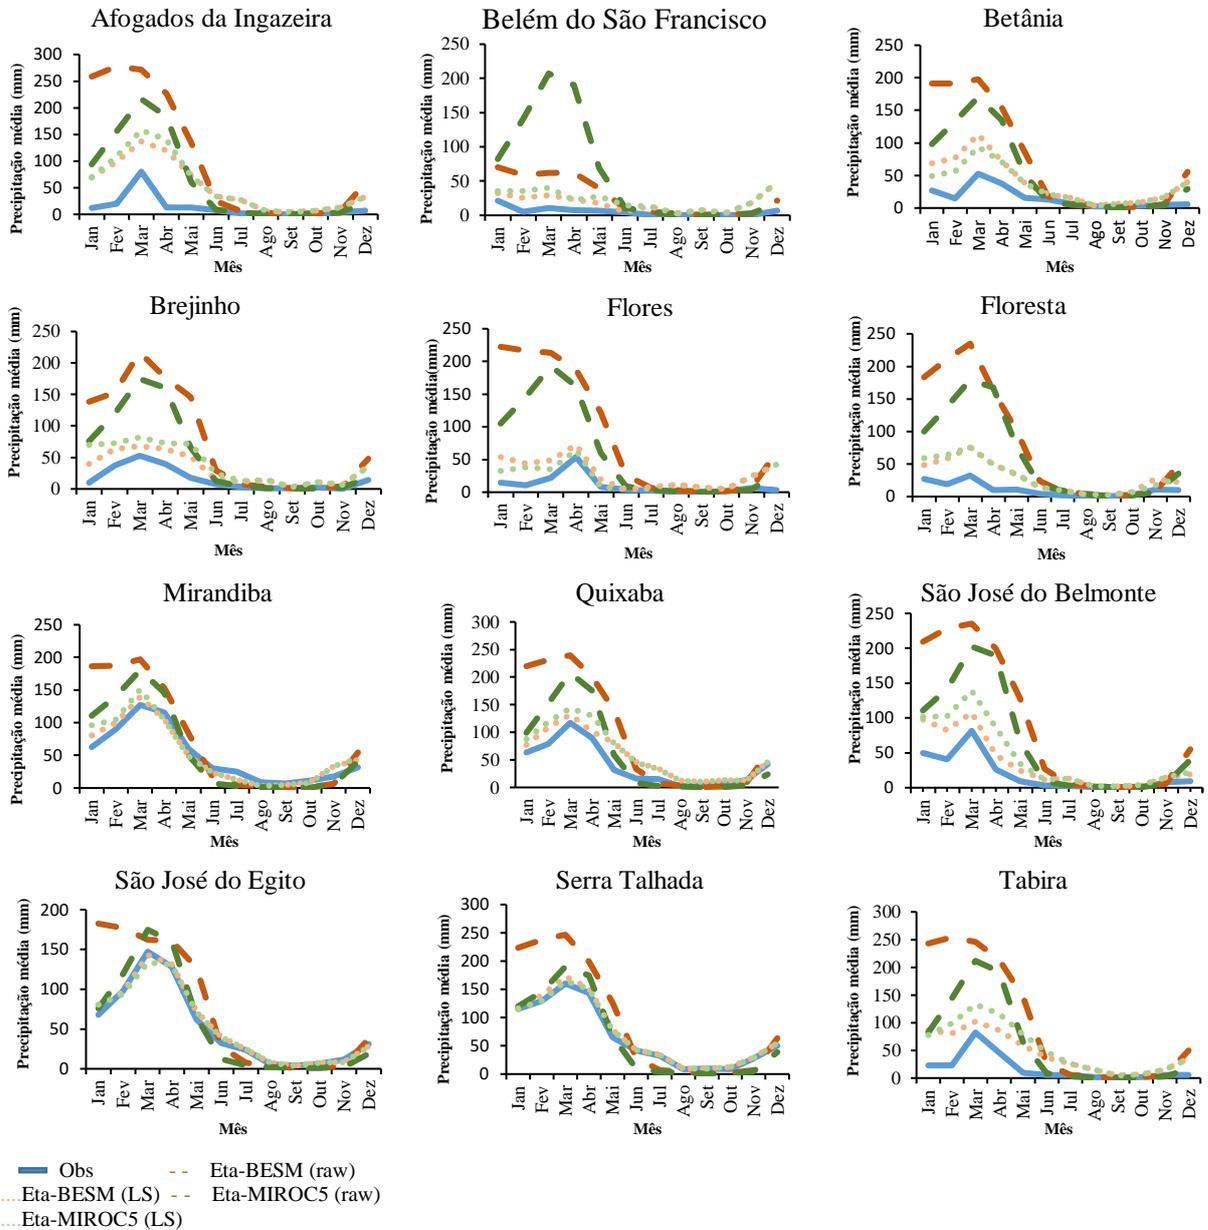


Figura 35. Correção de bias pelo método Linear Scaling para precipitação (obs = dados históricos observados (1961-2005); raw = dados históricos brutos (1961-2005); LS = dados históricos corrigidos (1961-2005) pelo método de escala linear).

Em relação à temperatura máxima e mínima dos modelos climáticos (Figura 36), o ajuste de correção de viés produziu um aumento nas médias da temperatura máxima na estação de Flores. Já em Triunfo, observou-se que os dados corrigidos ficaram muito próximos aos dados observados pelas estações.

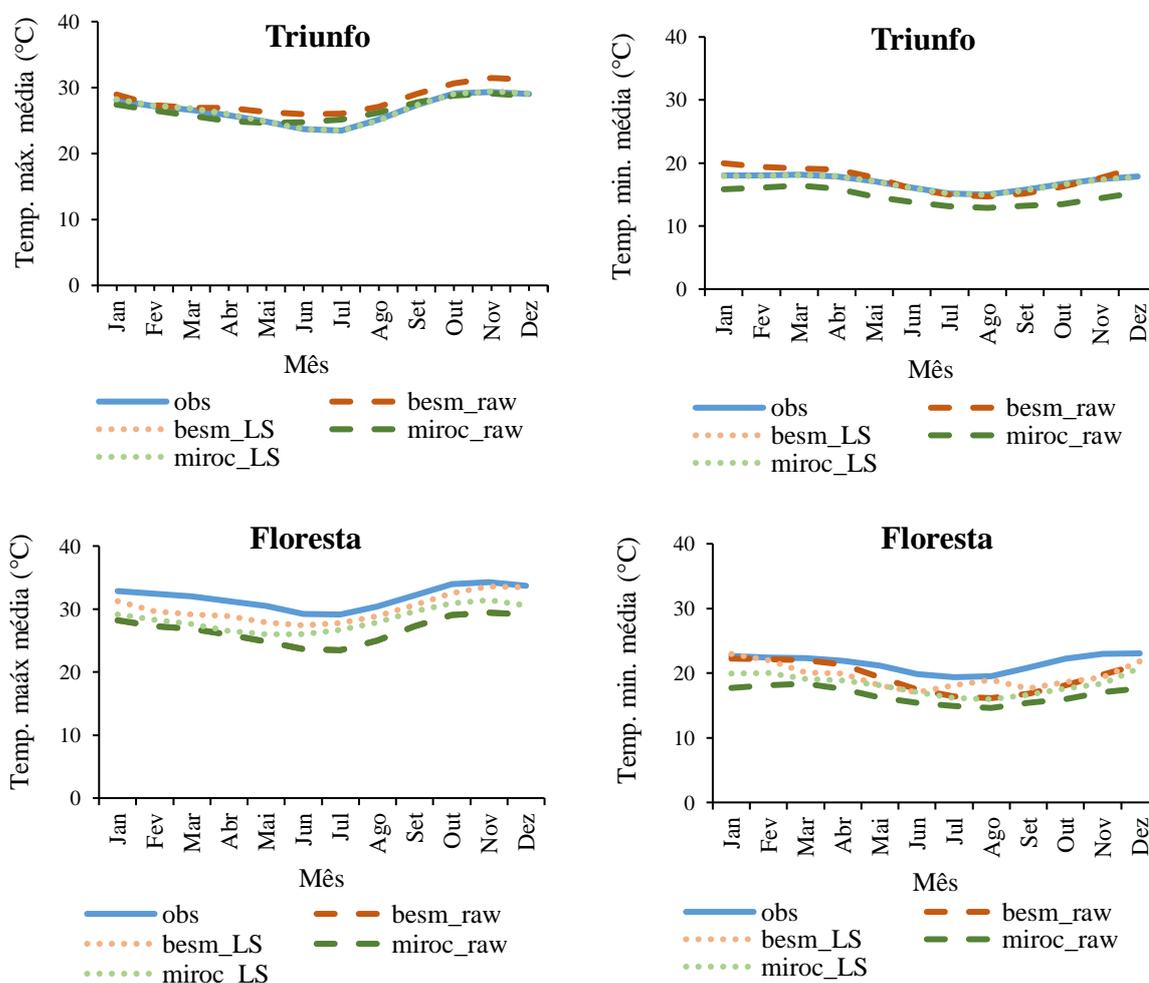


Figura 36. Correção de bias pelo método Linear Scaling para precipitação (obs = dados históricos observados (1961-2005); raw = dados históricos brutos (1961-2005); LS = dados históricos corrigidos (1961-2005) pelo método de escala linear)

As projeções corrigidas para precipitação pluviométrica e temperaturas anuais do Eta-MIROC5 e Eta-BESM para os três períodos futuros conforme os RCPs estão resumidas na Tabela 8 e 9, respectivamente. Os resultados indicam que a bacia certamente sofrerá com menos chuvas e maiores temperaturas para ambos os cenários de emissão e modelos climáticos. A precipitação média projetada diminuiu em todos os três períodos, variando de 914,16 mm em curto prazo a 900,21 mm a longo prazo para o modelo Eta-BESM, para o Eta-MIROC5 houve variação de 909,95 e 890,78 mm, respectivamente, sob o RCP 4.5.

Para o RCP 8.5, notou-se que a precipitação tende a diminuir para 1.041,07 mm a curto prazo e 815,59 mm a longo prazo. Ouyang et al. (2015), avaliando os impactos das mudanças climáticas sob cenários de RCP em fluxo na bacia hidrográfica de Huangnizhuang, também perceberam que a precipitação diminui no período de 2011 – 2040 sob três RCPs estudados (2.6, 4.5 e 8.5).

Em relação à temperatura, foi notado um aumento em todos os cenários e modelos climáticos, pois no modelo Eta-BESM projetou um acréscimo de 1,0 °C e 0,9 °C e no Eta-MIROC de 1,18 °C e 0,8 °C para a temperatura máxima e mínima, respectivamente no cenário RCP 4.5. No cenário RCP 8.5, as projeções são mais preocupantes, tendo um aumento de mais de 2 °C em todas as temperaturas e ambos os RCPs, chegando a quase 3 °C no modelo Eta-BESM na máxima.

Ouyang et al. (2015) encontraram aumento nos valores máximo e mínimos de temperatura temporalmente. O incremento máximo encontrado foi de 4,1°C e 3,8°C para o período de 2071 – 2100 sob RCP 8.5 para as temperaturas máxima e mínima, respectivamente. É muito importante estudar as variações de temperatura, pois, conforme os autores, esta variável está intimamente relacionada aos processos de evapotranspiração e fluxo.

Tabela 8. Precipitação e temperatura do Eta-MIROC5 para os três tempos futuros períodos sob os RCPs

Período	RCP 4.5			RCP 8.5		
	Prec.	Temp.máx	Temp.min	Prec.	Temp.máx	Temp.min
2020 - 2040	914,16	27,09	15,92	831,36	27,59	16,36
2041 - 2070	858,85	28,24	16,52	749,37	29,20	17,40
2071 - 2099	900,21	28,27	16,82	695,38	30,52	18,56

Tabela 9. Precipitação e temperatura do Eta-BESM para os três tempos futuros períodos sob os RCPs

Período	RCP 4.5			RCP 8.5		
	Prec.	Temp.máx	Temp.min	Prec.	Temp.máx	Temp.min
2020 – 2040	909,95	28,98	18,40	927,32	29,30	19,02
2041 – 2070	892, 31	29,62	18,91	771,20	30,29	19,94
2071 – 2099	890,78	29,98	19,20	659,86	31,34	20,96

3.2 SPI Dados observados

O SPI pode ser calculado em diversas escalas de tempo, esse permite avaliar os impactos da seca em diversas áreas conforme a sua duração. A Figura 37 apresenta a distribuição temporal de 58 anos desse índice referente ao período de seis meses (SPI6) e doze meses (SPI12), sendo gerado para toda a Bacia Hidrográfica do Rio Pajeú após interpolação espacial usando o inverso do quadrado da distância (IQD). Analisando o comportamento da série histórica dos dados observados, nota-se que a partir de 1984 foi verificada a seca extrema (-2,2), na Bacia Hidrográfica do Rio Pajeú, estendendo-se por vários intervalos de anos.

O período entre 1990 e 2003 foi o que mais apresentou a maior frequência de eventos de seca, com mais de uma década de valores negativos de SPI, tendo pequenos intervalos de valores positivos. Na bacia houve um intervalo de valores positivos bem representativos no período de 1985 a 1989, visto que, em 1986 o SPI teve valores maiores que 3, ou seja, foi um ano extremamente chuvoso. Entre os anos de 2012 a 2017, houve secas recorrentes e persistente, concordando com estudos prévios sobre a avaliação da seca no Nordeste brasileiro por SPI (BRITO et al., 2017; MARENGO et al., 2017; CUNHA et al., 2018).

Barbosa et al. (2019), analisaram o impacto da seca na vegetação de caatinga para o Nordeste brasileiro (NEB) e um dos índices utilizados foi o SPI, abrangendo as séries temporais de março – abril – maio, para o período 1901 a 2016 e observaram que dentre os anos com $SPI \leq -1$, foram identificados os anos de 1991, 1992, 1993, 1998, 2007, 2012 e 2016. Para os autores o período mais longo de anos consecutivos em que a precipitação total sazonal esteve abaixo da média, ou seja, valores negativos indicando quantidade abaixo do normal de precipitação, ocorreu entre 2010 a 2016, sendo o mais seco em 2012.

Os valores estimados pelo modelo Eta-Besm foram mais semelhantes aos valores observados pelos dados das estações do que o Eta-MIROC5. Também é possível perceber que os modelos tendem a apresentar uma frequência maior de secas moderadas e anormais do que os dados in situ.

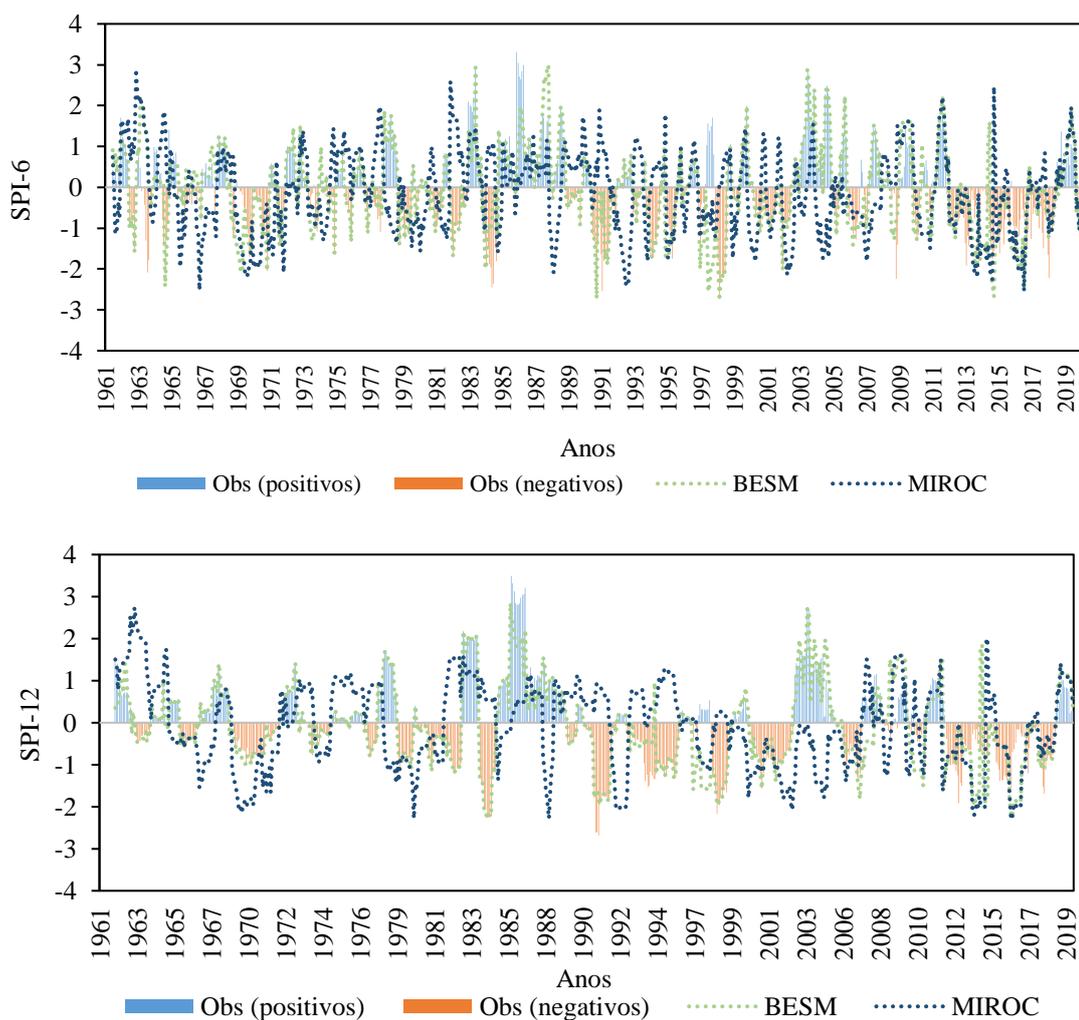


Figura 37. Comportamento do SPI6 e do SPI12 para a bacia hidrográfica do rio Pajeú simulados pelos modelos Eta-BESM e Eta-MIROC5 e os dados observados para o tempo presente (1961 – 2019).

Soares, Nobrega e Galvêncio (2018), analisaram os indicadores climáticos de desertificação na bacia hidrográfica do rio Pajeú, buscando-se identificar tendência climática na precipitação, no índice de aridez e no índice de precipitação padronizada. Os autores observaram que em Betânia, Floresta e Mirandiba/Açude Serrinha, às três localidades analisadas, é que a quantidade de anos considerados severamente secos (-1,5 e -1,99) e extremamente secos (menor ou igual a -2) foram maiores que a quantidade de anos muito úmidos (1,5 e 1,99) e extremamente úmido (maior ou igual a 2). Além disso, só se observaram anos muito ou extremamente úmidos entre os anos de 1965 e 1989, em simultâneo, em que só foram observados anos severos ou extremamente secos após 1990. Os únicos anos considerados muito ou extremamente úmidos ao menos em uma das séries analisadas foram 1974, 1985 e 1988. Já os anos considerados severos ou extremamente secos em pelo menos uma das séries

foram os anos de 1993, 1996, 1997, 1998, 1999, 2001, 2012, 2013 e 2014. Em alguns destes anos ocorreram eventos de El Niño de intensidade forte e se configurou a fase positiva no Padrão Dipolo do Atlântico.

3.3 Projeção do comportamento do SPI na Bacia Hidrográfica do Pajeú ao longo do século XXI

3.3.1. Análise das projeções segundo o modelo Eta-BESM

A Figura 38 apresenta o comportamento do SPI em dois períodos, seis meses e doze meses, respectivamente, projetado pelo modelo Eta-BESM tendo-se a premissa o cenário 4.5 e 8.5 para a Bacia do rio Pajeú. Na análise do SPI de 6 meses, foi possível observar que o cenário 4.5 simula um aumento da frequência de eventos severos de seca, e que no ano de 2032 tende a ocorrer a maior estiagem na bacia. A permanência de um evento crítico nessa escala temporal garante a informação da qualidade hídrica, pois, valores significativos indicam comprometimento ou favorecimento do regime pluviométrico.

A distinção da série analisada fica evidenciada ao se observar os gráficos com a distribuição dos valores do SPI-12, através dos quais se nota que há uma maior quantidade de anos com sinal negativo nos primeiros vinte e quatro anos da série, ao passo que a partir de 2025 há uma maior frequência da ocorrência de anos positivos, se configurando como um período mais chuvoso. Além dos eventos indicados terem durações maiores, seus efeitos têm impactos mais marcantes sobre as áreas atingidas. Eventos críticos nessa escala a partir da categoria moderada já condicionam o potencial agrícola e hídrico.

Já o cenário 8.5, sendo projetado pelo modelo supracitado, os eventos mais severos de seca ocorrem após o ano de 2056 ($SPI_6 = -1,83$; $SPI_{12} = -1,90$) e estende-se até o fim da série analisada. Um fato importante, que deve ser ressaltado é que em 2090 até 2099, quase uma década, o Eta-BESM simula uma seca extremamente severa e contínua. A principal diferença entre os cenários pode ser observada ao final do século XXI, visto que o modelo com o cenário 8.5 simula um aumento das concentrações de gases do efeito estufa continuamente, assim, eventos de seca são mais recorrentes do que no RCP 4.5 (CHOU et al., 2014). De maneira geral, observa-se que o RCP 8.5 tende a simular valores mais negativos para o índice SPI ao final do século vinte e um, no modelo Eta-BESM.

