



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

DIEGO CÉZAR DOS SANTOS ARAÚJO

**SENSORIAMENTO REMOTO E MODELAGEM APLICADOS À ESTIMATIVA
DE ATRIBUTOS HIDROLÓGICOS NO SEMIÁRIDO BRASILEIRO**

RECIFE – PE

2020

DIEGO CÉZAR DOS SANTOS ARAÚJO

**SENSORIAMENTO REMOTO E MODELAGEM APLICADOS À ESTIMATIVA
DE ATRIBUTOS HIDROLÓGICOS NO SEMIÁRIDO BRASILEIRO**

Tese apresentada ao Programa de Pós-graduação em Engenharia Agrícola, da Universidade Federal Rural de Pernambuco, como requisito para a obtenção do título de Doutor em Engenharia Agrícola.

Orientadora: Profa. Dra. Suzana Maria Gico Lima Montenegro

RECIFE – PE

2020

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)

- A663s Araújo, Diego César dos Santos
Sensoriamento remoto e modelagem aplicados à estimativa de atributos hidrológicos no semiárido brasileiro / Diego César dos Santos Araújo. - 2020.
234 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, 2020.
1. recursos hídricos. 2. seca. 3. monitoramento. 4. Nordeste. I. Montenegro, Suzana Maria Gico Lima, orient. II. Título

CDD 630

DIEGO CÉZAR DOS SANTOS ARAÚJO

**SENSORIAMENTO REMOTO E MODELAGEM APLICADOS À ESTIMATIVA
DE ATRIBUTOS HIDROLÓGICOS NO SEMIÁRIDO BRASILEIRO**

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: 20/02/2020

COMISSÃO JULGADORA

ORIENTADOR:

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

BANCA EXAMINADORA

Prof. Dr. Fabrício Marcos Oliveira Lopes (UFRPE/DEAGRI)

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

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

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

“

O Homem perdeu a sua capacidade de prever e de prevenir. Ele acabará destruindo a Terra.

- *Albert Schweitzer*

À minha mãe, **Lígia Ferreira**, por ter sido a razão da minha existência e por ter me ensinado a lidar com todos os obstáculos e dificuldades da vida, inclusive com a dor de sua ausência.

DEDICO

AGRADECIMENTOS

Não desejo (nem seria possível) fazer agradecimentos curtos. Essa tese é resultado de um trabalho desenvolvido durante um período de quatro anos e, nesse tempo, muitas pessoas e instituições contribuíram com a sua construção.

Todas as páginas que compõem esse documento são resultado de um conjunto de diversos sentimentos e estados de humor, de dias felizes, dias nebulosos, dias inspiradores, dias em que o meu maior desejo era ficar deitado na cama por horas seguidas, mas que o peso da consciência me obrigou a escrever pelo menos cinco linhas e, felizmente, essas cinco linhas foram seguidas de mais cinco, ou dez, ou vinte, ou algumas páginas...

O meu primeiro agradecimento é à minha família, mais especificamente à minha mãe (*In memoriam*). Esse momento, tão esperado, é fruto de uma grande batalha, mas não minha. Essa batalha foi travada diariamente pela minha mãe, desde a minha infância. Obrigado por ter sido a razão da minha existência e o motivo da minha chegada até aqui.

Agradeço aos meus tios e irmãos por todo o apoio, principalmente nesses últimos dois meses, onde cada abraço, por mais insignificante que aparentasse ser, agia como um pilar que crescia dentro de mim e me mantinha em pé.

À Profa. Suzana Montenegro, principalmente pela confiança. O maior aprendizado foi o de que uma orientação eficiente não precisa ser baseada em 'correntes'. Uma orientação promissora é aquela fundamentada na independência, com autonomia para apresentarmos todas as nossas ideias e, se devidamente embasadas, seguirmos com elas. E assim está construída essa tese, com base em algumas ideias que foram surgindo ao longo desses quatro anos, todas discutidas e acompanhadas pela Profa. Suzana.

A todos os demais professores, que sempre contribuíram dentro da sala de aula e fora dela, especialmente àqueles que foram membros das minhas bancas de defesa de projeto e qualificação: Profa. Werônica Meira, Profa. Ana Lúcia Candeias, Prof. Fabrício Lopes, Prof. Hernande Pereira e Profa.

Josiclêda Galvêncio, que transformaram momentos aparentemente tensos em encontros marcados por aprendizados e trocas de experiências.

Aos amigos da UFRPE e UFPE que conheci nos corredores, salas de aula e laboratórios, mas que sei que poderei levar para a vida. Fugindo um pouco do usual, não citarei nomes, mas tenho a certeza de que cada amigo, cada companheiro de jornada se sentirá representado nessas palavras. Muito obrigado, de verdade, a cada um de vocês.