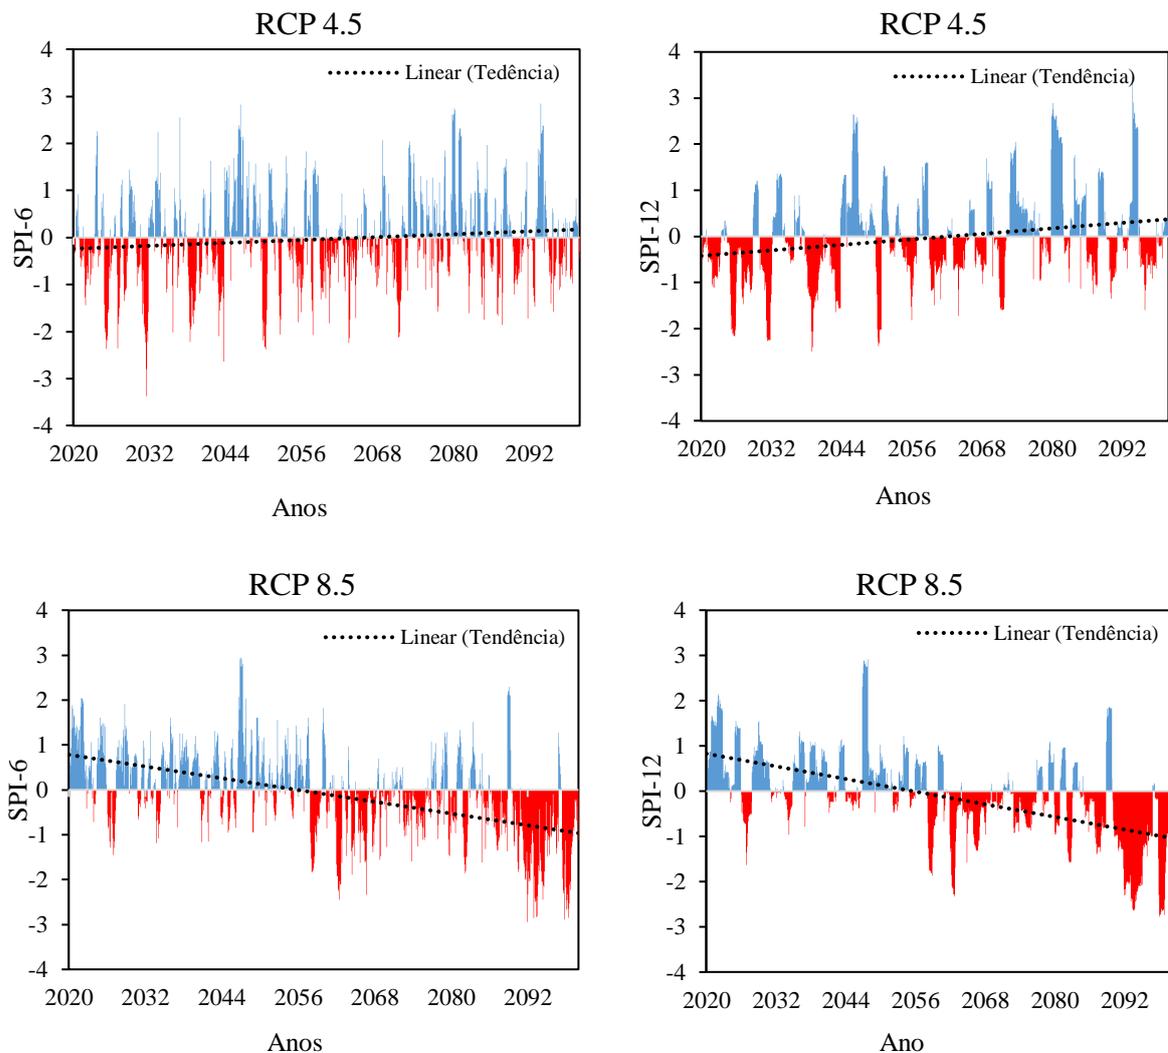


Figura 38. Projeções do SPI referentes aos períodos de 6 e 12 meses para a bacia hidrográfica do rio Pajeú simulados pelo modelo Eta-BESM na forçante 4.5 e 8.5.

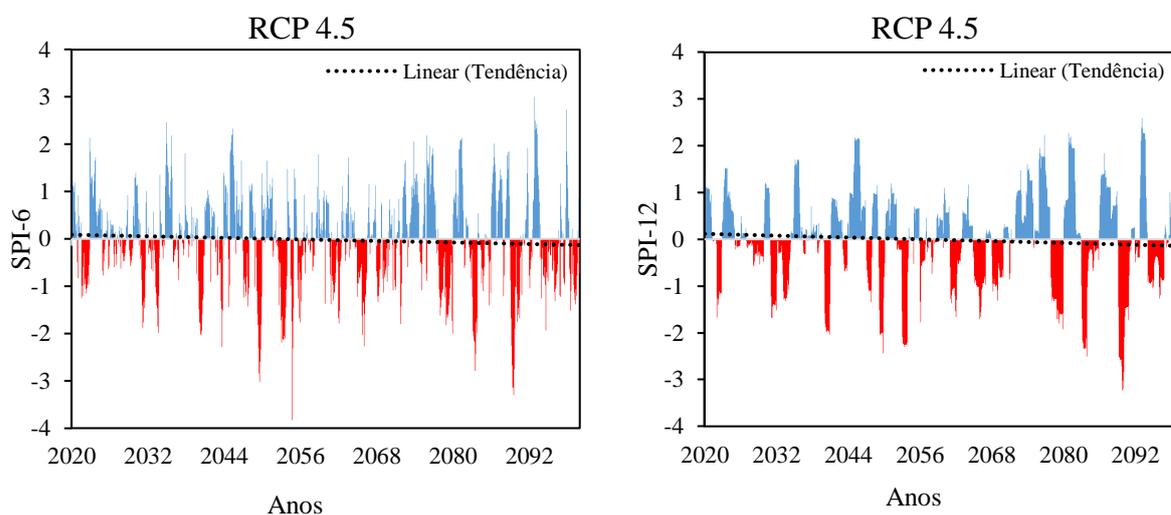
3.3.2 Análise das projeções segundo o modelo Eta-MIROC5

Na Figura 39 observa-se que o modelo Eta-MIROC5 simula mais eventos de seca do que o modelo Eta-BESM, onde foi observado tendência negativa para o SPI6 e SPI12. Com base nessas projeções, vários eventos extremamente secos foram simulados para o RCP 4.5, destacando os anos de 2056 (SPI6 = -3,90) e 2091 (SPI6 = -3,20). Para o SPI12, o ano de 2091 obteve o maior valor negativo gerado na série (SPI = -3,35).

No RCP 8.5, nota-se que existe mais eventos extremos de seca e chuva em relação a outra forçante radiativa. Valores de SPI maiores que três foram vistos nos anos de 2022 e 2084 para o período de seis meses, o que mostrar ser os anos mais chuvosos segundo a projeção feita

pelo Eta-MIROC5. Em relação aos valores negativos, é possível destacar que há uma tendência decrescente dos valores de SPI até o final do século, significando ausência de períodos de chuva significativa, principalmente a partir do ano de 2090. Da mesma forma que, o modelo Eta-BESM projetou secas mais intensas após os anos de 2056, levando uma tendência negativa até o fim da série, o Eta-MIROC5 gerou dados semelhantes, porém, com uma tendência mais negativa na forçante radiativa 4.5.

Em síntese, a análise de possíveis mudanças climáticas para o fim século XXI na bacia mostrou concordância entre as projeções do BESM e MIROC5, regionalizadas pelo MCR Eta. Souza et al. (2019) avaliou as mudanças climáticas projetadas pelo modelo climático regional Eta dirigido pelos modelos globais HadGEM2-ES e MIROC5 para o início (2011 – 2040) e metade (2041 – 2070) do século XXI no Estado do Tocantins, para as trajetórias representativas de concentração, RCP 4.5 e RCP 8.5, e destacaram que a mudança mais severa para a precipitação foi projetada pelo Eta-MIROC5.



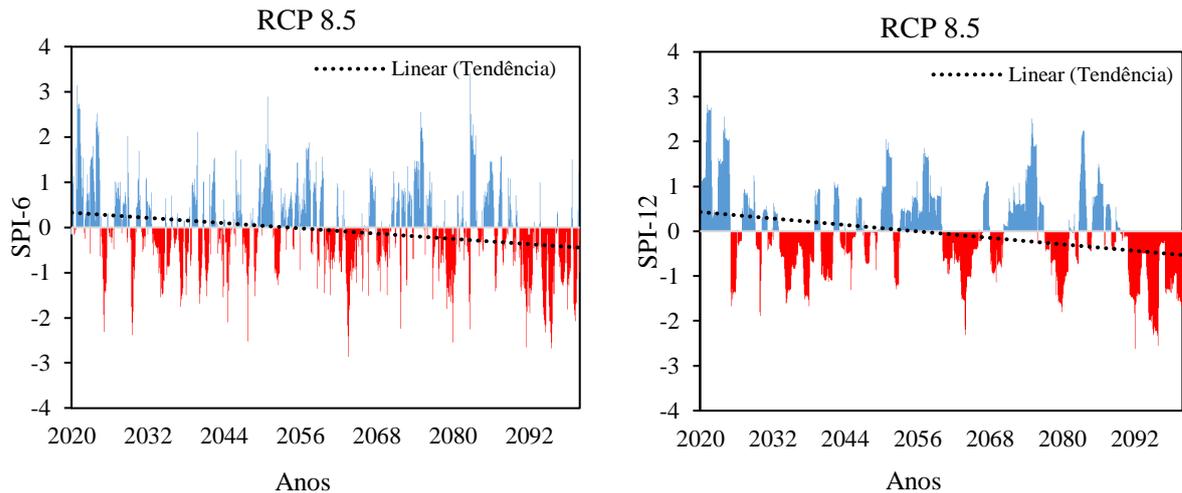


Figura 39. Projeções do SPI referentes aos períodos de 6 e 12 meses para a bacia hidrográfica do rio Pajeú simulados pelo modelo Eta-MIROC5 na forçante 4.5 e 8.5.

Para melhorar a compreensão do estudo de seca na bacia hidrográfica do rio Pajeú, foi realizada uma espacialização dos dados interpolados pelos modelos e forçantes radiativas, do índice do SPI (Figura 40), para identificar quais partes da bacia pode sofrer com os impactos da seca ao longo do fim do século. Para examinar melhor os efeitos das mudanças climáticas, os dados foram divididos em três períodos: 2020 – 2040, 2041 – 2070 e 2071 – 2099, ou seja, período curto, médio e longo, e os valores foram os mesmos já classificados conforme Mckee, Doesken, Kleist (1993).

Como pode ser observado, nos primeiros vinte anos podem não ocorrer secas extremas segundo os modelos utilizados, exceto nas projeções do Eta-BESM na RCP 4.5, onde a parte sul da bacia mostra indícios de que pode ocorrer secas moderadas. Soares, Nobrega e Galvêncio (2018), analisaram os indicadores climáticos de desertificação na bacia hidrográfica do rio Pajeú, buscando-se identificar tendência climática na precipitação, no índice de aridez e no SPI, utilizando séries históricas de pluviometria do período de 1965 a 2014 de 12 localidades, foram encontradas tendências negativas (de diminuição) com significância estatística de 95% para a chuva e os índices de aridez e de precipitação padronizada de três postos pluviométricos situados na porção sul da bacia. Demonstrando que esta região próxima ao rio São Francisco tende a se tornar mais seca.

Entre o período que compreende os anos de 2041 e 2070, em todas as situações projetadas pelos modelos mostraram uma predominância de seca leve em quase todo o território da bacia. Já no período mais longo (2071 – 2099) pode-se observar três cenários, no primeiro

temos que o Eta-BESM RCP 4.5 mostra uma espacialização mais úmida em boa parte da área de estudo, no Eta-MIROC, na mesma forçante radiativa, verifica-se que pode ocorrer secas moderadas e severas, principalmente na região sul da bacia, e no RCP 8.5, nos dois modelos, existiu uma cessação de chuva por toda extensão da área.

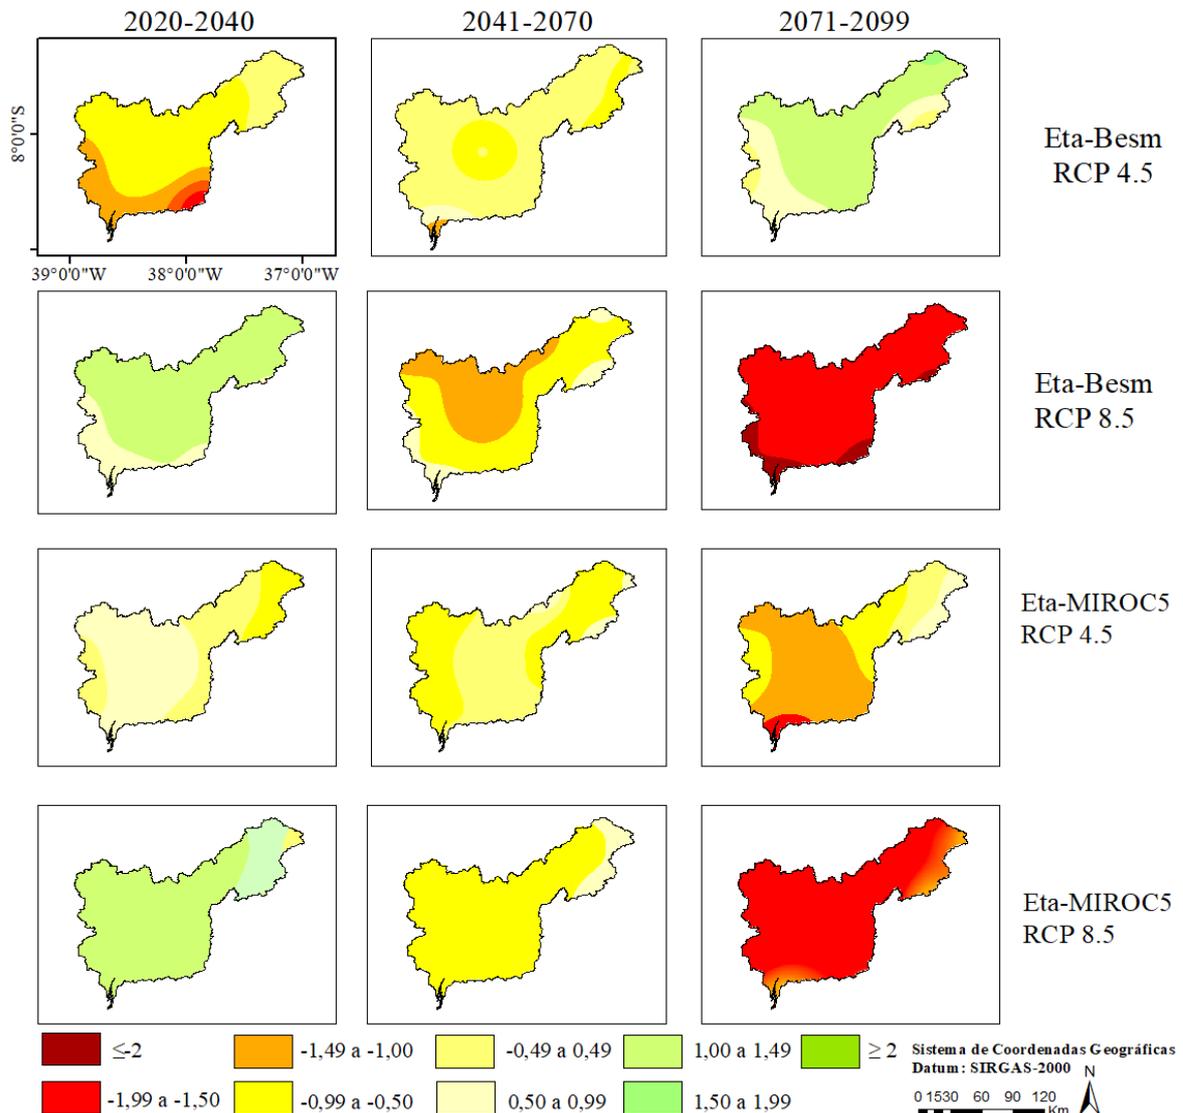


Figura 40. Comportamento de futuras secas baseado no SPEI-12 obtido pelos modelos climáticos na Bacia Hidrográfica do Rio Pajeú.

3.4 Projeção do comportamento do SPEI na bacia hidrográfica do rio Pajeú ao longo do século XXI

3.4.1 Análise das projeções segundo o modelo Eta-BESM

O SPI depende da precipitação como a variável de entrada única, enquanto o SPEI é derivado da chuva e temperatura na forma de um balanço hídrico simples e que permite a realização de análises em diversas escalas de tempo. Analisando a Figura 41, por meio dos dados gerados do modelo Eta-BESM, para a bacia, observa-se uma diferença no cenário 4.5, nota-se que os episódios de seca estão agrupados de forma diferente ao SPI, onde houve tendência negativa no decorrer da série temporal.

Nos anos de 2089 (SPEI = -3,20) e 2093 (SPEI = -2,95), foram observados os eventos extremamente secos para o RCP 4.5, por outro lado, o cenário 8.5 apresentou apenas um ano com seca extrema, sendo em 2086 (SPEI = 3,70). Em ambos os períodos estudados, seis e doze meses, observa-se que os eventos de seca, tendem a se tornar mais presentes na segunda metade do século XXI. O aumento gradual da temperatura até o final do século contribuiu para que os valores de evapotranspiração potencial fossem maiores. Dessa maneira o balanço hídrico vertical (P-ETp) foi ficando cada vez menor, de forma que boa parte dos valores negativos de SPEI ficassem concentrados no fim da série em todos os cenários e forçantes radiativas.

Zhai et al. (2020) verificou que o SPEI-12, com base no sc-PDSI, projetou um aumento na ocorrência de eventos de secas de curto prazo e persistentes no futuro. Esses dois índices baseados em PET (SPEI-12 e sc-PDSI) delineiam que há algumas diferenças em relação à significância e magnitude das mudanças. Isso pode ser um indicativo da evolução futura diferente do processo que controla a ocorrência de seca em diferentes escalas de tempo. Já o SPEI mostrou melhor desempenho na caracterização de futuras secas na Índia. Adnan et al. (2018) relatou que o desempenho do SPEI foi capaz de fornecer uma imagem real das condições de seca no Paquistão.

Haile et al. (2020) avaliaram as mudanças futuras da seca na África Ocidental usando modelos climáticos, o SPEI e o SPI foram utilizados para classificar a seca na região. Como resultados, o SPEI mostrou um aumento da seca no final do século XXI de 16%, 36% e 54% sob o RCP 2.6, 4.5, e 8,5, respectivamente, na área estudada, tendo como conclusão ser um índice que mostra mais condições de seca no futuro em comparação com o SPI.

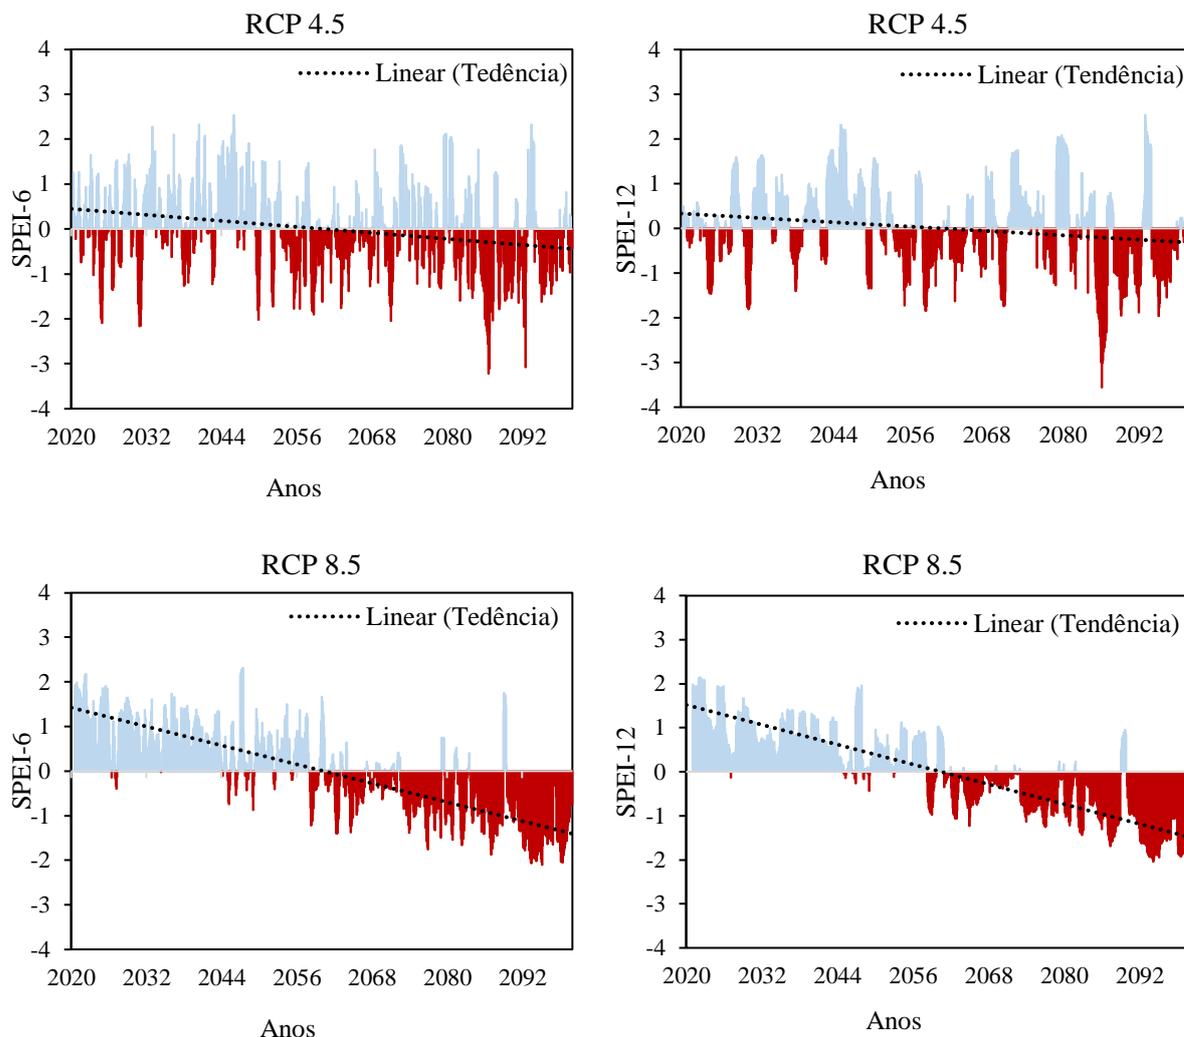


Figura 41. Projeções do SPEI referentes aos períodos de 6 e 12 meses para a bacia hidrográfica do rio Pajeú simulados pelo modelo Eta-BESM na forçante 4.5 e 8.5.

3.4.2 Análise das projeções segundo o modelo Eta-MIROC5

A Figura 42 ilustra o comportamento do SPEI com as projeções do modelo Eta-MIROC5 nos períodos de seis e doze meses. Da mesma forma que foi observado no modelo Eta-BESM, a tendência da série também foi negativa, ocorrendo uma sucessão de secas por longos períodos, ficando mais evidente no meio até o fim do intervalo analisado.

Os resultados também mostraram que esse modelo, em específico, gerou dados de SPEI mais negativos que o outro, e quando compara-se o RCP 4.5 e 8.5, o último tem um comportamento de secas persistentes por mais de uma década. Wang et al. (2019) utilizou três modelos GCMs do CMIP5, como CNRM-CM5, HadGEM2-ES e MIROC5, para avaliar as

futuras condições de seca sob dois cenários de vias de concentração (RCPs), RCP4.5 e RCP8.5. O SPEI foi o índice utilizado para verificar as variações da tendência, frequência e características da seca e suas respostas às mudanças climáticas. A pesquisa mostrou que a frequência e as características da seca tendem a se fortalecer sob o cenário de alta concentração de RCP8.5, e a tendência é maior que a de baixa concentração utilizando o modelo MIRCO5.

Em comparação com o SPI, gerado pelos dados do mesmo modelo, verificou-se que o SPEI gera mais eventos de seca na área da bacia, mesmo utilizando semelhante classificação. Esse fato ocorre porque o último índice utiliza dados de temperatura e evapotranspiração. Shiru et al. (2020), analisando a seca na Nigéria, relatou que geralmente, uma tendência decrescente no SPEI para uma determinada região, estava correlacionada fortemente com o aumento da temperatura, sugerindo que as secas foram mais frequentes e persistentes.

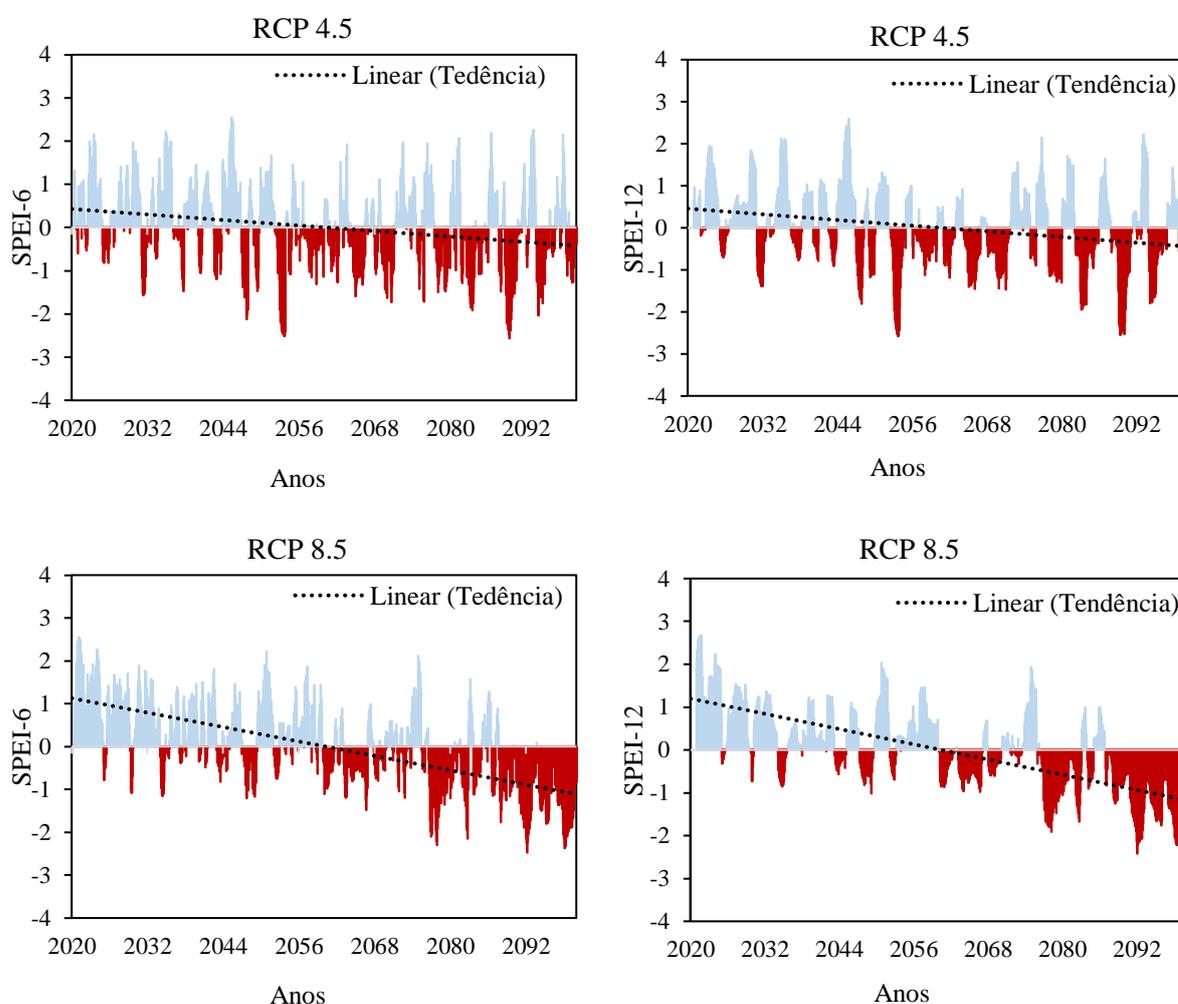


Figura 42. Projeções do SPEI referentes aos períodos de 6 e 12 meses para a bacia hidrográfica do rio Pajeú simulados pelo modelo Eta-MIROC5 na forçante 4.5 e 8.5.

Analisando o comportamento da espacialização dos dados do SPEI (Figura 43), observam-se algumas diferenças em relação ao comportamento gerados pelo SPI, visto que, nos primeiros vinte anos futuros a área da bacia pode não sofrer tanto com a escassez hídrica nas projeções de RCP 8.5, porém, conforme o RCP 4.5 pode apresentar uma seca de leve intensidade no sul da bacia.

Para o resto de toda a séria, fica percebido que pode existir um aumento da seca até o fim do século em todas as partes da bacia do rio Pajeú, e que nas últimas décadas a parte sul continuou sendo a mais afetada. Esse fato é bastante preocupante e que valoriza o estudo na região, pois segundo o Instituto Nacional do Semiárido (INSA, 2014) o SAB possui seis núcleos de desertificação, sendo pequenas partes do território com elevada degradação. Um desses núcleos está situado no município de Cabrobó que fica muito próximo da bacia do rio Pajeú. Segundo o Atlas das secas (NÚÑEZ COBO e VERBIST, 2018) durante o século vinte os eventos de seca a nível global causaram mais da metade das mortes associadas a desastres naturais e foi, depois das inundações, o desastre natural com o segundo maior nível de impactos humanos.

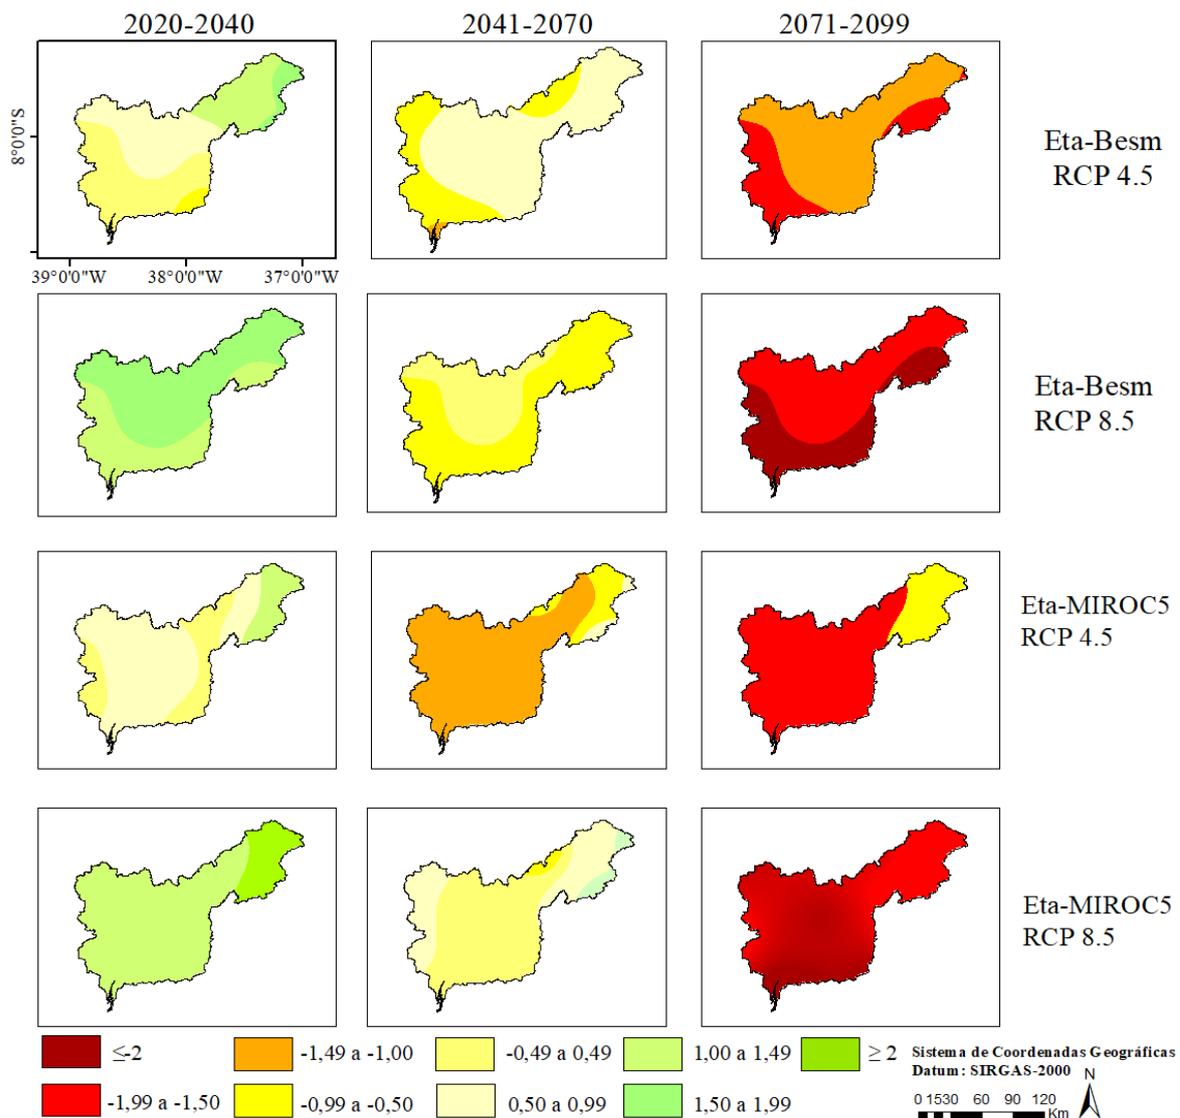
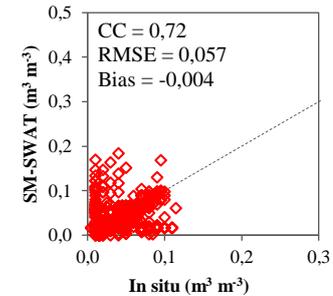
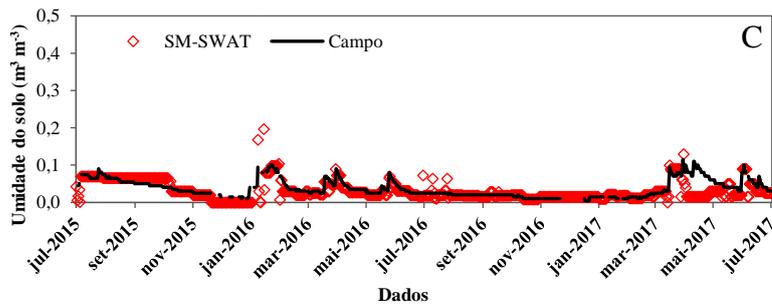
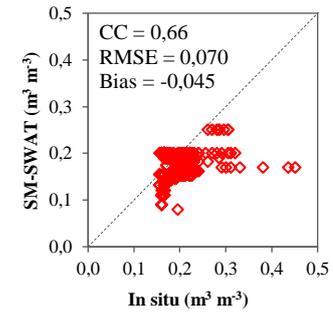
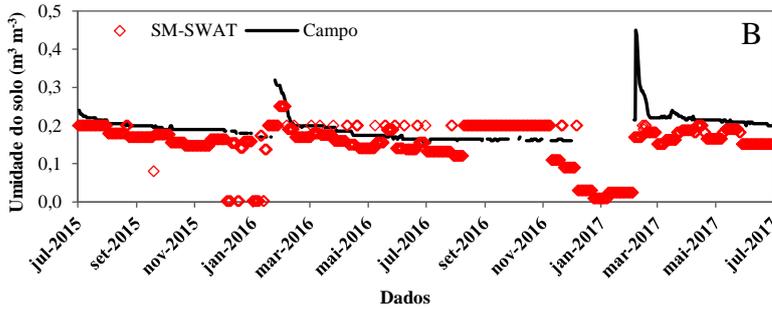
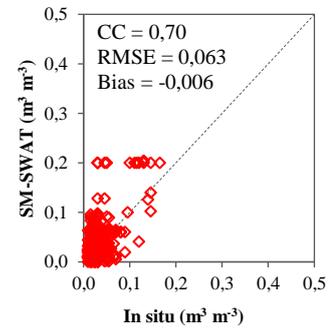
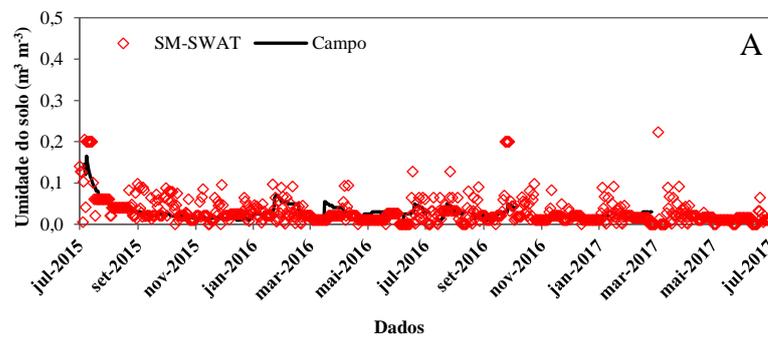


Figura 43. Comportamento de futuras secas baseado no SPEI-12 obtido pelos modelos climáticos na Bacia Hidrográfica do Rio Pajeú.

3.5 Validação dos dados de umidade de solo gerados pelo SWAT

A Figura 44 ilustra os valores de SM gerados pelo modelo SWAT e os medidos em campo pela rede de observação do CEMADEN, utilizando o intervalo de tempo diário na profundidade de 20 cm, com seus respectivos diagramas de dispersão com valores das métricas estatísticas utilizadas. Realizar uma validação dos dados de umidade do solo foi necessário, já que o modelo SWAT foi apenas calibrado.

Nas estações de Iguaraci (A) e Mirandiba (C) foram encontrados fortes correlações com dados médios de SM-SWAT, com CC igual e superior a 0,70, respectivamente, para o período de julho de 2015 a 2017. Nas estações de Itacuruba (B), São José do Egito (D) e Tuparetama (E) houve uma moderada correlação, mas esses resultados são bastantes satisfatórios, pois os dados dos sensores são pontuais e a saída do modelo é representada em sub-bacia. Outro fato que deve ser considerado é que nas estações existem pequenos intervalos de falhas, e para Lu et al. (2016), estações com falhas e perda de dados comprometem a confiabilidade para utilização em diversas aplicações, o que inclusive, compromete uma melhor correlação entre ambos. O conjunto de Bias calculado apresentou valores predominantemente negativos, o que revela uma subestimação dos dados SM-SWAT em relação à rede de observação, ficando mais expressivo na estação de Itacuruba.



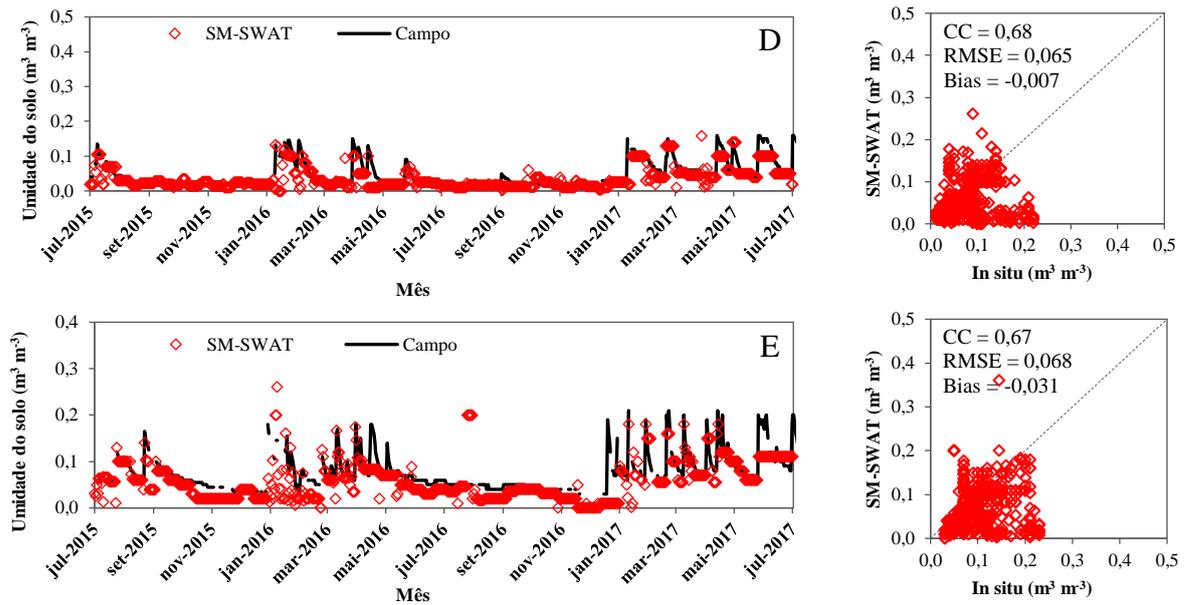


Figura 44. Comparação dos dados diários de umidade do solo medidos in situ e estimados pelo modelo SWAT (SM-SWAT) para o período de julho de 2015 a julho de 2017, nas estações de (A) Iguaraci, (B) Itacuruba, (C) Mirandiba, (D) São José do Egito e (E) Tuparetama.

Como esses resultados foram satisfatórios, mostra que o modelo foi calibrado de forma adequada para utilizar dados de projeções futuras dos modelos climáticos, tanto de precipitação pluviométrica quanto temperatura do ar, para diferentes cenários. Com os resultados gerados de umidade do solo do modelo SWAT, foi calculado o SSMI, seguindo a metodologia proposta por McKee et al. (1993), para a bacia hidrográfica do rio Pajeú.

3.6 Projeção do comportamento do SSMI na bacia hidrográfica do rio Pajeú ao longo do século XXI

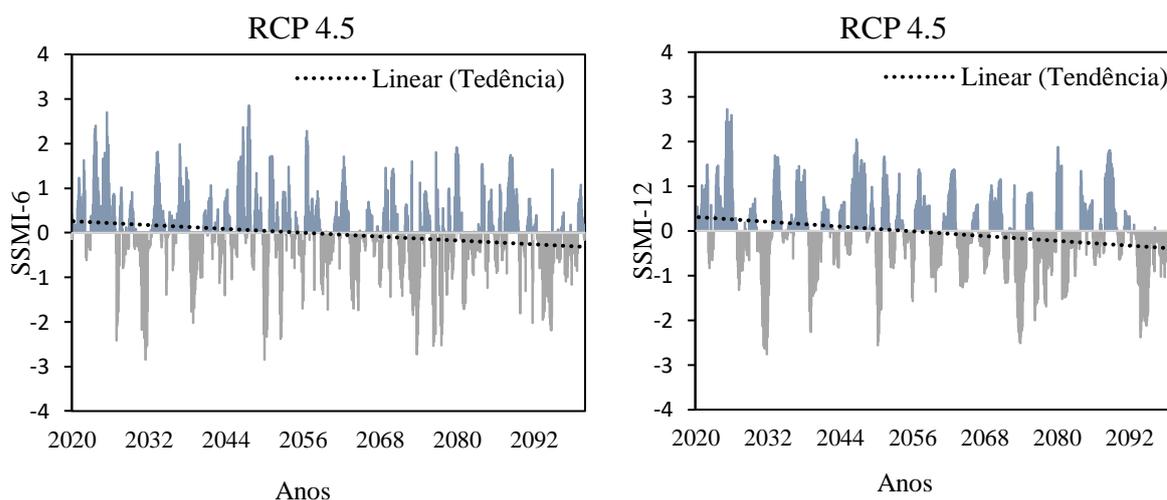
Os índices para avaliar a umidade do solo são relativamente novos, e um estudo de seca agrícola na bacia hidrográfica localizada no semiárido por meio dessa variável é muito importante, pois segundo Sánchez (2016) a seca agrícola é definida na zona de raízes e a redução da umidade do solo nesta área acaba por intensificar e potencializar este tipo de seca. A umidade deficiente no solo junto à cultura pode afetar a germinação, o crescimento e o desenvolvimento da planta, conduzindo à redução do rendimento final.