À Universidade Federal de Pernambuco e ao Programa de Pós-Graduação em Engenharia Agrícola da UFRPE, que forneceram todo o suporte e estrutura necessários ao desenvolvimento dessa tese.

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 todo o Departamento de Engenharia Civil e Ambiental da Universidade Politécnica de Milão, que me recebeu de braços abertos e contribuiu diretamente com o meu crescimento científico e desenvolvimento dessa tese, especialmente os professores Chiara Corbari, Marco Mancini, Giovanni Ravazzani e Alessandro Cepi.

A todas as outras pessoas e instituições que não foram citadas aqui, mas que de alguma forma colaboraram com esse trabalho. Minha eterna gratidão a todos!

RESUMO GERAL

Araújo, Diego César dos Santos. Universidade Federal Rural de Pernambuco. Fevereiro de 2020. **Sensoriamento remoto e modelagem aplicados à estimativa de atributos hidrológicos no semiárido brasileiro**. Orientadora: Profa. Dra. Suzana Maria Gico Lima Montenegro.

A região Nordeste do Brasil é a mais propensa à escassez hídrica em virtude da predominância do clima semiárido, marcado pelo déficit e irregularidade dos índices pluviométricos, características que afetam diretamente a segurança hídrica. De acordo com o novo Plano Nacional de Segurança Hídrica, de 2019, o Nordeste é a região com menor grau de segurança hídrica previsto para 2035, o que leva à necessidade de estudos com foco no monitoramento de processos hidrológicos e gestão dos recursos hídricos. Esse estudo teve como objetivo realizar a avaliação de alguns atributos hidrológicos no Nordeste utilizando dados de sensoriamento remoto e modelagem hidrológica, com foco principal na estimativa e monitoramento de eventos de seca. Para isso, dados de precipitação do *Tropical Rainfall Measuring Mission* (TRMM) foram validados e utilizados para cálculo do Índice de Precipitação Padronizada (SPI) em Pernambuco, para os anos de 1998 a 2017, assim como dados de umidade do solo do *Soil Moisture Active Passive* (SMAP) e *Soil Moisture and Ocean Salinity* (SMOS) foram validados também em Pernambuco e no semiárido em busca do melhor instrumento para estimativa do índice de seca agrícola *Soil Water Deficit Index* (SWDI), para o período de 2015 a 2018. Adicionalmente, um modelo hidrológico distribuído, FEST-EWB, foi utilizado para modelar espacialmente a umidade e temperatura de superfície do solo na Bacia do Rio Una, inserida em zona de transição climática. Os resultados indicaram o elevado potencial do TRMM, SMAP e SMOS para a estimativa da precipitação e umidade do solo, evidenciando que a seca baseada no SPI e SWDI pode ser continuamente monitorada em Pernambuco e no semiárido, com grande aplicabilidade. Em complemento, o modelo FEST-EWB mostrou alto potencial na modelagem da umidade e temperatura do solo, gerando dados matriciais (mapas) com alta resolução espacial e temporal, que podem auxiliar diretamente no manejo agrícola e dos recursos hídricos. Os dados gerados são essenciais por indicar formas diversificadas de estimativa e monitoramento de atributos hidrológicos que possuem grande potencial na gestão dos recursos hídricos no Nordeste.

Palavras-chave: recursos hídricos, seca, monitoramento, Nordeste.

GENERAL ABSTRACT

Araújo, Diego César dos Santos. Federal Rural University of Pernambuco. February 2020. **Remote sensing and modeling applied to the estimation of hydrological attributes in the Brazilian semiarid.** Advisor: Prof. Dr. Suzana Maria Gico Lima Montenegro.

The Brazilian Northeast is the region most vulnerable to water scarcity due to the predominance of the semiarid climate, marked by the deficit and irregularity of rainfall, characteristics that directly affect water security. According to the new National Water Security Plan, 2019, the Northeast is the region with the lowest degree of water security planned for 2035, which leads to the need for studies focusing on the monitoring of hydrological processes and management of water resources. This study aimed to evaluate some hydrological processes in the Northeast using data from remote sensing and hydrological modeling, with a primary focus on estimating and monitoring drought events. For this, precipitation data from the Tropical Rainfall Measuring Mission (TRMM) were validated and used to calculate the Standardized Precipitation Index (SPI) in Pernambuco, for the years 1998 to 2017, as well as soil moisture data from Soil Moisture Active Passive (SMAP) and Soil Moisture and Ocean Salinity (SMOS) were also validated in Pernambuco and the semiarid region in search of the best instrument for estimating the Soil Water Deficit Index (SWDI), for the period from 2015 to 2018. In addition, a distributed hydrological model, FEST-EWB, was used to spatially model soil moisture and soil surface temperature in the Una River Basin, inserted in a climate transition zone. The results indicated the high potential of TRMM, SMAP and SMOS to estimate rainfall and soil moisture, showing that drought based on SPI and SWDI can be continuously monitored in Pernambuco and in the semiarid region, with wide application. The FEST-EWB model showed great potential in modeling soil moisture and temperature, generating matrix data (maps) with high spatial and temporal resolution that can directly assist in agricultural and water resources management. The data generated in this study is essential because it indicates diversified ways of estimating and monitoring hydrological processes that have great potential in the management of water resources in Northeast Brazil.