O conceito de propagação da seca procura a ligação existente entre os diferentes tipos de secas. Alguns autores destacaram a capacidade de os índices de seca serem utilizados para monitoramento e alerta (BARKER et al., 2016; BACHMAIR et al., 2016) visando à preparação para a seca. Essa etapa teve a proposta de verificar a seca agrícola na bacia por meio do índice SSMI até o final do século, gerado por dados futuros dos modelos climáticos Eta-BESM e Eta-MIROC5 nos RCPs de 4.5 e 8.5.

3.6.1 Análise das projeções segundo o modelo Eta-BESM

Na Figura 45 mostra o comportamento do SSMI com as projeções do modelo Eta-BESM, nas forçantes radiativas de 4.5 e 8.5 para o período de seis e doze meses. Analisando o RCP 4.5, é notório que nos primeiros dez anos ocorre um maior período chuvoso, tendo valor extremamente positivo (SSMI = 2,7 para seis meses) para o ano de 2025. Porém, a tendência da série foi negativa, já que até o fim do período analisado ocorreu mais valores extremos negativos, principalmente em 2070 até 2094.

Para o RCP 8.5, maior é a tendência negativa da série para os dois períodos analisados com pico de valor extremamente negativo para o ano de 2093 (SSMI = -3,8 para o período de seis meses; SSMI = -4, para doze meses) mostrando que o final do século é marcado por grandes e prolongadas secas. Esses resultados foram coincidentes no que foi visto para o comportamento do SPI e SPEI, sendo baseados em precipitação e evapotranspiração potencial para as projeções, reforçando que medidas mitigadoras preventivas devem ser tomadas para que não agrave a seca na bacia hidrográfica do rio Pajeú até o final do século.



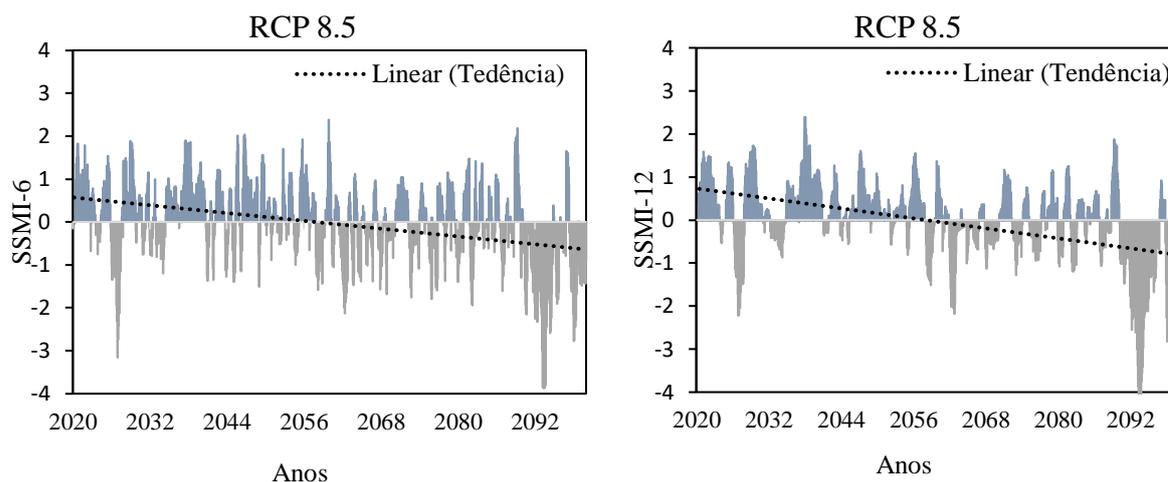


Figura 45. Projeções do SSMI referentes aos períodos de 6 e 12 meses para a bacia hidrográfica do rio Pajeú simulados pelo modelo Eta-BESM na forçante 4.5 e 8.5.

3.6.2 Análise das projeções segundo o modelo Eta-MIROC5

Os resultados do SSMI projetados com base no modelo Eta-MIROC5 (Figura 46) mostrou um comportamento um pouco diferente do que foi visto no Eta-BESM para o RCP 4.5, onde houve valores negativos nos primeiros dez anos e que foi extremo para o ano de 2022 (SSMI-6 = -2,42). O ano de 2066 ocorreu o maior valor negativo da série, chegando a um resultado de -4 para o valor de SSMI. Com relação à tendência, foi negativa, pois ocorreram mais eventos extremos secos do que eventos chuvosos na bacia do rio Pajeú.

Com os resultados da RCP 8.5 é possível perceber maior similaridade do que foi visto no Eta-BESM, onde ocorre mais períodos secos, principalmente na última década da série estudada. O detalhamento dessas projeções, em uma bacia no semiárido, são importantes para tomar medidas que atenuarão consideravelmente os seus efeitos adversos ao meio ambiente, agricultura e população dessa região.

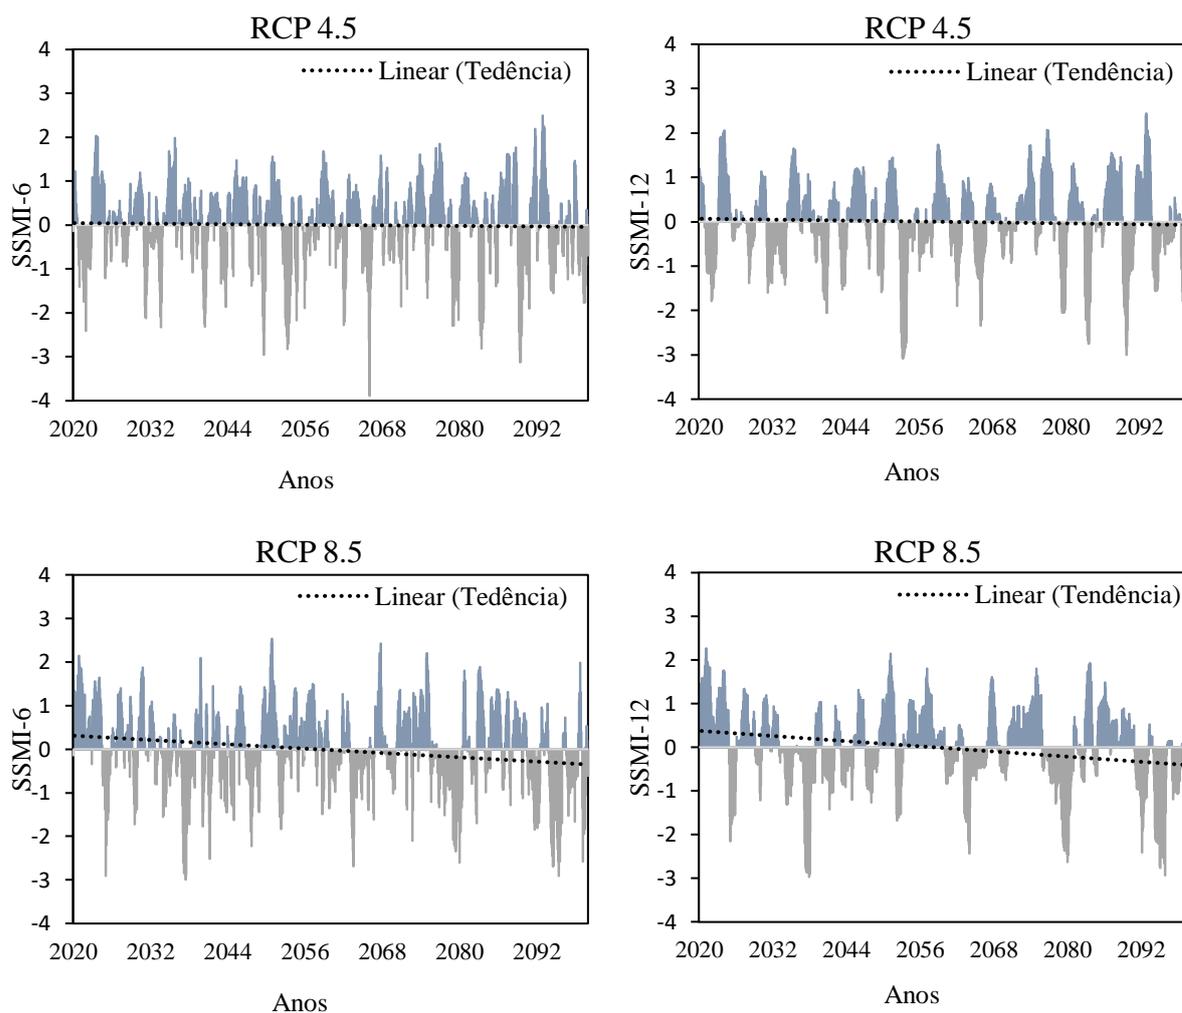


Figura 46. Projeções do SSMI referentes aos períodos de 6 e 12 meses para a bacia hidrográfica do rio Pajeú simulados pelo modelo Eta-MIROC5 na forçante 4.5 e 8.5.

Os dados do SSMI foram especializados na bacia (Figura 47), em três períodos até o final do século XXI, para analisar a distribuição dos impactos da seca de forma espaço-temporal. Essa informação é relevante para verificar onde pode ocorrer maior ausência de água no solo com os eventos de seca. Geralmente, os resultados foram bem semelhantes com os vistos nos índices SPI e SPEI, onde em média, no primeiro período a bacia não sofreu tanto com a ausência de chuva, mostrando a porção norte com os maiores valores de SSMI. Já para o último período (2071 – 2099), é possível ver que toda a bacia sofreu com as ocorrências de seca.

No modelo Eta-MIROC RCP 4.5 foi percebido um comportamento da seca menos intensa, nos três períodos analisados, fato esse que não foi visto nos dados simulados dos outros índices de seca analisados. Já para o RCP 8.5 do mesmo modelo, gerou dados mais extremos negativamente em toda a bacia. O fato de ser o final da década o mais crítico, indica que

medidas de controle deve ser tomada quanto antes possível, pois, a seca mostra-se persistente e decorrente até o final do século. Inocêncio, Ribeiro Neto e Souza (2020) quantificaram e classificaram, de forma objetiva, cada período seco em Pernambuco entre 1979 e 2016, utilizando o SPI e o SSMI nas escalas de seis e doze meses.

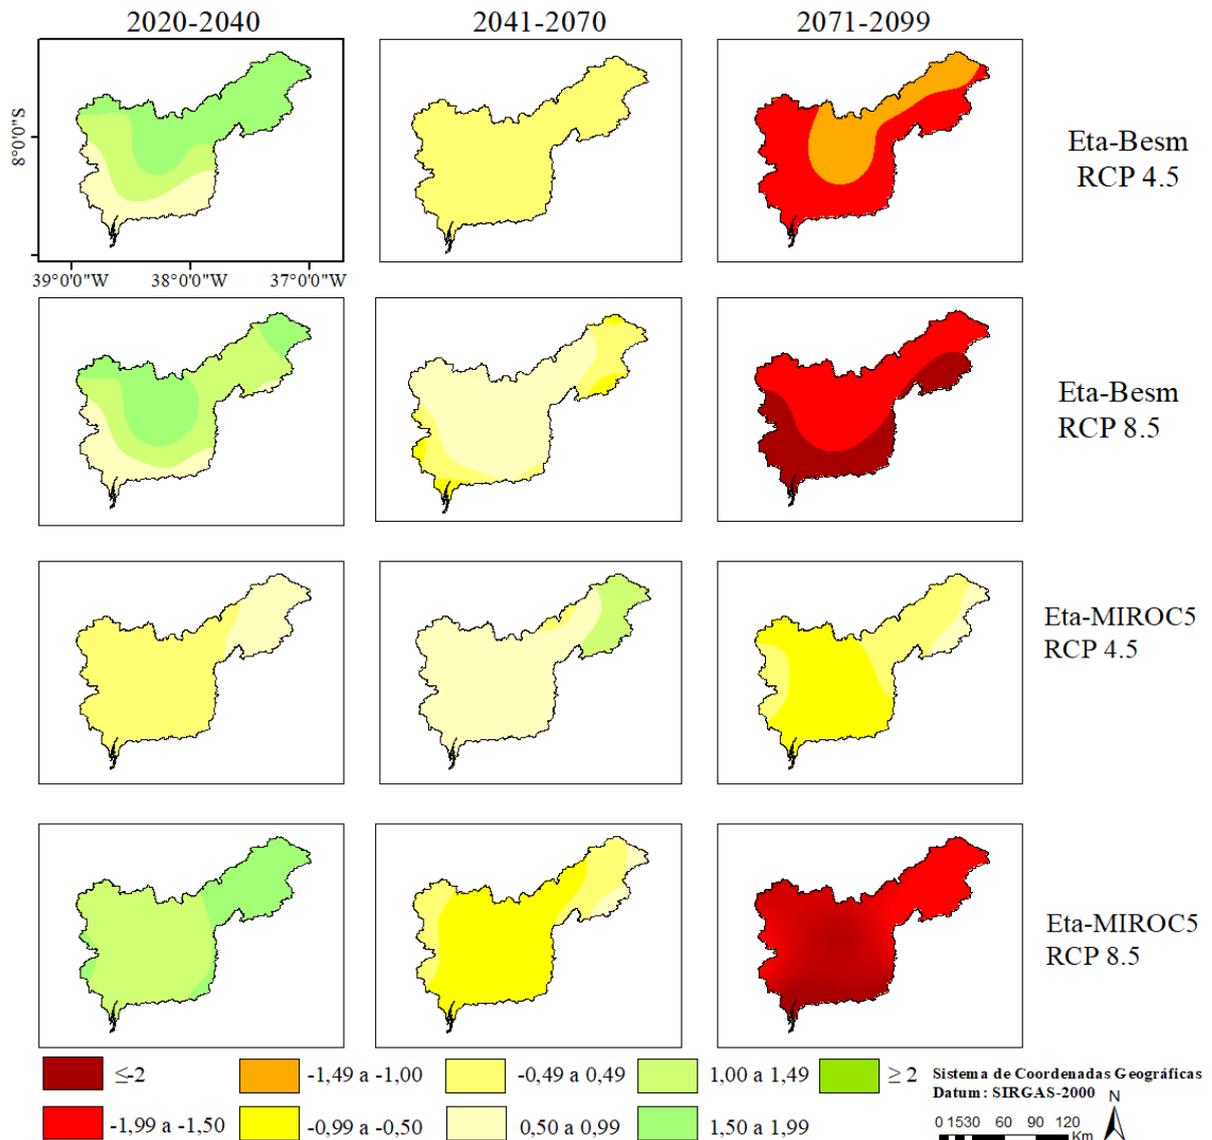


Figura 47. Comportamento de futuras secas baseado no SSMI-12 obtido pelos modelos climáticos na Bacia Hidrográfica do Rio Pajeú.

4. CONCLUSÃO

As projeções corrigidas para precipitação pluviométrica e temperaturas do ar anuais do Eta-MIROC5 e Eta-BESM, nos cenários RCP 4.5 e 8.5, para os três períodos analisados, indicam que a bacia certamente sofrerá com menos chuvas e maiores temperaturas no futuro para ambos modelos climáticos e cenários de emissão.

O comportamento dos índices de seca SPI, SPEI e SSMI, tanto espacial quanto temporal, derivados de dados futuros dos modelos climáticos e hidrológico, mostram grandes semelhanças, pois, indicam que os efeitos das mudanças climáticas sobre a bacia hidrográfica do rio Ipanema serão marcados por grandes e prolongadas secas, principalmente nas últimas três décadas.

A área mais afetada da bacia está situada na parte sul, onde se encontra um núcleo de desertificação no local, merecendo uma atenção maior. Os resultados deste estudo são importantes para emitir alertas para combater a seca e poderem ser usados por gestores de recursos hídricos na tomada de decisões sobre o uso adequado da água, na formulação de políticas públicas que favoreçam esse uso, e na adoção de práticas de mitigação e prevenção para garantir a segurança hídrica nesta e outras bacias hidrográficas em regiões semiáridas.

5. REFERÊNCIAS BIBLIOGRÁFICAS

ABBAS, S.; NICHOL, J. E.; QAMER, F. M.; XU, J. Characterization of drought development through remote sensing: a case study in Central Yunnan, China. **Remote Sensing**, v. 6, p. 4998 – 5018, 2014.

ABBASPOUR, K.; ROUHOLAHNEJAD, E.; VAGHEFI, S.; SRINIVASAN, R.; YANG, H.; KLOVE, B. A continental-scale hydrology and water quality model for Europe: calibration and uncertainty of a high-resolution large-scale SWAT model. **Journal of Hydrology**, v. 524, p. 733-752, 2015.

ADNAN, S.; ULLAH, K.; SHUANGLIN, L.; GAO, S.; KHAN, A. H.; MAHMOOD, R. Comparison of various drought indices to monitor drought status in Pakistan. **Climate Dynamics**, v. 51, p. 1885-1899, 2018.

AGHAKOUCHAK, A. A multivariate approach for persistence-based drought prediction: Application to the 2010–2011 East Africa drought. **In: Journal of Hydrology**, v. 526, p. 127-135, 2015.

ALBERGEL, C.; BROCCA, L.; WAGNER, W.; ROSNAY, P. DE; CALVET, J. C. Selection of Performance Metrics for Global Soil Moisture Products: The Case of ASCAT Soil Moisture Product. **Remote Sensing of Energy Fluxes and Soil Moisture Content**, n. 11, p. 431–448, 2013.

ALLEN, R. G.; TASUMI, M.; TREZZA, R.; BASTIAANSSEN, W. G. M. SEBAL (Surface Energy Balance Algorithms for Land). Advance Training and Users Manual. **Idaho Implementation**, v. 1, p. 97, 2002.

ALTAMIRANO, R. J. A. **Climatologia dos eventos chuvosos e secos severos, extremos e muito extremos usando o Índice de precipitação normalizada (SPI) para as regiões centro-oeste, sudeste e sul do Brasil**. Dissertação (Mestrado em Meteorologia). Instituto Nacional de Pesquisas Espaciais. São José dos Campos- SP, 168 p. 2010.

ALVALÁ, R. C. S.; CUNHA, A. P. M. A.; BRITO, S. S. B.; SELUCHI, M. E.; MARENGO, J. A.; MORAES, O. L. L.; CARVALHO, M. A. Drought monitoring in the Brazilian Semiarid region. **Anais da Academia Brasileira de Ciências**, v. 91, 2019.

ALVES, J. O.; PEREIRA, P. C.; QUEIROZ, M. G.; SILVA, T. G. F.; FERREIRA, J. M. S.; ARAÚJO JÚNIOR, G. N. Índice de anomalia de chuva para diferentes mesorregiões do Estado de Pernambuco. **Revista Pensar Acadêmico**, v. 14, n. 1, p. 37-47, 2016.

AL-YAARI, A.; WIGNERON, J. P.; DUCHARNE, A.; KERR, Y. H.; WAGNER, W.; LANNOY, G. DE; REICHLE, R.; BITAR, A. AL; DORIGO, W.; RICHAUME, P.; MIALON, A. Global-scale comparison of passive (SMOS) and active (ASCAT) satellite based microwave soil moisture retrievals with soil moisture simulations (MERRA-Land). **Remote Sensing of Environment**, v. 152, p. 614– 626, 2014.

AMIM, M. Z. M. et al. Future climate change impact assessment of watershed scale hydrologic processes in Peninsular Malaysia by a regional climate model coupled with a physically-based hydrology model. **Science of the Total Environment**, v. 575, p. 12-22, 2017.

AMITAI, E.; UNKRICH, C. L.; GOODRICH, D. C.; HABIB, E.; THILL, B. Assessing Satellite-Based Rainfall Estimates in Semiarid Watersheds Using the USDA-ARS Walnut Gulch Gauge Network and TRMM PR. **Journal of Hydrometeorology**, v. 12, p. 1579 – 1588, 2012.

ANAM, R.; CHISHTIE, F.; GHUFFAR, S.; QAZI, W.; SHAHID, I. Intercomparison of SMOS and AMSR-E soil moisture products during flood years (2010–2011) over Pakistan. **European Journal of Remote Sensing**, v. 50, n. 1, p. 442–451, 2017.

ANDRADE, C. W. L.; MONTENEGRO, S. M. G. L.; LIMA, J. R. DE S.; MONTENEGRO, A. A. DE A.; MAGALHÃES, A. G. Modelagem hidrológica sob mudanças na cobertura vegetal de uma bacia hidrográfica no Nordeste do Brasil. **Journal of Environmental Analysis and Progress**, v. 2, n. 3, p. 239, 2017a.

ANDRADE, C. W. L.; MONTENEGRO, S. M. G. L.; LIMA, J. R. DE S.; MONTENEGRO, A. A. D. A.; SRINIVASAN, R. Análise de sensibilidade de parâmetros do modelo SWAT em uma sub-bacia da Região Nordeste, Brasil. **Revista Brasileira de Geografia**, v. 51, n. 2, p. 440–453, 2017b.

ANDRADE, C. W. L.; MONTENEGRO, S. M. G. L.; MONTENEGRO, A. A. D. A.; LIMA, J. R. S.; SRINIVASAN, R.; JONES, C. A.; Climate change impact assessment on water resources under RCP scenarios: A case study in Mundaú River Basin, Northeastern Brazil. **Int. J. Climatol.**, p. 1–17, 2020.

ANJOS, R. S.; CANDEIAS, A. L.; NÓBREGA, R. S. Mapeamento da precipitação estimada e observada no semiárido pernambucano e sua relação com a modelagem de dados espaciais. **Revista brasileira de cartografia**, v. 69, n. 3, p. 447–462, 2017.

ARAÚJO, J. Barragens no Nordeste do Brasil: Experiência do DNOCS em Barragens na Região Semiárida. Departamento Nacional de Obras contra as Secas, Ministério do Interior, p. 158, 1982.

ARNOLD, J. G.; SRINIVASAN, R.; MUTTIAH, R. S.; WILLIAMS, J. R. Large area hydrologic modeling and assessment; Part I, Model development. **Journal of the American Water Resources Association**, v. 34, n. 1, p. 73-89, 1998.

ARNOLD, J. G.; ALLEN, P. M.; BERNHARDT, G. A comprehensive surface-groundwater flow model. **Journal of Hydrology**, v. 142, n. 1/4, p. 47-69, 1993.

ARNOLD, J. G.; MORIASI, D. N.; GASSMAN, P. W.; ABBASPOUR, K. C.; WHITE, M. J.; SRINIVASAN, R.; SANTHI, C.; HARMEL, R. D.; VAN GRIENSVEN, A.; VAN LIEW, M. W.; KANNAN, N.; JHA, M. K.. SWAT: model use, calibration, and validation. **Transactions of the American Society of Agricultural and Biological Engineers**, v. 55, p. 1491-1508, 2012.

ATZBERGER, C. Advances in Remote Sensing of Agriculture: Context Description, Existing Operational Monitoring Systems and Major Information Needs. **Remote Sens.** v. 5, p. 949-981, 2013.

BACHMAIR, S.; SVENSSON, C.; HANNAFORD, J.; BARKER, L. J.; STAHL, K. A quantitative analysis to objectively appraise drought indicators and model drought impacts. **Hydrol. Earth Syst. Sci.**, v. 20, p. 2589–2609, 2016.

BAI, L.; SHI, C.; LI, L.; YANG, Y.; WU, J. Accuracy of CHIRPS satellite-rainfall products over mainland China. **Remote Sensing**, v. 10, n. 3, 2018.

BANDAD, D.; RAHMANI, V. Capability of Remote-Sensing and In Situ Drought Indices for Detecting Drought and Streamflow in the MINK Region from 2003-2017. **American Society of Agricultural and Biological Engineers**, 2019.

BARBOSA, H.A; KUMAR, T.V.L; PAREDES, F.; ELLIOTT, S.; AYUGA, J.G. Assessment of Caatinga response to drought using Meteosat-SEVIRI Normalized Difference Vegetation Index (2008–2016). **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 148, p. 235–252, 2019.

BARKER, L. J.; HANNAFORD, J.; CHIVERTON, A.; SVENSSON, C. From meteorological to hydrological drought using standardised indicators. **Hydrology And Earth System Sciences**, v. 20, n. 6, p.2483-2505, 2016.

BASTIAANSEN, W. G. M. SEBAL – Based Sensible and Latent Heat Fluxes in the Irrigated Gediz Basin, Turkey. **Journal of Hidrology**, v. 229, n. 1, 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) 2. Validation. **Journal of Hydrology**, v. 212-213, p. 213-229, 1998b.

BASTIAANSEN, W. G. M.; PELGRUM, H.; WANG, J.; MA, Y.; MORENO, J. F.; ROERINK, G. J.; VAN DER WAL, T. A remote sensing surface energy balance algorithm for land (SEBAL) 1. **Formulation. Journal of Hydrology**, v. 212-213, p.198-212. 1998a.

BASTOS, S. Q.; BETARELLI JÚNIOR, A. A.; GOMES, B. S. M.; DINIZ, J. A. S. Evidências entre a Qualidade das Bacias Hidrográficas e as Características dos Municípios de Minas Gerais. **Rev. Econ. Sociol. Rural**, v. 56, n. 1, 2018.

BEGUERÍA, S.; VICENT-SERRANO, S. M.; REIG, F.; LATORRE, B. Standardized precipitation evapotranspiration index (SPEI) revisited: Parameter fitting, evapotranspiration models, tools, datasets and drought monitoring. **International Journal of Climatology**, v. 34, n. 10, p. 3001–3023, 2014.

BERGSTRÖM, S. The HBV model: its structure and applications. **Hydrology**, Norrköping, n. 4, p. 1-35, 1992.

BESKOW, S.; MELLO, C. R.; NORTON, L. D. Development, sensitivity and uncertainty analysis of LASH model. **Scientia Agricola**, v. 68, n. 3, p. 265-274, 2011.

BEVEN, K. J.; BINLEY, A. The future of distributed models - model calibration and uncertainty prediction. **Hydrological Processes**, v. 6, n. 3, p. 279-298, 1992.

BHUIYAN, C.; SINGH, R. P.; KOGAN, F. N. Monitoring drought dynamics in the Aravalli region (India) using diffabbaseerent indices based on ground and remote sensing data. **International Journal of Applied Earth Observation and Geoinformation**. v. 8, p. 289–302. 2006.

BHUIYAN, C., Desert vegetation during droughts: response and sensitivity. **Int Arch Photogramm Remote Sens Spat Inf Sci.**, v. 37, p. 907–912, 2008.

BITTELLI, M. Measuring soil water content: A review. **HortTechnology**, v. 21, n. 3, p. 293–300, 2011.

BLACK, T. L. The new NMC mesoscale Eta model: description and forecast examples. **Weather and Forecasting**, v.9, n.2, p.265-278, 1994.

BLAIN, G. C. Extreme value theory applied to the standardized precipitation index. **Acta Scientiarum Technology**, v.36, n.1, p.147-155, 2014.

BLAIN, G. C; PIRES, R. C. M. Variabilidade temporal da evapotranspiração real e da razão entre evapotranspiração real e potencial em Campinas, Estado de São Paulo, **Bragantia**, v.70, 2011.

BORETTI, A.; ROSA, L. Reassessing the projections of the World Water Development Report. **Npj Clean Water**, v. 2, n. 15, 2019.

BRITO, S. S. B.; CUNHA, A. P. M. A.; CUNNINGHAM, C. C.; ALVALÁ, R. C.; MARENGO, J. A.; CARVALHO, M. A. Frequency, duration and severity of drought in the Semiarid Northeast Brazil region. **In: Int. J. Climatol.**, v. 38, p. 517-529, 2018.

BRITO, S. S. B.; CUNHA, A. P. M. A.; CUNNINGHAM, C. C.; ALVALÁ, R. C. S.; MARENGO, J. A.; CARVALHO M. A. Frequency, duration and severity of drought in the Semiarid Northeast Brazil region. **International Journal of Climatology**, v. 38, n. 2, p. 517–529, 2017.

BROCCA, L.; CIABATTA, L.; MASSARI, C.; MORAMARCO, T.; HAHN, S.; HASENAUER, S.; KIDD, R.; DORIGO, W., WAGNER, W., LEVIZZANI. Soil Moisture for Hydrological Applications: Open Questions and New Opportunities. **Water**, v. 9, n. 2, p. 140, 2017.

BROCCA, L.; CIABATTA, L.; MASSARI, C.; MORAMARCO, T.; HAHN, S.; HASENAUER, S.; KIDD, R.; DORIGO, W., WAGNER, W., LEVIZZANI, V. Soil as a natural rain gauge: estimating global rainfall from satellite soil moisture data. **Journal of Geophysical Research**, v. 119, p. 5128–5141, 2014

BROCCA, L.; FILIPPUCCI, S.; HAHN, S.; CIABATTA, L.; MASSARI, C.; CAMICI, S.; SCHULLER, L.; BOJKOV, B.; WAGNER, W. SM2RAIN–ASCAT (2007–2018): global daily satellite rainfall data from ASCAT soil moisture observations. **Earth Syst. Sci. Data**, v. 11, p. 1583–1601, 2019.

BROCCA, L.; MASSARI, C.; CIABATTA, L.; MORAMARCO, T.; PENNA, D.; ZUECCO, G.; PIANEZZOLA, L.; BORGA, M.; MATGEN, P.; MARTÍNEZ-FERNÁNDEZ, J. Rainfall estimation from in situ soil moisture observations at several sites in Europe: an evaluation of the SM2RAIN algorithm. **Journal of Hydrology and Hydromechanics**, v. 63, n. 3, p. 201-209, 2015.

BROCCA, L., MELONE, F., MORAMARCO, T., WAGNER, W., A new method for rainfall estimation through soil moisture observations. **Geophys. Res. Lett.**, v. 40, n. 5, p. 853–858, 2013.

BROCCA, L., PELLARIN, T., CROW, W. T., CIABATTA, L., MASSARI, C., RYU, D., SU, C. H., Rudiger, C. and Kerr, Y.: Rainfall estimation by inverting SMOS soil moisture estimates: A comparison of different methods over Australia, **J. Geophys. Res. Atmos.**, v. 121, n. 20, 2016.

BURITI, C. O.; BARBOSA, H. A. Um século de secas: Por que as políticas hídricas não transformaram o semiárido brasileiro? Lisboa: Chiado, 432p. 2018.

CEPED-UFSC. Centro Universitário de Estudos e Pesquisas sobre Desastres - Universidade Federal de Santa Catarina. Atlas brasileiro de desastres naturais: 1991 a 2012. 2. ed. rev. ampl. Volume Pernambuco. Florianópolis: CEPED UFSC, 2013. 130 p.

CHEN, Q. L.; XU, J. W.; SHI, S. W.; LI, X.; WANG, P. Building Drought Index Based on AMSR-E Data - A Case Study in Hilly Area of Central Sichuan Basin. **Advanced Materials Research**, v. 781–784, p. 2292–2295, 2013.

CHEN, J.; BRISSETTE, F.; LUCAS-PICHER, P. Transferability of optimally-selected climate models in the quantification of climate change impacts on hydrology. **Climate Dynamics**, v. 47, p. 3359–3372, 2016.

CHEN, Y.; EBERT, E. E.; WALSH, K. J. E.; DAVIDSON, N. E. Evaluation of TRMM 3B42 precipitation estimates of tropical cyclone rainfall using PACRAIN data. **Journal of Geophysical Research Atmospheres**, v. 118, n. 5, p. 2184–2196, 2013.

CHEN, Y.; YANG, K.; QIN, J.; CUI, Q.; LU, H.; LA, Z.; HAN, M.; TANG, W. Evaluation of SMAP, SMOS, and AMSR2 soil moisture retrievals against observations from two networks on the Tibetan Plateau. **Journal of Geophysical Research: Atmospheres**, v. 122, n. 11, p. 5780–5792, 2017.

CHIARAVALLOTI, L. BROCCA, A. PROCOPIO, C. MASSARI, S. G. Assessment of GPM and SM2RAIN-ASCAT rainfall products over complex terrain in southern Italy. **Atmos. Res.**, v. 206, p. 64-74, 2018.

CHILKOTI, V.; BOLISSETTI, T.; BALACHANDAR, R. Climate change impact assessment on hydropower generation using multi-model climate ensemble. **Renewable Energy**, v. 109, p. 510-517, 2017.

CHOU, S. C. Modelo Regional Eta. **Climanálise – Boletim de Monitoramento e Análise Climática**, v.1, n. 10, 1996.(INPE-12512-PRE/7814).

CHOU, S. C.; BUSTAMANTE, J. F.; GOMES, J. L. Evaluation of Eta Model seasonal precipitation forecasts over South America. **Nonlinear Processes in Geophysics**, v. 12, n. 4, p. 537-555, 2005.

CHOU, S. C.; LYRA, A.; MOURÃO, C.; DEREZYNSKI, C.; PILOTTO, I.; GOMES, J.; BUSTAMANTE, J.; TAVARES, P.; SILVA, A.; RODRIGUES, D.; CAMPOS, D.; CHAGAS, D.; SUEIRO, G.; SIQUEIRA, G.; MARENGO, J. Evaluation of the Eta simulations nested in three global climate models. **American Journal of Climate Change**, v. 03, n. 05, p. 438–454, 2014.

CHOU, S. C.; MARENGO, J. A.; LYRA, A. A.; SUEIRO, G.; PESQUERO, J.; ALVES, L. M.; KAY, G.; BETTS, R.; CHAGAS, D.; GOMES, J. L.; BUSTAMANTE, J.; TAVARES, P. Downscaling of South America present climate driven by 4-member HadCM3 runs. **Climate Dynamics**, v. 38, n. 3, p. 635–653, 2012.

CIABATTA, L.; BROCCA, L.; MASSARI, C.; MORAMARCO, T.; GABELLANI, S.; PUCA, S.; WAGNER, W. Rainfall-runoff modelling by using SM2RAIN-derived and state-of-the-art satellite rainfall products over Italy. **International Journal of Applied Earth Observation and Geoinformation**, v. 48, p. 163-173, 2016.

CIABATTA, L.; BROCCA, L.; MASSARI, C.; MORAMARCO, T.; GABELLANI, S.; PUCA, S.; RINOLLO, A.; WAGNER, W. Integration of satellite soil moisture and rainfall observations over the Italian territory. **Journal of Hydrometeorology**, v. 16, n. 3, p. 1341-1355, 2015.

CIABATTA, L.; MASSARI, C.; BROCCA, L.; GRUBER, A.; REIMER, C.; SEBASTIAN, H.; PAULIK, C.; DORIGO, W.; KIDD, R.; WAGNER, W. SM2RAIN-CCI: a new global long-term rainfall data set derived from ESA CCI soil moisture. **Earth Syst. Sci. Data**, v. 10, p. 267–280, 2018.

CIABATTA, L., MARRA, A.C., PANEGROSSI, G., CASELLA, D., SANÒ, P., Dietrich, S., Massari, C., Brocca, L. Daily precipitation estimation through different microwave sensors: verification study over Italy. **Journal of Hydrology**, v. 390, p. 436-450, 2017.

CIABATTA, L.; MASSARI, C.; BROCCA, L.; REIMER, C.; HANN, S.; PAULIK, C., Dorigo, W., Wagner, W. Using Python® language for the validation of the CCI soil moisture products via SM2RAIN. **PeerJ Preprints**, v. 2, n. 4, 2016.

CIRILO, J. A. Crise hídrica: desafios e superação. **Revista USP**, n. 106, v. 45, 2015.

CIRILO, J. A. Políticas públicas de recursos hídricos para o semiárido. **Estud. av.** v. 22 n. 63, 2008.

CLARKE, L.; EDMONDS, J.; JACOBY, H.; PITCHER, H.; REILLY, J.; RICHEL, R. Scenarios of greenhouse gas emissions and atmospheric concentrations. **US Department of Energy Publications**, v. 6, 2007.

COLLINS, W. J.; FRY, M. M.; YU, H.; FUGLESTVEDT, J. S.; SHINDELL, D. T.; WEST, J. J. Global and regional temperature-change potentials for near-term climate forcings. **Atmos. Chem. Phys.** v. 13 p. 2471–85, 2013.

COLLINS, W.J.; BELLOUIN, N.; DOUTRIAUX-BOUCHER, M.; GEDNEY, N.; HALLORAN, P.; HINTON, T.; HUGHES, J.; JONES, C.D.; JOSHI, M.; LIDDICOAT, S.; MARTIN, G.; O'CONNOR, F.; RAE, J.; SENIOR, C.; SITCH, S.; TOTTERDELL, I.; WILTSHIRE, A.; WOODWARD, S. Development and Evaluation of an Earth System Model-HadGEM2. **Geoscientific Model Development**, v. 4, p. 1051-1075, 2011.

COLLISCHONN, W.; TUCCI, C. E. M. Ajuste multiobjetivo dos parâmetros de um modelo hidrológico. **Revista Brasileira de Recursos Hídricos**, v. 8, n. 3, p. 27-39, 2003.

CONDEPE/FIDEM. **Bacia Hidrográfica do Rio Una, GL4 e GL5**. Série Bacias Hidrográficas de Pernambuco. v. 3, 27-35. 2006.

CONFALONIERI, U. E. C. Variabilidade climática, vulnerabilidade social e saúde no Brasil. **Terra Livre**, v. 1, n. 20, p. 193-204, 2003.

COSH, M. H.; JACKSON, T. J.; MORAN, S.; BINDLISH, R. Temporal persistence and stability of surface soil moisture in a semi-arid watershed. **Remote Sensing of Environment**, v. 112, n. 2, p. 304–313, 2018.

CROW, W. T.; HUFFMAN, G. J.; BINDLISH, R.; JACKSON, T. J. Improving satellitebased rainfall accumulation estimates using spaceborne surface soil moisture retrievals. **Journal of Hydrometeorology**, v. 10, p. 199–212, 2009.

CRISTIANO, E.; VELDHUIS, M.; GIESEN, N. VAN DE. Spatial and temporal variability of rainfall and their effects on hydrological response in urban areas – a review. **Hydrology and Earth System Sciences**, v. 21, p. 3859–3878, 2017.

CUADRA, S. V.; ROCHA, R. P., Simulação numérica do clima de verão sobre o Brasil e sua variabilidade. **Revista Brasileira de Meteorologia**, 2006.

CUNHA, A. P. M. A.; BRITO, S. S. B.; ALVALÁ, R. C. S.; CARVALHO, M. A.; ZERI, M.; VIEIRA, R. M. S. P.; ROSSATO, L.; MACIEL, A. P. R.; ANDRADE, E. S. Avaliação de indicador para o monitoramento dos impactos da seca em áreas de pastagens no semiárido do Brasil. **Revista Brasileira de Cartografia**, v. 69, p. 89–106, 2017.

CUNHA, A. P. M. A.; ZERI, M.; LEAL, K. D.; COSTA, L.; CUARTAS, L. A.; MARENGO, J. A.; TOMASELLA, J.; VIEIRA, R. M.; BARBOSA, A. A.; CUNNINGHAM, C.; GARCIA, J. V. C.; BROEDEL, E.; ALVALÁ, R.; RIBEIRO-NETO, G.; Extreme Drought Events over Brazil from 2011 to 2019. **Atmosphere**, v. 10, n. 642, 2019.

CUNHA, A.P.M.A.; TOMASELLA, J.; RIBEIRO-NETO, GG et al. Changes in the spatial-temporal patterns of droughts in the Brazilian Northeast. **Atmospheric Science Letters**, v. 19, n. 10, 2018.

CUTTER, S. L.; FINCH, C. Temporal and spatial changes in social vulnerability to natural hazards. **Proceedings of the National Academy of Sciences of the United States of America**, v. 105, n. 7, p. 2301-2306, 2008.

D'ODORICO, P.; CARR, J. A.; LAIO, F.; RIDOLFI, L.; VANDONI, S. Feeding humanity through global food trade. **Earth's Future**, v. 2, n. 9, p. 458–469, 2014.

DE JEU, R. A. M. Retrieval of land surface parameters using passive microwave remote sensing. Thesis. Vrije Universiteit Amsterdam, 2003.

DE SHERBININ, A. et al. Preparing for resettlement associated with climate change. **Science**, v. 334, n. 6.055, p. 456-457, 2011.

DELAZERI, L. M. M. Mudanças climáticas e migração rural-urbana no Semiárido brasileiro. 73 f. Dissertação (Mestrado em Economia Aplicada) - Universidade Federal de Viçosa, Viçosa, 2015.

DILLON, M. E.; COLLINI, E. A.; FERREIRA, L. J.: Sensitivity of WRF short-term forecasts to different soil moisture initializations from the GLDAS database over South America in March 2009. **Atmos. Res.** v. 167, p. 196–207, 2016.

DOORENBOS, J.; PRUITT, W. O. Background and Development of Methods to Predict Reference Crop Evapotranspiration (ET₀). **Appendix II in FAO-ID-24**, p. 108–119, 1977.

FAMIGLIETTI, J. S.; WOOD, E. F. Multiscale modeling of spatially variable water and energy balance processes. **Water Resour. Res.**, v. 11, p. 3061–3078, 1994.

FAO. Food and Agriculture Organization. The impact of disasters and crises on agriculture and food security 2017. Food and Agriculture Organization of the United Nations, Rome, 2018.

FASULLO, J. A. Mechanism for land-ocean contrasts in global monsoon trends in a warming climate. **Climate Dynamics**. v. 39, p. 1137-1147, 2012.

FEITOSA, A. **Zoneamento de pequenas bacia hidrográficas hidrográficas e caracterização de várzeas na Bacia hidrográfica do Pajeú**. Tese (Doutorado em Geografia), Universidade Federal de Pernambuco, Recife, 2012.

FERREIRA, P. S.; SOUZA, W. M.; SILVA, J. F.; GOMES, V. P. Variabilidade Espaço-Temporal das Tendências de Precipitação na Mesorregião Sul Cearense e sua Relação com as Anomalias de TSM. **Revista Brasileira de Meteorologia**, v. 33, n. 1, p. 141-152, 2018.

FERNÁNDEZ. J. M.; GONZÁLEZ-ZAMORA, A.; SÁNCHEZ, N.; GUMUZZIO, A.; JIMÉNEZ, C. M. H.. Satellite soil moisture for agricultural drought monitoring: Assessment of the SMOS derived Soil Water Deficit Index. **Remote Sensing of Environment**, v. 177, p. 277–286, 2016.

FUJINO, J.; NAIR, R.; KAINUMA, M.; MASUI, T.; MATSUOKA, Y. Multi-gas mitigation analysis on stabilization scenarios using AIM global model. **The Energy Journal**, p. 343-353, 2006.