Keywords: water resources, drought, monitoring, Northeast.

LISTA DE FIGURAS

Figura 1. Principais sensores presentes no TRMM. Fonte: NASA (2011).	37
Figura 2. Conjunto de satélites e países que formam a constelação GPM Core Observatory. Fonte: NASA (2019).	38
Figura 3. Modelo digital de elevação do Estado de Pernambuco obtido a partir da base SRTM (NASA), com resolução de 30 m. Em destaque as mesorregiões do Estado.....	57
Figura 4. Disposição da grade do produto TRMM 3B42V7 no Estado de Pernambuco, com destaque para a localização das estações INMET dentro de cada pixel.....	58
Figura 5. Representação de um pixel hipotético do TRMM 3B42V7 com valores acumulados diários de precipitação em cinco estações (A) e valor médio estimado pelo satélite (B) em uma condição ideal (valor estimado igual a média aritmética das estações).	59
Figura 6. Incidência de falhas em dados de precipitação nas estações validadas durante o período avaliado. (A) Petrolina, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Arcoverde..	68
Figura 7. Diagramas de dispersão dos dados de precipitação estimados e mensurados durante o período avaliado, em escala mensal. (A) Petrolina, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Arcoverde.....	69
Figura 8. Quantidades de eventos subestimados e superestimados pelo TRMM nas estações validadas para o período de 1998 a 2017.....	70
Figura 9. Precipitação estimada pelo TRMM e mensurada pelas estações pluviométricas, em escala temporal mensal, para o período de 1998 a 2017. .	71
Figura 10. Variação sazonal da precipitação com base nas estações pluviométricas e produto TRMM 3B42V7.....	72
Figura 11. Frequência acumulada para os dados de precipitação estimados e mensurados em escala temporal mensal. (A) Petrolina, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (I) Arcoverde. ..	74
Figura 12. Diagramas de dispersão dos dados de precipitação estimados e mensurados durante o período avaliado, em escala anual. (A) Petrolina, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Arcoverde.....	76
Figura 13. Comparação dos dados de precipitação estimados e mensurados durante o período avaliado, em escala anual. (A) Petrolina, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Arcoverde..	77
Figura 14. Precipitação acumulada anual obtida a partir do TRMM 3B42V7 para o Estado de Pernambuco.....	79
Figura 15. Precipitação média anual obtida a partir do TRMM 3B42V7 para o Estado de Pernambuco.....	80
Figura 16. Precipitação acumulada mensal obtida a partir do TRMM 3B42V7 para o Estado de Pernambuco.	81