GALLEGO-ELVIRA, B.; TAYLOR, C. M.; HARRIS, P. P.; GHENT, D.; VEAL, K. L.; FOLWELL, S. S. Global observational diagnosis of soil moisture control on the land surface energy balance. **Geophys. Res. Lett.** v. 43, p. 2623–2631, 2016.

GAO, F.; ZHANG, Y.; CHEN, Q.; WANG, P.; YANG, H.; YAO, Y. Comparison of two long-term and high-resolution satellite precipitation datasets in Xinjiang , China. **Atmospheric Research**, v. 212, p. 150–157, 2018.

GEORGAKAKOS, K. P.; BAUMER, O. W. Measurement and utilization of on-site soil moisture data. **J. Hydrol.**, 184, 131–152, 1996

GIBBS, W. J.; MAHER, J. V. Rainfall Deciles as Drought Indicators. Bureau of Meteorology Bulletin No. 48. Commonwealth of Australia, Melbourne. 1967.

GIORGI, F.; MEARNS, L. O. Introduction to special section: regional climate modeling revisited. **Journal of Geophysical Research**, v. 104, p. 6335-6352, 1999.

GOIS, G.; DELGADO, R. C.; OLIVEIRA-JÚNIOR, J. F. Modelos teóricos transitivos aplicados na interpolação espacial do standardized precipitation index (SPI) para os episódios de El Niño Forte no Estado do Tocantins, Brasil. **Irriga**, v.20, n.2, p.371-387, 2015.

GOMES, A. R. S.; ALVES, J. M. B.; SILVA, E. M.; GOMES, M. R. S.; GOMES, C. R. S. Study of the Relationship Between the Variability of Vegetation and Temperature Indexes of the Northeast Region of Brazil. **Rev. bras. meteorol.**, v. 34, n. 3, 2019.

GONZÁLEZ-ZAMORA, A.; SÁNCHEZ, N.; MARTÍNEZ-FERNÁNDEZ, J.; GUMUZZIO, A.; PILES, M.; OLMEDO, E. Long-term SMOS soil moisture products: A comprehensive evaluation across scales and methods in the Duero Basin (Spain). **Physics and Chemistry of the Earth**, p. 83–84, 2015.

GOUDARZI, F. M.; SARRAF, A.; AHMADI, H. Assessment of SM2RAIN-ASCAT and CMORPH satellite precipitation products over Maharlu Lake basin in Iran. **Water Supply**, v. 20, n. 5, p. 1799–1806, 2020.

GUEDES, M. V. Situação das áreas de reserva legal e proteção dos recursos naturais em assentamentos rurais da Mata Meridional pernambucana. **Dissertação de Mestrado**. Universidade Federal de Pernambuco, CFCH. Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente. Recife, 2012.

GUIMARÃES, S. O.; COSTA, A. A.; VASCONCELOS JÚNIOR, F. DAS C.; SILVA, E. M. DA; SALES, D. C.; ARAÚJO JÚNIOR, L. M. DE; SOUZA, S. G. 212 DE. Projeções de mudanças climáticas sobre o nordeste Brasileiro dos modelos do CMIP5 e do CORDEX. **Revista Brasileira de Meteorologia**, v. 31, n. 3, p. 337–365, 2016.

GUTIERREZ, A. P. A.; ENGLE, N. L.; DE NYS, E.; MOLEJON, C.; MARTINS, E. S. Drought preparedness in Brazil. **Weather and Climate Extremes**. v. 3, p. 95-106, 2014.

HAILE, G. G.; TANG, Q.; HOSSEINI-MOGHARI, S. M.; LIU, X.; GEBREMICAEL, T. G.; LENG, G.; KEBEDE, A.; XU, X.; YUN, X. Projected Impacts of Climate Change on Drought Patterns Over East Africa. **Earth's Future**, 2020.

HAJJ, M.; BAGHDADI, N.; ZRIBI, M.; RODRÍGUEZ-FERNÁNDEZ, N.; WIGNERON, J. P.; AL-YAARI, A.; BITAR, A. AL; ALBERGEL, C.; CALVET, J. C. Evaluation of SMOS, SMAP, ASCAT and Sentinel-1 soil moisture products at sites in Southwestern France. **Remote Sensing**, v. 10, n. 4, p. 1–17, 2018.

HALLEGATTE, S.; MACH, K. J. Make climate-change assessments more relevant. **Nature**, v. 534, n. 7609, p. 613–615, 2016.

HAO, Z.; AGHAKOUCHAK, A. Multivariate Standardized Drought Index: A parametric multi-index model. **Advances in Water Resources**, v. 57, p. 12–18, 2013.

HAO, Z.; HAO, F.; SINGH, V. P. A general framework for multivariate multi-index drought prediction based on Multivariate Ensemble Streamflow Prediction (MESP). In: **Journal of Hydrology**, 539, 1-10, 2016.

HAO, Z.; SINGH, V. P. Drought characterization from a multivariate perspective: A review. In: **Journal of Hydrology**, 527, 668-678, 2015.

HAYES, J. M.; SVOBODA, M. D.; WILHITE, D. A.; VANYARKHO, O. V. Monitoring the 1996 drought using the Standardized Precipitation Index. **Bulletin of the American Meteorological Society**, v. 80, p. 429-438, 1999.

HAYES, M. J.; SVOBODA, M. D.; WARDLOW, B. D.; ANDERSON, M. C.; KOGAN, F. Drought monitoring: historical and current perspectives. **Remote sensing of drought**, p. 1-19, 2011.

HE, B.; WANG, H.; HUANG, L.; LIU, J.; CHEN, Z. A new indicator of ecosystem water use efficiency based on surface soil moisture retrieved from remote sensing. **Ecol. Indic.** v. 75, p. 10–16, 2017.

HIJIOKA, Y.; MATSUOKA, Y.; NISHIMOTO, H.; MASUI, T.; KAINUMA, M. Global GHG emission scenarios under GHG concentration stabilization targets. **J. Glob. Environ. Eng.**, v.13 p. 97–108, 2008.

HIROTA, N.; TAKAYABU, Y. N.; WATANABE, M.; KIMOTO, M. Precipitation Reproducibility over Tropical Oceans and Its Relationship to the Double ITCZ Problem in CMIP3 and MIROC5 Climate Models. **Journal of Climate**, v. 24, n. 18, p. 4859–4873, 2011.

HOLZMAN, M. E.; RIVAS, R.; PICCOLO, M. C. Estimating soil moisture and the relationship with crop yield using surface temperature and vegetation index. **International Journal of Applied Earth Observation and Geoinformation**, v. 28, p. 181–192, 2014.

HOU, A.; KAKAR, R. K.; NEECK, S.; AZARBARZIN, A. A.; KUMMEROW, C. D.; KOJIMA, M.; OKI, R.; NAKAMURA, K.; IGUSHI, T. The Global Precipitation Measurement Mission. **American Meteorological Society**, v. 95, p. 701- 722, 2014.

HUFFMAN, G. J.; ADLER, R. F.; BOLVIN, D. T.; GU, G.; NELKIN, E. J. The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-Global, Multiyear, Combined-Sensor Precipitation Estimates at Fine Scales. **Journal of Hydrometeorology**, v.8, n.1, p. 38-55, 2007.

IBGE. INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Cidades@. Informações sobre os municípios brasileiros. Rio de Janeiro, 2014.

INOCÊNCIO, T. M.; RIBEIRO NETO, A.; SOUZA, A. G. S. S. Soil moisture obtained through remote sensing to assess drought events. **R. Bras. Eng. Agríc. Ambiental**, v. 24, n. 9, p.575-580, 2020.

INSA. Instituto nacional do Semiárido publica mapas dos núcleos de desertificação do semiárido. 2014. Disponível em: <<https://portal.insa.gov.br/noticias/740-insa-publica-mapas-dos-nucleos-de-desertificacao-do-semiarido>> . Acesso em: 19 dez. 2020.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). Climate Change 2001: Working Group II: Impacts, adaptations and vulnerability. INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). Climate Change 2007: Working Group I: The Physical Science Basis (Summary for Policymakers). Cambridge.

IPCC. Climate Change: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. IPCC, Geneva, Switzerland, p. 151, 2014.

IPCC. Climate Change and Water. Special Report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems (SR2). Dublin, February 2017.

IPCC. Climate Change and Water. Technical Paper of the Intergovernmental Panel on Climate Change. Geneva, Switzerland, 2008.

JALE, J. S.; XAVIER, S. F. A.; STOSIC, T.; STOSIC, B.; FERREIRA, T. A. E. Application of Markov chain on daily rainfall data in Paraíba-Brazil from 1995-2015. **Acta Scientiarum Technology**, v. 41, p. 1-10, 2019.

JENSEN, J. R. Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres. John R. Jensen; tradução: José Carlos Neves Epiphanyo, et al. 2009.

JESUS, N. V. G.; CORREIA, M. F.; JESUS, E. S. Estimativas de Precipitação por Satélite para o Nordeste do Brasil: O Uso do Algoritmo 3B42_V6 em Condições Meteorológicas Extremas. **Revista Brasileira de Geografia Física**, v. 6, n. 5, p. 1082 – 1099, 2013.

JIA, X.; SHAO, M.; ZHU, Y.; LUO, Y. Soil moisture decline due to afforestation across the Loess Plateau, **Journal of Hydrology**. v. 546, p. 113–122, 2017.

JOHNSON, G. E.; ACHUTUNI, V.R.; THIRUVENGADACHARI, S.; KOGAN, F. N.; The role of NOAA satellite data in drought early warning and monitoring: selected case studies. Chapter in: Drought assessment, management and planning: Theory and case studies, eds. D.A. Wilhite. Kluwer Academic Publ. 1993.

JOSHI, N. et al. A Review of the Application of Optical and Radar Remote Sensing Data Fusion to Land Use Mapping and Monitoring. **Remote Sensing**, v. 8, n. 1, p. 1–23, 2016.

KANG, H.; SRIDHAR, V.; Combined statistical and spatially distributed hydrological model for evaluating future drought indices in Virginia. **Journal of Hydrology: Regional Studies**. v. 12, p. 253-272, 2017.

KARLSSON, M; SOCHOR, J.; STRÖMBERG, H. Developing the ‘Service’ in Mobility as a Service: experiences from a field trial of an innovative travel brokerage. **Transportation Research Procedia**, v. 14, p. 3265 – 3273, 2016.

KERR, Y. H.; WALDTEUFEL, P.; RICHAUME, P.; WIGNERON, J. P.; FERRAZZOLI, P.; MAHMOODI, A.; AL BITAR, A.; Cabot, F.; GRUHIER, C.; JUGLEA, S. E., Leroux, D.; MIALON, A., DELWART, S.. The SMOS soil moisture retrieval algorithm. **IEEE transactions of geoscience and remote sensing**, v. 50, p. 1384–1403, 2012.

KERR, Y. H. Soil moisture from space: Where are we? **Hydrogeol. J.**, v. 15, p. 117–120, 2007.

KERR, Y. H.; AL-YAARI, A.; RODRIGUEZ-FERNANDEZ, N.; PARRENS, M.; MOLERO, B.; LEROUX, D.; BIRCHER, S.; MAHMOODI, A.; MIALONA, A.; RICHAUME, P.; et al. Overview of SMOS performance in terms of global soil moisture monitoring after six years in operation. **Remote Sensing of Environment**, v. 180, p. 40–63, 2016.

KERR, Y.; WALDTEUFEL, P.; WIGNERON, J.P.; DELWART, S.; CABOT, F.; BOUTIN, J.; ESCORIHUELA, M.J.; FONT, J.; REUL, N.; GRUHIER, C.; et al. The SMOS mission: New tool for monitoring key elements of the global water cycle. **Proc. IEEE**, 2010, 98, 666–687, doi:10.1109/JPROC.2010.2043032.

KEYANTASH, J., DRACUP, J.A. An aggregate drought index: assessing drought severity based on fluctuations in the hydrologic cycle and surface water storage. **Water Resources Research**, 40, 2004.

KEYANTASH, J.; DRACUP, J. A. The quantification of drought: an evaluation of drought indices. **Bulletin of the American Meteorological Society**, v. 83, n. 8, p. 1167, 2002.

KIRCHNER, J. W.; Catchments as simple dynamical systems: catchment characterization, rainfall-runoff modeling, and doing hydrology backward. **Water Resour. Res.**, 45, W02429, 2009.

KITIĆ, G.; CRNOJEVIĆ-BENGIN, V. A Sensor for the Measurement of the Moisture of Undisturbed Soil Samples. **Sensors**. v. 13, p. 1692-1705, 2013.

KHAN, N. A.; GAO, Q.; ABID, M. Public institutions’ capacities regarding climate change adaptation and risk management support in agriculture: the case of Punjab Province, Pakistan. **Scientific Reports**, v. 10, n. 1, 2020.

KHODAYAR, S.; COLL, A.; LOPEZ-BAEZA.; An improved perspective in the spatial representation of soil moisture: potential added value of SMOS disaggregated 1 km resolution "all weather" product. **Hydrology and Earth System Sciences**, v. 23, n. 1, p.255-275, 2019.

KOGAN, F. N. Global drought watch from space. **Bull Am Meteorol Soc.** p. 621–636, 1997.

KOGAN, F. N. World droughts in the new millennium from AVHRR-based vegetation health indices. **EOS Transactions American Geophysical Union**, v.83, p.562-563, 2002.

KOGAN, F. N.; GITELSON, A.; EDIGE, Z.; SPIVAK, L.; LEBED, L. AVHRR-based spectral vegetation index for quantitative assessment of vegetation state and productivity: calibration and validation. **Photogramm Eng Remote Sens**, p. 899–906, 2003.

- KOGAN, F.N. Remote sensing of weather impacts on vegetation in non-homogeneous areas. **International Journal of Remote Sensing**, v. 11, n. 8, p. 1405 – 1419. 1990.
- KORICHE, S. A. RIENTJES, T. H. M.: Application of satellite products and hydrological modelling for flood early warning. **Phys. Chem. Earth**, n. 93, 12–23, 2016.
- KOSTER, R. D.; BROCCA, L.; CROW, W. T.; BURGIN, M. S.; DE LANNOY, G. J. M.: Precipitation Estimation Using L-Band and C-Band Soil Moisture Retrievals. **Water Resources Research**, v. 52, n. 9, p. 7213-7225, 2016.
- LARGE, W. G., G. DANABASOGLU, J. C. MCWILLIAMS, P. R. GENT, and F. O. BRYAN: Equatorial circulation of a global ocean climate model with anisotropic horizontal viscosity. **J. Phys. Oceanogr.**, v. 31, p. 518–536, 2001.
- LEE, J. R.; MAGGINI, R.; TAYLOR, M. F. J.; FULLER, R. A. Mapping the drivers of climate change vulnerability for Australia’s threatened species. **PLoS One**, v. 10, n. 5, 2015.
- LENDERINK, G.; BUIHAND, A.; VAN DEURSEN, W. (2007) Estimates of future discharges of the river Rhine using two scenario methodologies: direct versus delta approach. **Hydrology and Earth System Sciences**, v. 11, n. 3, 2007.
- LI, N.; TANG, G.; ZHAO, P.; HONG, Y.; GOU, Y.; YANG, K. Statistical assessment and hydrological utility of the latest multi-satellite precipitation analysis IMERG in Ganjiang River basin. **Atmospheric Research**, v. 183, n. July, p. 212-223, 2017.
- LIANG, L.; SUN, X.; LUO, J.; WANG, L.; ZHANG, M.; DENG, L; DI, L.; LIU, Z. Long-term spatial and temporal variations of vegetative drought based on vegetation condition index in China. **Ecosphere**, v. 8, n. 8, 2017.
- LIANG, S.; WANG, W.; ZHANG, D. Characteristics of Annual and Seasonal Precipitation Variation in the Upstream of Minjiang River, Southwestern China. **Advances in Meteorology**, v. 2018, p. 1–14, 2018.
- LIMA, J. E. F. W.; SILVA, E. M. da; KOIDE, S.; SANTOS, R, M. Avaliação do Desempenho de Sonda de Capacitância no Monitoramento da Umidade de Latossolos do Cerrado em Condições de Campo. **Revista Brasileira de Recursos Hídricos**, v. 17, n.1, p. 23-32. 2012.
- LIMBERGER, L.; SILVA, M. E. S. Precipitação observada na Amazônia brasileira: comparação entre os dados das redes convencionais e dados da Reanálise I do NCEP/NCAR, CRU e GPCC. **Revista Brasileira de Climatologia**, v. 22, p. 20-37, 2018.
- LIU, Y. Y.; PARINUSSA, R. M.; DORIGO, W. A.; DE JEU, R. A. M.; WAGNER, W., VAN DIJK, A. I. J. M., McCabe, M. F.; EVANS, J. P. Developing an improved soil moisture dataset by blending passive and active microwave satellite based retrievals. **Hydrology and Earth System Sciences**, v. 15, p. 425-436, 2011.
- LIU, Y. Y.; DORIGO, W. A.; PARINUSSA, R. M.; DE JEU, R. A. M.; WAGNER, W.; MCCABE, M. F.; EVANS, J. P.; VAN DIJK, A. I. J. M. Trend-preserving blending of passive

and active microwave soil moisture retrievals, **Remote Sensing of Environment**, v. 123, p. 280-297, 2012.

LOEW, A.; SCHLENZ, F. A dynamic approach for evaluating coarse scale satellite soil moisture products. **Hydrol. Earth Syst. Sci.**, v. 15, p. 75–90, 2011.

LOPES, F. B.; TEIXEIRA, A. S.; ANDRADE, E. M.; AQUINO, D. N.; ARAÚJO, L. F. P. Mapa da qualidade das águas do rio Acaraú, pelo emprego do IQA e Geoprocessamento. **Revista Ciência Agrônômica**, v. 39, n. 3, p. 392-402, 2008.

LOUVET, S.; PELLARIN, T.; AL BITAR, A.; CAPPELAERE, B.; GALLE, S.; GRIPPA, M.; GRUHIER, C.; KERR, Y.; LEBEL, T.; MIALON, A.; et al. SMOS soil moisture product evaluation over West-Africa from local to regional scale. **Remote Sens. Environ.** v. 156, p. 383–394, 2015.

LOUZADA, F. L. R. O.; XAVIER, A. C.; PEZZOPANE, J. E. M. Climatological Water Balance With Data Estimated By Tropical Rainfall Measuring Mission for the Doce River Basin. **Engenharia Agrícola**, v. 38, n. 3, p. 376–386, 2018.

LU, X.; WANG, L.; PAN, M.; KASEKE, K. F.; LI, B. A multi-scale analysis of Namibian rainfall over the recent decade – comparing TMPA satellite estimates and ground observations Journal of Hydrology: Regional A multi-scale analysis of Namibian rainfall over the recent decade – comparing TMPA satellite. **Biochemical Pharmacology**, v. 8, n. 12, p. 59–68, 2016.

LU, X.; WEI, M.; TANG, G.; ZHANG, Y. Evaluation and correction of the TRMM 3B43V7 and GPM 3IMERGM satellite precipitation products by use of ground - based data over Xinjiang , China. **Environmental Earth Sciences**, 2018.

LUCENA, R. L.; CABRAL JÚNIOR, J. B.; STEINKE, E. T. Comportamento Hidroclimatológico do Estado do Rio Grande do Norte e do Município de Caicó. **Revista Brasileira de Meteorologia**, v. 33, n. 3, 485-496, 2018.

LYRA, A. A. Estudo de vulnerabilidade do bioma Amazônia aos cenários de mudanças climáticas. Tese (Doutorado em Ciência do Sistema Terrestre) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2015.

LYRA, A.; TAVARES, P.; CHOU, S. C.; SUEIRO, G.; DERECZYNSKI, C.; SONDERMANN, M.; SILVA, A.; MARENGO, J.; GIAROLLA, A. Climate change projections over three metropolitan regions in Southeast Brazil using the non-hydrostatic Eta regional climate model at 5-km resolution. **Theoretical and Applied Climatology**, v. 132, p. 663-682, 2018.

MACHADO, A. R.; VIEIRA, A.; JUNIOR, M.; WENDLAND, E. C. Avaliação do modelo J2000 / JAMS para modelagem hidrológica em bacias hidrográficas brasileiras. **Revista de Engenharia Sanitária e Ambiental**, v. 22, n. 2, p. 327– 340, 2017.

MAFFRA, C. Q. T.; CENTENO, J. A. SILVA. Estimativa da umidade do solo por meio de sensoriamento remoto e suas possíveis aplicações no estudo de deslizamento de terra. **Revista Brasileira de Cartografia**: Edição Especial Movimentos de Massa e Processos Erosivos, n. 68/9, p. 1709-1719, 2016.

MAGALHÃES, A. R.; CHAILO FILHO, H.; GARAGORRY, F. L.; GASQUES, J. G.; MOLION, L. C. B.; NETO, M. S. A.; NOBRE, C. A.; PORTO, E. R.; REBOUÇAS, O. E. The effects of climate variations on agriculture in Northeast Brazil. In: Parry M, Carter T, Konijn N (eds) **The Impact of Climate Variations on Agriculture**, v. 2, p. 277–304, 1988.

MALBÉTEAU, Y., MERLIN, O., Molero, B., Rüdiger, C., & Bacon, S. DisPATCh as a tool to evaluate coarse-scale remotely sensed soil moisture using localized in situ measurements: Application to SMOS and AMSR-E data in Southeastern Australia. **International Journal of Applied Earth Observation and Geoinformation**, v. 45, p. 221–234, 2016.

MARAUN, D.; SHEPHERD, T. G.; WIDMANN, M.; ZAPPA, G.; WALTON, D.; GUTIÉRREZ, J. M.; HAGEMANN, S.; RICHTER, I.; SOARES, P. M. M.; HALL, A.; MEARNNS, L. O. "Towards processinformed bias correction of climate change simulations". **Nature Climate Change**, v. 7, n. 11, p. 764–773, 2017.

MARENGO, J. A. Vulnerabilidade, impactos e adaptação à mudança do clima no semi-árido do Brasil. **Parcerias Estratégicas**, v. 13, n. 27, p. 149–176, 2008.

MARENGO, J. A.; CUNHA, A. P.; ALVES, L. M. A seca de 2012-15 no Nordeste do Brasil no contexto histórico. **Indicadores**, v. 3, n. 11, p. 1–6, 2018.

MARENGO, J. A.; TORRES, R. R.; ALVES, L. M. Drought in Northeast Brazil— past, present, and future. **Theoretical and Applied Climatology**, v. 129, n. 3– 4, p. 1189–1200, 2017.

MARENGO, J.A.; ALVES, L.M.; ALVALÁ, R.C.S.; CUNHA, A.P.M.A.; BRITO, S.; MORAES, O.L.L. Climatic characteristics of the 2010–2016 drought in the semiarid Northeast Brazil region. **Anais da Academia Brasileira de Ciências**, 2017.

MARENGO, J. A. Mudanças Climáticas e eventos extremos no Brasil. Fundação Brasileira para o Desenvolvimento sustentável. Brasília: MMA, 2012. Disponível em: http://www.fbds.org.br/cop15/FBDS_MudancasClimaticas.pdf.

MARONEZE, M. M.; ZEPKA, L. Q.; VIEIRA, J. G.; QUEIROZ, M. I.; JACOBLOPES, E. A tecnologia de remoção de fósforo: Gerenciamento do elemento em resíduos industriais. **Revista Ambiente e Água**, v. 9, n. 3, p. 445–458, 2014.

MARRA, F.; MORIN, E. Autocorrelation structure of convective rainfall in semiarid-arid climate derived from high-resolution X-Band radar estimates. **Atmospheric Research**, v.200, p.126- 138, 2018.

MARTIN, G.M. et al. The HadGEM2 Family of Met Office Unified Model Climate Configurations. **Geoscientific Model Development**, v. 4, p. 723-757, 2011.

MARTÍNEZ-FERNÁNDEZ, J.; GONZÁLEZ-ZAMORA, A.; SÁNCHEZ, N.; GUMUZZIO, A.; HERRERO-JIMÉNEZ, C. M. Satellite soil moisture for agricultural drought monitoring: Assessment of the SMOS derived Soil Water 218 Deficit Index. **Remote Sensing of Environment**, v. 177, p. 277–286, 2016.

MASSARI, C.; MAGGIONI, V.; BARBETTA, S.; BROCCA, L.; CIABATTA, L.; CAMICI, S.; MORAMARCO, T.; COCCIA, G.; TODINI, E.: Complementing near-real time satellite rainfall products with satellite soil moisture-derived rainfall through a Bayesian Inversion approach, **J. Hydrol.**, v. 573, p. 341–351, 2019.

McEVOY, P. M.; NATHAN, P.; RAPEE, R. M.; CAMPBELL, B. N. Cognitive behavioural group therapy for social phobia: Evidence of transportability to community clinics. **Behaviour Research and Therapy**, v. 50, n. 4, p. 258-265, 2012.

MCKEE, T. B., DOESKEN, N. J., KLEIST, J. The relation of drought frequency and duration to time scales. Proceedings of the Eighth Conference on Applied Climatology. **Am. Meteorol. Soc. Boston**. p. 179–184, 1993.

MELLO, C. R. Development and application of a simple hydrologic model simulation for a Brazilian headwater basin. **Catena**, v. 75, n. 3, p. 235-247, 2008.

MENESES, P. R. e ALMEIDA T. Introdução ao processamento de imagens de Sensoriamento Remoto. Universidade de Brasília – UNB. Brasília. 2012. Disponível em <http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>. Acesso em 15/07/2020.

MESINGER, F. A blocking for representation of mountains in atmospheric models. **Rivista di Meteorologia Aeronautica**, v.44, p.195-202, 1984.

MIALON, A.; RICHAUME, P.; LEROUX, D.; BIRCHER, S.; AL BITAR, A.; PELLARIN, T.; WIGNERON, J. P.; KERR, Y. H.. Comparison of dobson and mironov dielectric models in the SMOS Soil Moisture Retrieval Algorithm. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, n. 6, 2015.

MISHRA, A. K.; Singh, V. P. A review of drought concepts. **In: Journal of Hydrology**, v. 391, p. 202-216, 2010.

MISHRA, A.; VU, T.; VALIYA, A.; ENTEKHABI, D. Drought monitoring with soil moisture active passive (SMAP) measurements. v. 552, n. 10, p. 620–632, 2017.

MISRA, V., DIRMEYER, P. A.; KIRTMAN, B. P.; JUANG, H.-M.H.; KANAMITSU, M. Regional Simulation of interannual variability over South America. **Journal of Geophysical Research**, v. 107, 2002.

MO, K. C. Model-based drought indices over the United States. **J. Hydrometeor.**, v. 9, p. 1212–123, 2008.

MOHANTY, B. P.; COSH, M. H.; LAKSHMI, V.; MONTZKA, C. Soil Moisture Remote Sensing: State-of-the-Science. **Vadose Zone Journal**, v. 16, n. 1, p. 1–9, 2017.

MOLERO, B.; MERLINA, O.; MALBÉTEAUA, Y.; AL BITAR, A.; CABOT, F.; STEFAN, V.; KERR, Y.; BACONA, S.; COSH, M. H.; BINDLISH, R.; JACKSON, T. J.. SMOS disaggregated soil moisture product at 1 km resolution: Processor overview and first validation results. **Remote Sensing of Environment**, v. 180, p. 361–376, 2016.

MONTE-MOR, R. C. A. **Análise de processos hidrológicos em bacias de rios intermitentes no semiárido mineiro**. Tese (Doutorado em Saneamento) Universidade Federal de Minas Gerais, Minas Gerais, p. 307, 2012.

MOREIRA, E. P.; VALERIANO, M. M. Application and evaluation of topographic correction methods to improve land cover mapping using object-based classification. **International Journal of Applied Earth Observations and Geoinformation**, v. 32, p. 208-217, 2014.

MOSCATI, M. C. L.; GAN, M. A. Rainfall variability in the rainy season of semiarid zone of Northeast Brazil (NEB) and its relation to wind regime. **International Journal of Climatology**, v.27, p.493-512, 2007.

NAGHETTINI, M. Parameter and Quantile Estimation. In: NAGHETTINI, M. (Ed.). **Fundamentals of Statistical Hydrology**. p. 203–250, 2017.

NARASIMHAN, B.; SRINIVASAN, R. Development and evaluation of Soil Moisture Deficit Index (SMDI) and Evapotranspiration Deficit Index (ETDI) for agricultural drought monitoring. **Agricultural and Forest Meteorology**, v. 133, n. 4, p. 69-88, 2005.

NASA. NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. The Tropical Measurement Mission, 2019. Disponível em: .Acesso em: 23 de Abril de 2019.

NEITSCH, S. L.; ARNOLD, J. G.; KINIRY, J. R.; WILLIAMS GRASSLAND, J. R. 2011. Soil and Water Research Laboratory. Soil and Water Assessment Tool Theoretical Documentation Version 2009. Agricultural Research Service Blackland Research Center-Texas Agrilife Research. Texas A&M University System, 2011.

NEVES, H. H.; MATA, M. G. F.; GUERRA, J.G.M., CARVALHO, D.F.; WENDROTH, O. O., CEDDIA, M. B. Spatial and temporal patterns of soil water content in an agroecological production system. **Sci. Agric**. v. 74, 383–392, 2017.

NGUYEN, P.; OMBADI, M.; SOROOSHIAN, S.; HSU, K.; AGHAKOUCHAK, A.; BRATHWAITE, D.; ASHOURI, H.; THORSTENSEN, A. R. The PERSIANN Family of Global Satellite Precipitation Data: A Review and Evaluation of Products. **Hydrology and Earth System Sciences Discussions**, n. 4, p. 1– 34, 2018.

NICLOS, R.; RIVAS, R.; GARCÍA-SANTOS, V.; DOÑA, C.; VALOR, E.; HOLZMAN, M.; BAYALA, M. SMOS Level-2 Soil Moisture Product Evaluation in Rain-Fed Croplands of the Pampean Region of Argentina. **IEEE Transactions on Geoscience and Remote Sensing**, v. 54, n. 1, p. 499–512, 2016.

NÓBREGA, R. S.; SOUZA, E. P.; GALVÍNCIO, J. D. Análise da estimativa de precipitação do TRMM em uma sub-bacia da Amazônia Ocidental. **Rev. Geografia**, v. 25, n. 1, p. 6-20, 2008.

NÓBREGA, R. S.; FARIAS, R. F. L.; SANTOS, C. A. C.; Variabilidade temporal e espacial da precipitação pluviométrica em Pernambuco através de índices de extremos climáticos. **Rev. bras. meteorol**. v. 30, n. 2, 2015.

NÚÑEZ COBO, J.; VERBIST, K. Atlas de sequías de América Latina y el Caribe - UNESCO Digital Library. 1. ed. UNESCO y CAZALAC, 2018.

OLIVEIRA, P. T.; SILVA, C. M. S.; LIMA, K. C. Climatology and trend analysis of extreme precipitation in subregions of Northeast Brazil. **Theoretical and Applied Climatology**, v. 130, n. 2, p. 77-90, 2017.

OERTEL, M.; MEZA, F. J.; GIRONÁS, J.; SCOTT, C. A.; ROJAS, F.; PINEDAPABLOS, N.; Drought propagation in semi-arid river basins in Latin America: Lessons from Mexico to the Southern Cone. **Water**, v. 10, p. 1-21, 2018.

PABLOS, M.; GONZÁLEZ-ZAMORA, Á.; SÁNCHEZ, N.; MARTÍNEZ-FERNÁNDEZ, J. Assessment of SMADI and SWDI agricultural drought indices using remotely sensed root zone soil moisture. **Proceedings of the International Association of Hydrological Sciences**, v. 380, n. 12, p. 55–66, 2018.

PABLOS, M.; MARTÍNEZ-FERNÁNDEZ, J.; SÁNCHEZ, N.; GONZÁLEZ-ZAMORA, A. Temporal and Spatial Comparison of Agricultural Drought Indices from Moderate Resolution Satellite Soil Moisture Data over Northwest Spain. **Remote Sensing**, v. 9, p. 1–27, 2017.

PABLOS, M.; PILES, M.; SÁNCHEZ, N.; Gonzalez-Gambau V., Vall-llossera M., Camps A., Martínez-Fernandez J. A sensitivity study of land surface temperature to soil moisture using in-situ and spaceborne observations. **IEEE International Geoscience on Remote Sensing Symposium**, p. 3267-3269, 2014.

PALMER, W.C. Meteorological drought. Research Paper No. 45, U.S. Department of Commerce Weather Bureau, Washington, DC. 1965.

PALMER, W.C. Keeping track of crop moisture conditions, nationwide: The new Crop Moisture Index. **Weatherwise**, v. 21, p. 156 – 161. 1968.

PANCIERA, R.; WALKER, J.P.; JACKSON, T.J.; RYU, D.; GRAY, D.; MONERRIS, A.; YARDLEY, H.; TANASE, M.; RÜDIGER, C.; WU, X.; et al. The Soil Moisture Active Passive Experiments (SMAPEX): Towards Soil Moisture Retrieval from the SMAP Mission. **IEEE Trans. Geosci. Remote Sens**, v. 52, p. 490–507, 2014.

PELLARIN, T.; LOUVET, S.; GRUHIER, C.; QUANTIN, G.; LEGOUT, C. A simple and effective method for correcting soil moisture and precipitation estimates using amsr-e measurements. **Remote Sensing of Environment**, v. 136, p. 28–36, 2013.

PENG, J.; LOEW, A., MERLIN, O.; VERHOEST, N. E. C. A review of spatial downscaling of satellite remotely sensed soil moisture. **Reviews of Geophysics**, p. 1–26, 2017.

PENG, J.; NIESEL, J.; LOEW, A.; ZHANG, S.; WANG, J. Evaluation of satellite and reanalysis soil moisture products over southwest China using ground-based measurements. **Remote Sensing**, v. 7, n. 11, p. 15729–15747, 2015.

PEREIRA, E. R. R. **Índices pluviométricos na análise da intensidade e variabilidade regional das chuvas no Nordeste do Brasil**. Tese (Doutorado em Meteorologia), Universidade Federal de Campina Grande, Campina Grande, p. 102, 2014.

PEREIRA, G. R.; CUELLAR, M. D. Z. Conflitos pela água em tempos de seca no Baixo Jaguaribe, Estado do Ceará. **Estudos Avançados**, v. 29, n. 84, p. 115-137, 2015.

PEREIRA, G.; SILVA, M. E. S.; MORAES, E. C.; CARDOZO, F. S. Avaliação dos dados de precipitação estimados pelo satélite TRMM para o Brasil. **RBRH: revista brasileira de recursos hídricos**. v. 18, n. 3, p. 139-148, 2013.

PETERS, A.J., WALTER-SHEA, JII, E. A., VINA, A., HAYES, M., SVOBODA, M. D. Drought monitoring with NDVI-based standardized vegetation index. **Photogrammetric Engineering & Remote Sensing**, v. 68, n. 1, p. 71- 75. 2002.

PIANI C.; WEEDON G.P.; BEST M.; GOMES S.M.; VITERBO P.; HAGEMANN S.; HAERTER J.O. Statistical bias correction of global simulated daily precipitation and 177 temperature for the application of hydrological models. **Journal of Hydrology**, v. 395, p. 199–215, 2010.

PILES, M.; POU, X.; CAMPS, A.; VALL-LLOSSERA, M. Quality report: validation of SMOS-BEC L4 high resolution soil moisture products, version 3.0. Tech. rept. Barcelona Expert Center (BEC), 2015.

PILES, M.; SÁNCHEZ, N. Spatial Downscaling of Passive Microwave Data With Visible-to-Infrared Information for High-Resolution Soil Moisture Mapping. **Satellite Soil Moisture Retrieval: Techniques and Applications**, p. 109–132, 2016.

PILES, M.; MONERRIS, A.; VALL-LLOSSERA, M.; CAMPS, A. Enhancing the spatial resolution of smos soil moisture data over Spain. **IEEE International Geoscience and Remote Sensing Symposium**. p. 24-29, 2011.

PILES, M.; SÁNCHEZ, N.; VALL-LLOSSERA, M.; MEMBER, S.; CAMPS, A. A Downscaling Approach for SMOS Land Observations : Evaluation of High-Resolution Soil Moisture Maps Over the Iberian Peninsula. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 9, p. 3845–3857, 2014.

PILOTTO, Isabel L.; CHOU, Sin Chan; NOBRE, Paulo. Seasonal climate hindcasts with Eta model nested in CPTEC coupled ocean–atmosphere general circulation model. **Theoretical and applied climatology**, v. 110, n. 3, p. 437- 456, 2012.

PORTAL, G.; JAGDHUBER, T.; VALL-LLOSSERA, M.; CAMPS, A.; PABLOS, M.; ENTEKHABI, D.; PILES, M. Assessment of Multi-Scale SMOS and SMAP Soil Moisture Products across the Iberian Peninsula. **Remote Sens**. v. 12, n. 570, 2020.

POSSAS, J. M. C.; CORREA, M. M.; MOURA, G. B. DE A.; LOPES, P. M. O.; CALDAS, A. M.; FONTES JÚNIOR, R. V. DE P. Zoneamento agroclimático para a cultura do pinhão-mansão no estado de Pernambuco. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, n. 9, p. 993–998, 2012.

RADHA, L. SUDHAKARAN, G. Spatial and Temporal Variation of Rainfall in Iraq. **SSRG International Journal of Applied Physics (SSRG-IJAP)**, v. 2, n. 2, 2015.

RAHMAN, K. U.; SHANG, S.; SHAHID, M.; WEN, Y. Performance Assessment of SM2RAIN-CCI and SM2RAIN-ASCAT Precipitation Products over Pakistan. **Remote Sens.**, v. 11, n. 17, 2019.

RAJSEKHAR, D.; SINGH, V. P.; MISHRA, A. K. Multivariate drought index: An information theory based approach for integrated drought assessment. **In: Journal of Hydrology**, v. 526, p. 164-182, 2015.

RESENDE, N.; CHOU, S. C. INFLUÊNCIA DAS CONDIÇÕES DO SOLO NA CLIMATOLOGIA DA PREVISÃO SAZONAL DO MODELO ETA. **Revista Brasileira de Climatologia**, v. 15, 2015.

RIAHI, K.; GRUBLER, A.; NAKICENOVIC, N. Scenarios of long-term socioeconomic and environmental development under climate stabilization. **Technological Forecasting and Social Change**, v. 74, n. 7, p. 887-935, 2007.

RIBEIRO, E. P. **Mudanças ambientais e desertificação na bacia hidrográfica do rio Pajeú**. Tese (Doutorado em Geografia), Universidade Federal de Pernambuco, Recife, p. 180, 2016.

RIBEIRO NETO, A.; SCOTT, C. A.; LIMA, E. A.; MONTENEGRO, S. M. G. L.; CIRILO, J. A. Infrastructure sufficiency in meeting water demand under climate-induced socio-hydrological transition in the urbanizing Capibaribe River basin. Brazil, Hydrol. **Earth Syst. Sci.**, 18, p. 3449-3459, 2014.

RICTHIE, J.T. Soil water availability. **Plant and Soil**, v. 58, p. 327-338, 1981.

RODRIGO, S.; BRAGA, C. C.; SANSIGOLO, C. A.; PAULA, A. Determinação de Regiões Homogêneas do Índice de Precipitação Normalizada (SPI) na Amazônia Oriental. **Revista Brasileira de Meteorologia**, v. 32, n. 1, p. 111– 122, 2017.

ROMANO, N. Soil moisture at local scale: Measurements and simulations. **Journal of Hydrology**, v. 516, p. 6–20, 2014.

ROSSATO, L.; ALVALÁ, R.C.S.; MARENGO, J.A.; ZERI, M.; CUNHA, A.P.M.A.; PIRES, L.B.M.; BARBOSA, H.A. Impact of soil moisture on crop yields over Brazilian semiarid. **Front. Environ. Sci.** v. 5, p. 1–16, 2017.

ROSSATO, L.; DE, J., R.; ALVALÁ, R. C. S.; SOUZA, S. Evaluation of soil moisture from satellite observations over South America. **International Journal of Remote Sensing**, v.32, n.23, p.8013-8031, 2011.

SABBAGHI, M. A.; NAZARIB, M.; ARAGHINEJADC, S.; SOUFIZADEHD, S. Economic impacts of climate change on water resources and agriculture in Zayandehroud river basin in Iran. **Agricultural Water Management**, v. 241, 2020.

SALES, D. C.; PEREIRA, J. M. R. Projeções de mudanças na precipitação e temperatura no Nordeste Brasileiro utilizando a técnica de downscaling dinâmico. **Revista Brasileira de Meteorologia**, v. 30, n. 4, 435 - 456, 2015.

SÁNCHEZ, N.; MARTÍNEZ-FERNÁNDEZ, J.; GONZÁLEZ-ZAMORA, A. A combined approach with SMOS and MODIS to monitor agricultural drought. **Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.** p. 393–398, 2016.

SÁNCHEZ, N.; GONZÁLEZ-ZAMORA, Á.; PILES, M.; MARTÍNEZ-FERNÁNDEZ, J. (SMADI) Integrating MODIS and SMOS Products : A Case of Study over the Iberian Peninsula. **Remote Sensing**, v. 8, n. 287, p. 1–25, 2016.

SANTOS, T. S.; CARLA, A.; DUARTE, M.; COUTINHO, L.; SILVA, R.; CASTRO, A. A. DE. Análise de Eventos Extremos na Região Amazônica. **Revista Brasileira de Geografia Física**, v. 6, n. 4, p. 1356–1370, 2013.

SANTOS NETO, L. A.; MANIESI, V.; SILVA, M. J. G.; QUERINO, C. A. S.; LUCAS, E. W. M.; BRAGA, A. P.; ATAÍDE, K. R. P. Distribuição horária da precipitação em Porto Velho no período de 1998 – 2013. **Revista Brasileira de Climatologia**, v. 14, 2014.

SANTOS, C. A. S.; ROCHA, F. A.; RAMOS, T. B.; ALVES, L. M.; MATEUS, M.; OLIVEIRA, R. P. DE; NEVES, R. Using a Hydrologic Model to Assess the Performance of Regional Climate Models in a Semi-Arid Watershed in Brazil. **Water**, v. 11, n. 170, p. 1–17, 2019.

SATGÉ, F.; DEFRANCE, D.; SULTRAN, B.; BONNET, M.; SEYLER, F.; ROUCHÉ, N., PIERRON, F.; PATUREL, J. Evaluation of 23 gridded precipitation datasets across West Africa. **Journal of Hydrology**, n. 581, 2020.

SCAINI A.; SÁNCHEZ, N.; VICENTE-SERRANO, S. M.; MARTINEZ-FERNANDEZ, J.. A comparative analysis: SMOS-derived Soil Moisture and drought indices: a comparative analysis using in situ measurements. **Hydrol. Process.** v. 29, p. 373–383, 2015.

SENENT-APARICIO, J.; PÉREZ-SÁNCHEZ, J.; CARRILLO-GARCÍA, J.; SOTO, J. Using SWAT and fuzzy TOPSIS to assess the impact of climate change in the headwaters of the Segura River Basin (SE Spain). **Water**, v. 9, n. 149, 2017.