Figura 17. Histogramas de precipitação obtidos a partir do TRMM 3B42V7 para o Estado de Pernambuco.....	82
Figura 18. Quantidade de dias secos por ano obtidos a partir do TRMM 3B42V7 para o Estado de Pernambuco.	84
Figura 19. Quantidade de dias úmidos por ano obtidos a partir do TRMM 3B42V7 para o Estado de Pernambuco.....	85
Figura 20. Variação espacial da precipitação em função do perfil longitudinal.	87
Figura 21. Índice de precipitação padronizada (SPI) para o município de Recife obtido pelo TRMM 3B42V7 e postos pluviométricos em superfície, referente ao período de 1998 a 2017.....	89
Figura 22. Índice de precipitação padronizada (SPI) para o município de Garanhuns obtido pelo TRMM 3B42V7 e postos pluviométricos, referente ao período de 1998 a 2017.....	90
Figura 23. Índice de precipitação padronizada (SPI) médio para a mesorregião do São Francisco obtido pelo TRMM 3B42V7, referente ao período de 1998 a 2017.....	92
Figura 24. Índice de precipitação padronizada (SPI) médio para Estado de Pernambuco obtido pelo TRMM 3B42V7, referente ao período de 1998 a 2017.	93
Figura 25. Percentual de área afetada por secas em Pernambuco entre os anos de 1998 a 2017.	94
Figura 26. Monitoramento de seca baseado no SPI-12 obtido pelo produto TRMM 3B42V7 no Estado de Pernambuco, para o ano de 2012.	95
Figura 27. Monitoramento de seca baseado no SPI-24 obtido pelo produto TRMM 3B42V7 no Estado de Pernambuco, para o ano de 2013.	96
Figura 28. Anomalias de precipitação obtidas pelo TRMM para o período de 1998 a 2017.....	97
Figura 29. Anomalias de precipitação obtidas pelo CHIRPS para o período de 1998 a 2017.....	100
Figura 30. Comparação dos dados de precipitação do TRMM e CHIRPS para os anos de 2004 e 2012.....	101
Figura 31. Anomalias de NDVI obtidas pelo produto MOD13C2 para o período de fevereiro de 2000 a dezembro de 2017.	102
Figura 32. Comparação dos dados de precipitação do TRMM e NDVI, do MODIS, para os anos de 2004 e 2012.....	103
Figura 33. Área de estudo com localização dos postos pluviométricos utilizados para validação dos dados orbitais e representação dos pixels TRMM e GPM.	112
Figura 34. Distribuição mensal (esquerda) e sazonal (direita) da precipitação registrada pelo TRMM, GPM e pluviômetros em casa mesorregião do Estado de Pernambuco.....	117
Figura 35. Diagramas de dispersão entre a precipitação mensurada e estimada pelo TRMM 3B43V7 e GPM 3IMERGM.....	118

Figura 36. Relação entre altitude (perfil longitudinal) e incidência de erros de estimativas dos satélites TRMM 3B43V7 e GPM 3IMERGM. A – Erro médio absoluto (EMA); B – Raiz do erro quadrático médio (REQM); C – Precipitação anual e altitude.....	119
Figura 37. Distribuição temporal de tendências para os dados de precipitação estimados pelos produtos TRMM 3B43V7 e GPM 3IMERGM nas mesorregiões do Estado de Pernambuco.....	121
Figura 38. Distribuição espacial do coeficiente de correlação (CC), erro médio absoluto (EMA) e bias relativo (Bias %) por mesorregião do Estado de Pernambuco.....	124
Figura 39. Estações de monitoramento da umidade do solo no semiárido.....	132
Figura 40. Rede de PCD do CEMADEN utilizadas para a interpolação de dados de propriedades físicas e frações granulométricas do solo, com destaque para o Estado de Pernambuco.....	141
Figura 41. Frações granulométricas e propriedades físicas do solo para o semiárido brasileiro com base nos dados de PCD do CEMADEN, para a camada de 0 a 40 cm.	142
Figura 42. Frações granulométricas e propriedades físicas do solo para o semiárido brasileiro com base em estimativas do SoilsGrid, para a camada de 0 a 5 cm.	143
Figura 43. Localização das estações do INMET utilizadas para cálculo do índice AWD no semiárido.....	145
Figura 44. Índices estatísticos diários para os três produtos orbitais de umidade do solo sobre o Estado de Pernambuco. Barras verticais em CC indicam o desvio-padrão em torno da média; * Indica que apenas os pixels com dado no Litoral foram considerados.....	147
Figura 45. Índices estatísticos mensais para os três produtos orbitais de umidade do solo sobre o Estado de Pernambuco. Barras verticais em CC indicam o desvio-padrão em torno da média; * Indica que apenas os pixels com dado no Litoral foram considerados.....	149
Figura 46. Comparação dos dados diários de umidade do solo medidos in situ e estimados por sensoriamento remoto (SMAP, SMOS-IC e SMOS-CATDS) para o período de julho de 2015 a junho de 2018; Soil moisture: umidade do solo.	152
Figura 47. Diagramas de dispersão dos dados diários de umidade do solo, obtidos in situ e estimados por produtos de sensoriamento remoto, para o período de julho de 2015 a junho de 2018.....	153
Figura 48. Coeficiente de correlação (CC) para dados diários e mensais de umidade do solo obtidos por sensoriamento remoto sobre o Estado de Pernambuco; valores médios para o período de jul/2015 a jun/2018.	154
Figura 49. Valores de tendência (bias) para dados diários e mensais de umidade do solo obtidos por sensoriamento remoto sobre o Estado de Pernambuco; valores médios para o período de jul/2015 a jun/2018.	155
Figura 50. Valores de RMSD para dados diários e mensais de umidade do solo obtidos por sensoriamento remoto sobre o Estado de Pernambuco; valores médios para o período de jul/2015 a jun/2018.	156