SHIFERAW, H.; GEBREMEDHIN, A.; GEBRETSADKAN, T.; ZENEBE, A. Modelling hydrological response under climate change scenarios using SWAT model: the case of Ilala watershed, Northern Ethiopia. **Modeling Earth Systems and Environment**, v. 4, p. 437–449, 2018

SHIRU, M. S.; SHAHID, S.; DEWAN, A.; CHUNG, E. S.; ALIAS, N.; AHMED, K.; HASSAN, Q. K.; Projection of meteorological droughts in Nigeria during growing seasons under climate change scenarios. **Scientific Reports**, v. 10, 2020.

SMOS-BEC. Soil Moisture and Ocean Salinity - Barcelona Expert Center. SMOS-BEC Ocean and Land Products Description. Version 1.5. 2016. 23p.

SOARES, D. B.; NOBREGA, R. S.; GALVÍNCIO, J. D. Indicadores climáticos de desertificação na bacia hidrográfica do rio Pajeú. **Revista Brasileira de Climatologia**, v. 22, n. 14, 2018.

STERNBERG, T., Regional drought has a global impact. **Nature**, v. 472, 2011.

SOUSA JÚNIOR, M. A. E.; LACRUZ, M. S. P. Sensoriamento Remoto para seca/estiagem. 1. ed. São Paulo: Oficina de Textos, 2015.

SOUSA, R. M.; VIOLA, M. R., CHOU, S. C.; ALVES, M. V. G.; AVANZI, J. C. Projeções climáticas regionalizadas para o estado do Tocantins, Brasil, nos cenários RCP 4.5 e RCP 8.5. **Revista Brasileira de Climatologia**, v. 24, n. 15, p. 330–347, 2019.

TRINDADE, L. L.; SCHEIBE, L. F. Gestão das águas: limitações e contribuições dos comitês de Bacias Hidrográficas Brasileiros. **Ambient. soc.** v. 22, 2019.

SECTMA. SECRETARIA DE CIÊNCIA, TECNOLOGIA E MEIO AMBIENTE. Plano estadual de recursos hídricos do estado de Pernambuco. v. 1, p. 2, 1998.

SEHGAL, V.; SRIDHAR, V.; TYAGI, A. Stratified drought analysis using a stochastic ensemble of simulated and in- situ soil moisture observations. **Journal Hydrology**, v. 545, p. 226-250, 2017.

SELUCHI, M. E.; NORTE, F. A.; SATYAMURTY, P.; CHOU, S. C. Analysis of three situations of the foehn effect over the Andes (zonda wind) using the Eta–CPTEC regional model. **Weather and forecasting**, v. 18, n. 3, p. 481-501, 2003.

SHAFER, B. A.; DEZMAN, L. E. Development of a Surface Water Supply Index (SWSI) to assess the severity of drought conditions in snowpack runoff areas. **In: Proceedings of the Western Snow Conference**, p. 164 – 175. 1982.

SHIMAKURA, S. E. (2006) Interpretação do coeficiente de correlação. Disponível em: <<http://leg.ufpr.br/~shimakur/CE003/node74.html>>. Acesso em: 20 junho. 2020.

SILVA, A. R.; SANTOS, T. S.; QUEIROZ, D. E.; GUSMÃO, M. O.; SILVA, T. G. F. Variations in rainfall anomaly index in semi-arid. **Journal of Environmental Analysis and Progress**, v. 2 n. 4, p. 377-384, 2017.

SILVA, J. M. T. Estudo da viabilidade do uso de dados do sensor AMSR-E para detecção da umidade do solo. 2011. 113f. Dissertação (Mestrado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul, 2011.

SILVA, J. C.; HELDWEIN, A. B.; MARTINS, F. B.; TRENTIN, G.; GRIMM, E. L. Análise de distribuição de chuva para Santa Maria, RS. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.11, n.1, p.67-72, 2007.

SILVA, M. A. R. Economia dos recursos naturais. In: MAY, P.; LUSTOSA, M. C.; VINHA, V. (Orgs.). Economia do meio ambiente: teoria e prática. Rio de Janeiro: Editora Campus, 2003.

SIQUEIRA, Vinícius Alencar et al. Ensemble flood forecasting based on operational forecasts of the regional Eta EPS in the Taquari-Antas basin. **RBRH**, v. 21, n. 3, p. 587-602, 2016.

SMITH, S. J.; WIGLEY, T. M. L. "Multi-gas Forcing stabilisation with the MiniCAM." **Energy Journal (Special Issue 3)**: 373-391, 2006.

SOBRAL, B. S.; OLVEIRA-JÚNIOR, J. F.; GOIS, G.; TERASSI, P. M. B.; MUNIZ-JÚNIOR, J. G. R. Variabilidade espaço-temporal e interanual da chuva no estado do Rio de Janeiro. **Revista Brasileira de Climatologia**, v. 22, 2018.

SOUSA, R. M.; VIOLA, M. R.; CHOU, S. C.; ALVES, M. V. G.; AVANZI, J. C. Projeções climáticas regionalizadas para o Estado do Tocantins, Brasil, nos cenários RCP 4.5 e RCP 8.5. **Revista Brasileira de Climatologia**, v. 24, n. 15, 2019.

SOUZA, A. C. M.; Silva, M. R. F., DIAS, N. S. Gestão de recursos hídricos: o caso da bacia hidrográfica Apodi/Mossoró (RN). **Irriga**, Botucatu, Edição Especial, p. 280 - 296, 2012.

SOUZA, A. G. S. S.; NETO, A. R.; ROSSATO, L.; ALVALÁ, R. C. S.; SOUZA, L. L. Use of SMOS L3 Soil Moisture Data: Validation and Drought Assessment for Pernambuco State, Northeast Brazil. **Remote Sens**, v. 10, 2018.

SOUZA, A. G. S. S.; NETO, A. R.; SOUZA, L. L. Avaliação da seca no Estado de Pernambuco utilizando o Índice da Condição da Vegetação (VCI), umidade do solo do satélite SMOS e precipitação. In: XIX Simpósio Brasileiro de Sensoriamento Remoto, 2019, Santos, **Anais [...]**. Santos - SP, 2019.

SRIVASTAV, R. K.; SCHARDONG, A.; SIMONOVIC, S. P. Water Resources Research Report. 2015.

STEINEMANN, A. C.; HAYES, M. J.; CAVALCANTI, L. F. N. (2005). Drought Indicators and Triggers. In: Wilhite, D. A., Drought and Water Crises Science, Technology, and Management Issues. Taylor & Francis Group. Nova York.

STAGGE, J.; TALLAKSEN, L. Standardized precipitation–evapotranspiration index (SPEI): Sensitivity to potential evapotranspiration model and parameters. **International Association of Hydrological Sciences**, v. 10, p. 367–373, 2014.

STERNBERG, T. **Regional drought has a global impact**. **Nature**, v. 472, p. 169, 2011.

SUDENE. PLIRHINE - Plano de Aproveitamento Integrado dos Recursos Hídricos do Nordeste, Recife, PE 1980.

TAKEUSHI, K.; MASOOD, M.; Indicators of Necessary Storages for Flood and Drought Management: Towards Global Maps. **Hydrol. Earth Syst. Sci. Discuss.**, 2016.

TAN, M. L.; DUAN, Z. Assessment of GPM and TRMM precipitation products over Singapore. **Remote Sensing**, v. 9, n. 7, p. 1–16, 2017.

TAO, H.; FISCHER, T.; ZENG, Y.; FRAEDRICH, K. Evaluation of TRMM 3B43 precipitation data for drought monitoring in Jiangsu Province, China. **Water**, v. 8, n. 6, p. 1–13, 2016.

TARPANELLI, A.; MASSARI, C.; CIABATTA, L.; FILIPPUCCI, P.; AMARNATH, G.; BROCCA, L. Exploiting a constellation of satellite soil moisture sensors for accurate rainfall estimation. **Advances in Water Resources**, v. 108, p. 249-255, 2017.

TEIXEIRA, M. N. O sertão semiárido. Uma relação de sociedade e natureza numa dinâmica de organização social do espaço. **Revista Sociedade e Espaço**, v. 31, n. 3, p. 769–798, 2016.

TEUTSCHBEIN, C.; SEIBERT, J. Bias correction of regional climate model simulations for hydrological climate-change impact studies: review and evaluation of different methods. **Journal of Hydrology**, v. 456, p. 12–29, 2012.

THORNTHWAITE, C. W. An Approach toward a Rational Classification of Climate. **Geographical Review**, v. 38, n. 1, p. 55–94, 1948.

TRENBERTH, K. E.; ASRAR, G. R. Challenges and opportunities in water cycle research: WCRP contributions. **Surveys in Geophysics**, v. 35, p. 515–532, 2014.

TUCCI, C.E.M. Hidrologia: Ciência e Aplicação. Editora da Universidade: ABRH: EDUSP. Coleção ABRH de Recursos Hídricos, v.4. Porto Alegre, 1ª Edição, 2012. 943p.

TURKES, M.; TATLI, H. Use of the standardized precipitation index (SPI) and a modified SPI for shaping the drought probabilities over Turkey. **International Journal of Climatology**, v. 29, p. 2270–2282, 2009.

UCHIYAMA, R.; OKOCHI, H.; KAMIYA, J.; ASAI, D.; KANEKO, C.; OGATA, H.; KATSUMI, N. The impacts of “urban-induced heavy rains” on the distribution of deposition fluxes of inorganic acidic substances in the Tokyo metropolitan area in summer. **Atmospheric Research**, v. 200, p.109- 116, 2018.

VAANI, N.; PORCHELVAN, P.; Monitoring of Agricultural Drought Using Fortnightly Variation of Vegetation Condition Index (VCI) for the State of Tamil Nadu, India. **Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.**, p. 159–164, 2018.

VAN VUUREN, D. P. et al. The representative concentration pathways: an overview. **Climatic Change**, v. 109, n. 5, p. 5–31, 2011.

VAN VUUREN, D. P.; DEN ELZEN, M. G.; LUCAS, P. L. et al. Stabilizing greenhouse gas concentrations at low levels: an assessment of reduction strategies and costs. **Climatic Change**, v. 81, n. 2, p 119–159, 2007.

VASILIADES, L.; LOUKAS, A. Hydrological response to meteorological drought using the Palmer drought indices in Thessaly, Greece. **Desalination**, v. 1, n. 237, p. 3–21, 2009.

VELPURI, N. M.; SENAY, G. B.; MORISETTE, J. T. Evaluating New SMAP Soil Moisture for Drought Monitoring in the Rangelands of the US High Plains. **Rangelands**, v. 38, n. 4, p. 183–190, 2015.

VERECKEN, H.; HUISMAN, J. A.; PACHEPSKY, Y.; MONTZKA, C.; KRUK, J. V.D.; BOGENA, H.; WEIHERMULLER, L.; HERBST, M.; MARTINEZ, G.; VANDERBORGH, J. On the spatio-temporal dynamics of soil moisture at the field scale. **Journal of Hydrology**, v. 516, p. 76–96, 2014.

VIANA, J. F. S.; MIRANDA, R. Q.; FARIAS, A. C. W. L.; LINS, F. A. C.; MONTENEGRO, S. M. G. L. Análise do Balanço Hídrico Da Bacia Do Rio Pajeú Utilizando o Modelo Hidrológico Swat. **Anais do III Simpósio da Bacia Hidrográfica do Rio São Francisco**, 2020.

VIANA, J. F. S.; MONTENEGRO, S. M. G. L.; SILVA, B. B.; SOUSA, W. S. Modelagem Hidrológica Da Bacia Do Riacho Fundo No Distrito Federal, Utilizando O Modelo SWAT. **Journal of Environmental Analysis and Progress**, v. 03, n. 1, p. 155–172, 2018.

VICENTE-SERRANO, S.M.; BEGUERÍA, S.; LÓPEZ-MORENO, J.I. A Multiscalar Drought Index Sensitive to Global Warming: The Standardized Precipitation Evapotranspiration Index. **Journal of Climate**, v. 23, p. 1696–1718, 2010.

VIEIRA, R. M. S. P.; TOMASELLA, J.; ALVALÁ, R. C. S.; SESTINI, M. F.; AFFONSO, A. G.; RODRIGUEZ, D. A.; BARBOSA, A. A.; CUNHA, A. P. M. A.; VALLES, G. F.; CREPANI, E.; OLIVEIRA, S. B. P.; SOUZA, M. S. B.; CALIL, P. M.; CARVALHO, M. A.; VALERIANO, D. M.; CAMPELLO, F. C. B.; SANTANA, M. O. Identifying areas susceptible to desertification in the Brazilian northeast. **Solid Earth**, v. 6, n. 1, 347–360, 2015.

VIEIRA, Raphael Moreira Gomes et al. Avaliação das Previsões de Precipitação do Modelo Eta para Bacia do Rio São Francisco em Minas Gerais, Brasil. **Anuário do Instituto de Geociências**, v. 38, n. 2, p. 15-23, 2016.

VIOLA, M. R. et al. Assessing climate change impacts on Upper Grande River Basin hydrology, Southeast Brazil. **International Journal of Climatology**, v. 35, p. 1054-1068, 2015.

VITTUCCI, C.; FERRAZZOLI, P.; KERR, Y.; RICHAUME, P.; GUERRIERO, L.; VAGLIO LAURIN, G. SMOS retrieval over forests: Exploitation of optical depth and tests of soil moisture estimates. **Remote Sens. Environ.** v. 180, 115–127, 2016.

VITTUCCI, C.; GUERRIERO, L.; FERRAZZOLI, P.; RAHMOUNE, R.; TANASE, M.; PANCIERA, R.; WALKER, J.P. Airborne forest monitoring during SMAPEX-3 campaign. In Proceedings of the 2013. **IEEE International Geoscience and Remote Sensing Symposium IGARSS**, v. 21–26, p. 987–990, 2013.

WADA, Y. M.; FLORKE, N.; HANASAKI, S.; EISNER, G.; FISCHER, S.; TRAMBEREND, Y. SATOH, M.T.H.; VAN VLIET, P.; YILLIA, C.; D. WIBERG. Modeling global water use for the 21st century: Water Futures and Solutions (WFaS) initiative and its approaches. **Geosci. Model Dev.**, v. 9, p. 175-222, 2016.

WAGNER, W.; HAHN, S.; KIDD, R.; MELZER, T.; BARTALIS, Z.; HASENAUER, S.; FIGA-SALDAÑA, J.; DE ROSNAY, P.; JANN, A.; SCHNEIDER, S.; KOMMA, J.; KUBU, G.; BRUGGER, K.; AUBRECHT, C.; ZUGER, J.; GANGKOFNER, U.; KIENBERGER, S.; BROCCA, L.; WANG, Y. The ASCAT soil moisture product: A review of its specifications, validation results, and emerging applications. **Meteorologische Zeitschrift**, v. 22, n. 1, p. 5–33, 2013.

WAGNER, W., DORIGO, W., DE JEU, R., Fernandez, D., Benveniste, J., Haas, E., Ertl, M. (2012). Fusion of active and passive microwave observations to create an Essential Climate Variable data record on soil moisture, **ISPRS Annals of the Photogrammetry, Remote Sensing**

and Spatial Information Sciences (ISPRS Annals), Volume I-7, XXII ISPRS Congress, Melbourne, Australia, 25 August-1 September 2012, 315-321.

WANDERS, N.; KARSSSENBERG, D.; BIERKENS, M.; PARINUSSA, R.; DE JEU, R., VAN DAM, J. Observation uncertainty of satellite soil moisture products determined with physically-based modeling. **Remote Sensing of Environment**, 127, 341–356, 2015.

WANG, J.; WANG, E.; LIU, D. L. Modeling the impact of climate change on wheat yield and field water balance over the Murray-Darling Basin in Australia. **Theoretical and Applied Climatology**, v. 104, p. 285–300, 2011.

WANG, L.; QU, J. J. Satellite remote sensing applications for surface soil moisture monitoring: A review. **Front. Earth Sci.** v.3, n.2, p.237-247, 2009.

WANG, W.; MEMBER, S.; LU, H.; ZHAO, T. Evaluation and Comparison of Daily Rainfall From Latest GPM and TRMM Products Over the Mekong River Basin. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 6, p. 2540–2549, 2017.

WATANABE, M., SUZUKI, T., O'ISHI, R., KOMURO, Y., WATANABE, S., EMORI, S., TAKEMURA, T., CHIKIRA, M., OGURA, T., SEKIGUCHI, M., TAKATA, K., YAMAZAKI, D., YOKOHATA, T., NOZAWA, T., HASUMI, H., TATEBE, H., KIMOTO, M., Improved Climate Simulation by MIROC5: Mean States, Variability, and Climate Sensitivity. **Journal of Climate**, v. 23, p. 6312– 6335, 2010.

WIGMOSTA, M. S.; VAIL, L. W.; LETTENMAIER, D. P. A distributed hydrology-vegetation model for complex terrain. **Water Resources Research**, v. 30, n. 6, p. 1665-1679, 1994.

WILHITE, D. A.; SIVAKUMAR, M. V. K.; PULWARTY, R. Managing drought risk in a changing climate: The role of national drought policy. **Weather and Climate Extremes**, v. 3, p. 4–13,. 2014.

WILHITE, D. A.; BUCHANAN-SMITH, M. Drought as Hazard: Understanding the Natural and Social Context. In: Wilhite, D. A., Drought and Water Crises Science, Technology, and Management Issues. Taylor & Francis Group. Nova York, 2015.

WILKS, D. S. Statistical Methods in the Atmospheric Sciences. **International Geophysics Series Vol 100**, v. 59, n. 1, p. 627, 2006.

WISE, M. A.; CALVIN, K. V.; THOMSON, A. M.; CLARKE, L. E.; BOND-LAMBERTY, B.; SANDS, R. D.; SMITH, S. J.; JANETOS, A. C.; EDMONDS, J. A. "Implications of limiting CO2 concentrations for land use and energy." **Science**. v. 324, p. 1183-1186, 2009.

WU, K.; JOHNSTON, C. A. Hydrologic response to climatic variability in a Great Lakes Watershed: A case study with the SWAT model. **Journal of Hydrology**, n. 337, p. 187-199, 2007.

WU, Q.; LIU, H.; WANG, L.; DENG, C. Evaluation of AMSR2 soil moisture products over the contiguous United States using in situ data from the International Soil Moisture Network.

International Journal of Applied Earth Observation and Geoinformation, v. 45, n. 11, p. 187–199, 2016.

XU, Y.; WANG, L.; ROSS, K. W.; LIU, C.; BERRY, K. Standardized Soil Moisture Index for Drought Monitoring Based on Soil Moisture Active Passive Observations and 36 Years of North American Land Data Assimilation System Data : A Case Study in the Southeast United States. **Remote Sensing**, v. 10, n. 301, p. 1–13, 2018.

ZHAI, J.; MONDAL, S. K.; FISCHER, T.; WANG, Y.; SU, B.; HUANG, J.; TAO, H.; WANG, G.; ULLAH, W.; UDDIN, M. Future drought characteristics through a multi-model ensemble from CMIP6 over South Asia. **Atmospheric Research**, v. 246, n. 1, 2020.

ZHANG, A.; JIA, G. Monitoring meteorological drought in semiarid regions using multi-sensor microwave remote sensing data. **Remote Sensing of Environment**, v.134, p.12-23, 2013.

ZHANG, D.; LIU, X.; BAI, P.; LI, X. H. Suitability of satellite-based precipitation products for water balance simulations using multiple observations in a humid catchment. **Remote Sensing**, v. 11, n. 2, 2019.

ZHANG, D.; ZHOU, G. Estimation of Soil Moisture from Optical and Thermal Remote Sensing: A Review. **Sensors**, v. 16, n. 8, p. 1308, 2016.

ZHANG, L.; JIAO, W.; ZHANG, H.; HUANG, C.; TONG, Q. Studying drought phenomena in the continental United States in 2011 and 2012 using various drought indices. **Remote Sensing of Environment**, v. 190, p. 96-106, 2017.

ZHANG, Y.; LI, Y.; JI, X.; LUO, X.; LI, X. Fine-resolution precipitation mapping in a mountainous watershed: Geostatistical downscaling of TRMM products based on environmental variables. **Remote Sensing**, v. 10, n. 1, p. 1–27, 2018.

ZHANG, Y.; SCHAAP, M. G.; ZHA, Y. A High-Resolution Global Map of Soil Hydraulic Properties Produced by a Hierarchical Parameterization of a Physically Based Water Retention Model. **Water Resources Research**, v. 54, 230 p. 9774–9790, 2018.

ZHANG, X.; ZHAO, W.; LIU, Y.; FANG, X.; FENG, Q. The relationships between grasslands and soil moisture on the Loess Plateau of China: A review. **Catena** n. 145, p. 56–67, 2016.

ZHANG, Y.; SU, F.; HAO, Z.; XU, C.; YU, Z.; WANG, L.; TONG, K. Impact of projected climate change on the hydrology in the headwaters of the Yellow River basin. **Hydrological Processes**, v. 29, n. 20, p. 4379–4397, 2015.

ZHANG, Y.; SHANGGUAN, Z. The change of soil water storage in three land use types after 10 years on the Loess Plateau. **Catena**, v. 147, p. 87–95, 2016.

ZHU, L.; SUOMALAINEN, J.; LIU, J.; HYYPPÄ, J.; KAARTINEN, H.; HAGGREN, H. A Review: Remote Sensing Sensors. In: RUSTAMOV, R. B. (Ed.). Multi-purposeful Application of Geospatial Data. **IntechOpen**, v. 12, p. 19–42, 2017.

ZHU, Q.; YULIN, L.; XU, Y.; TIAN, Y.; YANG, T. Satellite Soil Moisture for Agricultural Drought Monitoring: Assessment of SMAP-Derived Soil Water Deficit Index in Xiang River Basin, China. **Remote Sens**, v. 11, 2019.