Figura 51. Valores de ubRMSD para dados diários e mensais de umidade do solo obtidos por sensoriamento remoto sobre o Estado de Pernambuco; valores médios para o período de jul/2015 a jun/2018.....	157
Figura 52. Valores de CC para dados diários de umidade do solo obtidos por sensoriamento remoto sobre o Semiárido Brasileiro; valores médios para o período de jul/2015 a jun/2018.....	158
Figura 53. Valores de tendência (bias) para dados diários de umidade do solo obtidos por sensoriamento remoto sobre o Semiárido Brasileiro; valores médios para o período de jul/2015 a jun/2018.	159
Figura 54. Valores de ubRMSD para dados diários de umidade do solo obtidos por sensoriamento remoto sobre o Semiárido Brasileiro; valores médios para o período de jul/2015 a jun/2018.....	160
Figura 55. Índices estatísticos diários para os três produtos orbitais de umidade do solo sobre o semiárido.....	161
Figura 56. Variação semanal dos índices SWDI e AWD em algumas estações de cada um dos estados do semiárido que foram considerados nas avaliações.	166
Figura 57. Coeficientes de correlação entre os índices SWDI e AWD em algumas estações de cada um dos estados do semiárido que foram considerados nas avaliações.	167
Figura 58. Resumo estatístico do coeficiente de correlação, SWDI e AWD no semiárido brasileiro durante o período de julho de 2015 a junho de 2018.....	168
Figura 59. SWDI trimestral para o semiárido durante o período de julho de 2015 a junho de 2018. SWDI <-10,00 indica déficit hídrico absoluto.....	169
Figura 60. Precipitação média no semiárido de acordo com a série de dados espaciais do <i>WorldClim - Global Climate Data</i> (1970-2000).....	170
Figura 61. SWDI semestral para o semiárido durante o período de julho de 2015 a junho de 2018. SWDI <-10,00 indica déficit hídrico absoluto.....	171
Figura 62. SWDI médio para o semiárido durante o período de julho de 2015 a junho de 2018. SWDI <-10,00 indica déficit hídrico absoluto.....	173
Figura 63. Localização da Bacia do Rio Una (BRU), com destaque para as estações meteorológicas e agrometeorológicas utilizadas no estudo.	183
Figura 64. Parâmetros físicos e hidráulicos do solo obtidos a partir de diferentes números de imagens de LST do MODIS durante o teste de 'calibração'. BC: Brooks-Corey; CN: curva número.....	192
Figura 65. Histogramas de frequência da LST estimada pelo MODIS e FEST-EWB usando 15 e 24 imagens, respectivamente.	193
Figura 66. Imagens de temperatura de superfície do solo simulada e observada com seus respectivos histogramas de frequência, para o dia 10 dez. 2016 às 10:30 AM.....	194
Figura 67. Erro médio absoluto (EMA) obtido pela diferença entre a RET (FEST-EWB) e a LST (MODIS) antes e após a calibração, para cada imagem utilizada durante o procedimento.....	197

Figura 68. Erro médio absoluto (EMA) obtido pela diferença entre a RET (FEST-EWB) e a LST (MODIS) antes e após a calibração, para cada imagem utilizada durante o procedimento nas duas regiões climáticas da BRU.....	197
Figura 69. Comparação da LST diária estimada pelo FEST-EWB e observada pelas estações em superfície durante os anos de 2016 e 2017. (A) São Bento do Una, semiárido; (B) Barreiros, Mata Atlântica; r = coeficiente de correlação. EM, EMA e RMSE referem-se aos dados calibrados.	198
Figura 70. Comparação da LST diária (10:30 AM) simulada pelo FEST-EWB, estimada pelo MODIS e observada na estação de Barreiros (Mata Atlântica).	199
Figura 71. Comparação da umidade do solo (U.S.) simulada e observada na Bacia do Rio Una durante os anos de 2016 e 2017.....	201

LISTA DE TABELAS

Tabela 1. Instrumentos de sensoriamento remoto e plataformas de satélite (passadas e atuais) para observação global da umidade do solo. Fonte: (MOHANTY et al., 2017).	35
Tabela 2. Classificação dos períodos secos e chuvosos do SPI segundo Mckee, Doesken, Kleist (1993).	65
Tabela 3. Índices estatísticos utilizados para avaliação do desempenho do TRMM 3B42V7 em escala temporal mensal e anual.	78
Tabela 4. Índices estatísticos utilizados para validação dos produtos TRMM 3B43V7 e GPM 3IMERGM.	122
Tabela 5. Capacidade geral de detecção de eventos de chuva pelos produtos TRMM 3B43V7 e GPM 3IMERGM no Estado de Pernambuco.	124
Tabela 6. Resumo estatístico da avaliação dos dados estimados pelo SMAP, SMOS-IC e SMOS-CATDS em Pernambuco, em base diária e mensal.....	150
Tabela 7. Resumo estatístico dos dados de SWDI e AWD nas estações do INMET consideradas para a validação. CC: coeficiente de correlação; PMP: ponto de murcha permanente (déficit hídrico absoluto).	163
Tabela 8. Erro médio absoluto (EMA), erro médio (EM) e erro da raiz quadrada média (RMSE) computados para diferentes números de imagens de RET contra LST do MODIS. Todos os índices de avaliação estão expressos em °C; D.P.: desvio-padrão em torno da média.....	191
Tabela 9. Parâmetros de avaliação computados para todas as imagens de RET (FEST-EWB) contra as imagens de LST observada pelo MODIS para as simulações realizadas durante a calibração.	195
Tabela 10. Índices de avaliação da umidade do solo estimada pelo FEST-EWB antes e depois da calibração na Bacia do Rio Una. EM e EMA estão expressos em m ³ m ⁻³	200

LISTA DE ABREVIATURAS E SIGLAS

AMSR-E	<i>Advanced Microwave Scanning Radiometer - Earth Observing System</i>
APAC	Agência Pernambucana de Águas e Clima
ASAR	<i>Advanced Synthetic Aperture Radar</i>
ASCAT	<i>Advanced Scatterometer</i>
AWD	<i>Atmospheric Water Deficit</i>
BC	<i>Brooks-Corey</i>
BEC	<i>Barcelona Expert Center</i>
BRU	Bacia do Rio Una
CAD	Capacidade de Água Disponível
CATDS	<i>Centre Aval de Traitement des Données</i>
CC	Capacidade de Campo
CEMADEN	Centro Nacional de Monitoramento e Alertas de Desastres Naturais
CERES	<i>Clouds and the Earth's Radiant Energy System</i>
CESBIO	<i>Centre d'Etudes Spatiales de la BIOSphère</i>
CHG	<i>Climate Hazards Group</i>
CHRIPS	<i>Climate Hazards Group InfraRed Precipitation with Station data</i>
CMORPH	<i>CPC MORPHing technique</i>
CN	Curva-Número
CPC	<i>Climate Prediction Center</i>
CSI	Índice de Sucesso Crítico
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
ETo	Evapotranspiração de Referência
FAR	Razão de Falso Alarme
FEST-EWB	<i>Flash-flood Event-based Spatially distributed rainfall–runoff Transformation–Energy Water Balance</i>
GEE	Gases do Efeito Estufa
GOES	<i>Geostationary Operational Environmental Satellite</i>
GPM	<i>Global Precipitation Measurement</i>
IAF	Índice de Área Foliar

IC	INRA-CESBIO
IQD	Inverso do Quadrado da Distância
IMERG	<i>Integrated Multi-satellite Retrievals for GPM</i>
INMET	Instituto Nacional de Meteorologia
INRA	<i>Institut National de la Recherche Agronomique</i>
IPCC	Painel Intergovernamental sobre Mudanças Climáticas
IR	Infravermelho
ITCZ	Zona de Convergência Intertropical
JAXA	<i>Japan Aerospace eXploration Agency</i>
LAT	Latitude
LIS	<i>Lightning Imaging Sensor</i>
LON	Longitude
LST	Temperatura de Superfície do Solo
MDR	Taxa de Perda de Detecção
MIRAS	<i>Microwave Imaging Radiometer using Aperture Synthesis</i>
MODIS	<i>Moderate-Resolution Imaging Spectroradiometer</i>
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
PCD	Plataforma de Coleta de Dados
PDSI	Índice de Severidade da Seca de Palmer
PERSIANN	<i>Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks</i>
PNSH	Plano Nacional de Segurança Hídrica
PMP	Ponto de Murcha Permanente
POD	Probabilidade de Detecção
PR	<i>Precipitation Radar</i>
R	Coeficiente de Correlação
R²	Coeficiente de Determinação
RB	Bias Relativo
REQM	Raiz do Erro Quadrático Médio
RET	Temperatura de Equilíbrio Representativa
RFI	Interferência de Radiofrequência
RMR	Região Metropolitana de Recife
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
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>
TMI	<i>TRMM Microwave Imager</i>
TMPA	<i>Multisatellite Precipitation Analysis</i>
TRMM	<i>Tropical Rainfall Measuring Mission</i>
ubRMSD	Desvio da Raiz Quadrada Média não-tendenciosa
UF	Unidade Federativa
US	Umidade do Solo
VIRS	<i>Visible Infrared Scanner</i>

SUMÁRIO

INTRODUÇÃO GERAL.....	22
OBJETIVOS.....	24
Geral:.....	24
Específicos:	24
HIPÓTESES.....	24
CAPÍTULO I: Revisão bibliográfica	25
1 REVISÃO BIBLIOGRÁFICA.....	26
1.1 RECURSOS HÍDRICOS EM REGIÕES SEMIÁRIDAS.....	26
1.2 PRECIPITAÇÃO PLUVIOMÉTRICA	29
1.3 UMIDADE DO SOLO	31
1.4. SENSORIAMENTO REMOTO	33
1.4.1 Tropical Rainfall Measuring Mission (TRMM) Multisatellite Precipitation Analysis (TMPA)	36
1.4.2 Global Precipitation Measurement (GPM) Core Observatory	37
1.4.3 Soil Moisture and Ocean Salinity (SMOS)	39
1.4.5 Soil Moisture Active Passive (SMAP)	41
1.5 VALIDAÇÃO DE DADOS ORBITAIS.....	42
1.6 NORDESTE BRASILEIRO E O IMPACTO DAS SECAS.....	43
1.7 MUDANÇAS CLIMÁTICAS	45
1.8 UMIDADE DO SOLO E PRECIPITAÇÃO APLICADOS AO MONITORAMENTO DE SECAS	46
1.9 MODELAGEM HIDROLÓGICA	49
CAPÍTULO II: Validação e uso de dados de precipitação do TRMM 3B42 para monitoramento da seca no Estado de Pernambuco	52
1 INTRODUÇÃO	55
2 MATERIAL E MÉTODOS.....	56
2.1 Área de estudo	56
2.2 Base de dados.....	57
2.3 Validação dos dados do TRMM 3B42V7	60
2.4 Índices estatísticos	61
2.5 Dinâmica espaço-temporal da precipitação em Pernambuco	62
2.6 Quantidade de dias secos e úmidos por ano.....	62
2.7 Índice de Precipitação Padronizada – SPI	63
2.8 Anomalias de precipitação	65
2.9 Comparação com outras fontes de dados	66
3 RESULTADOS E DISCUSSÃO	66
3.1 Comparação da precipitação mensal com base no produto TRMM 3B42V7 e estações pluviométricas para série de 20 anos	66
3.2 Comparação da precipitação sazonal com base no produto TRMM 3B42V7 e estações pluviométricas para série de 20 anos	71
3.3 Comparação da precipitação anual com base no produto TRMM 3B42V7 e estações pluviométricas para série de 20 anos	74
3.4 Precipitação acumulada anual obtida a partir da série de dados do TRMM	78
3.5 Precipitação acumulada mensal obtida a partir da série de dados do TRMM ..	80
3.6 Quantidades de dias secos e úmidos por ano.....	82
3.7 Variabilidade espacial da precipitação em relação ao perfil longitudinal.....	86

3.8 Validação do índice de precipitação padronizada (SPI) obtido pelo produto TRMM 3B42.....	88
3.9 Incidência e severidade da seca no Estado de Pernambuco com base no produto TRMM 3B42V7	91
3.10 Anomalias climáticas	96
4 CONCLUSÕES	104
CAPÍTULO III: Validação dos dados de precipitação estimados pelos produtos TRMM 3B43V7 e GPM 3IMERGM no estado de Pernambuco.....	106
1 INTRODUÇÃO	109
2 MATERIAL E MÉTODOS.....	111
2.1 Área de estudo	111
2.2 Fontes de dados.....	112
2.3 Comparação dos dados	113
2.4 Análise de desempenho.....	114
3 RESULTADOS E DISCUSSÃO	116
4 CONCLUSÕES	125
CAPÍTULO IV: Validação e aplicação de dados de umidade do solo estimados por sensoriamento remoto na detecção de secas no semiárido.....	126
1 INTRODUÇÃO	129
2 MATERIAL E MÉTODOS.....	130
2.1 Área de Estudo	130
2.1.2 Semiárido Brasileiro.....	130
2.1.3. Estado de Pernambuco	131
2.2 Séries de dados.....	132
2.2.1 Estações do CEMADEN	133
2.2.2 Estações da APAC	133
2.2.3 SMOS (MIRAS).....	134
2.2.4 SMAP.....	135
2.3 Validação dos dados.....	136
2.4 Índice de seca.....	139
2.4.1 Propriedades físicas do solo.....	140
2.4.2 Soil Water Deficit Index (SWDI)	143
2.4.3 Atmospheric Water Deficit (AWD).....	144
3 RESULTADOS E DISCUSSÃO	146
3.1 Avaliação dos dados orbitais de umidade do solo em Pernambuco.....	146
3.2 Avaliação dos dados orbitais de umidade do solo no Semiárido.....	157
3.3 Índices de seca SWDI e AWD	162
4 CONCLUSÕES	176
CAPÍTULO V: Calibração do modelo hidrológico FEST-EWB utilizando dados de sensoriamento remoto em uma bacia inserida em região de transição climática no Nordeste Brasileiro.....	177
1 INTRODUÇÃO	180
2 MATERIAL E MÉTODOS.....	183
2.1 Área de estudo	183
2.2 Dados de superfície	184
2.3 Modelo digital de elevação e propriedades hidráulicas do solo	185
2.4 Dados de sensoriamento remoto	186
2.5 O modelo hidrológico: FEST-EWB.....	187
2.6 Calibração e validação.....	188
2.7 Definição do número de imagens de LST necessárias para a calibração.....	189
3 RESULTADOS E DISCUSSÃO	191
3.1 Número de imagens de LST do MODIS necessário para a calibração	191

3.2 Calibração	193
3.3 Validação.....	198
3.3.1 Temperatura de superfície do solo (LST)	198
3.3.2 Umidade do solo (US)	200
4 CONCLUSÕES	202
CONSIDERAÇÕES FINAIS.....	203
REFERÊNCIAS.....	205

INTRODUÇÃO GERAL

A população e a demanda por água estão crescendo rapidamente nas regiões mais secas do mundo. Pelo menos mais de 20% da população mundial, o que corresponde a 1,2 bilhão de pessoas, atualmente vive em áreas com escassez hídrica. Regiões áridas e semiáridas ocorrem em aproximadamente 30% da área continental total da Terra e, com a intensificação da desertificação causada pelo aquecimento global e práticas deficitárias de manejo do solo, esse percentual está gradativamente aumentando (KOCH e MISSIMER, 2016).

A avaliação e gestão dos recursos hídricos em regiões subdesenvolvidas e semiáridas ainda estão repletas de dificuldades. A típica cadeia de gerenciamento dos recursos hídricos começa com a coleta de dados, processamento e análise das informações coletadas dentro do cenário natural e socioeconômico, finalmente gerando produtos finais que impulsionam a tomada de decisões. No entanto, muitas dessas etapas costumam ser problemáticas quando confrontadas com questões de desenvolvimento e pressões severas sobre os recursos hídricos (BUYTAERT et al., 2012).

Aliado a isso, ainda há as secas, fenômenos climáticos que afetam a atividade humana e ambiental globalmente e podem ser consideradas um dos desastres naturais mais onerosos e generalizados (SHEFFIELD et al., 2014). Especificamente no Nordeste Brasileiro (NEB), as secas são recorrentes e causam severos impactos nas atividades sociais, econômicas e na disponibilidade dos recursos hídricos, afetando milhares de pessoas. Em 2012, o NEB enfrentou a seca mais impactante dos últimos anos, que se estendeu até 2016 (SOUZA et al., 2018).

Uma das maiores limitantes à gestão dos recursos hídricos é enfrentada justamente na primeira etapa do processo, que envolve a coleta de dados. A escassez de redes de monitoramento em superfície aliada à alta variabilidade espacial e temporal dos dados representam um grande problema à adequada compreensão dos processos envolvidos (LU et al., 2018). Em face disso, métodos alternativos de estimativa desses dados surgiram ao longo das décadas, especialmente com o avanço das áreas de sensoriamento remoto e modelagem hidrológica.

Diversas variáveis meteorológicas, biofísicas e relacionadas às propriedades do solo atualmente são monitoradas de forma contínua por sensores orbitais, gerando informações em escala espacial e temporal regulares que favorecem aplicações diversas, dispensando a utilização de dados *in situ* após correta validação e, se necessário, ajuste para remoção de tendências (SILVA LELIS et al., 2018).

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). Nesse sentido, a grande vantagem do sensoriamento remoto é a possibilidade de estudo em diferentes escalas espaciais, desde uma pequena bacia hidrográfica até o globo inteiro (FERNANDEZ-MORAN et al., 2017; JACKSON et al., 2015).

Na modelagem hidrológica, também são grandes as possibilidades de estimativa de variáveis do balanço hídrico. Embora a modelagem necessite de dados de entrada mensurados, é crescente a tendência de utilizar informações obtidas por sensores remotos, seja em substituição aos dados medidos *in situ*, preenchimento de falhas ou calibração (CORBARI e MANCINI, 2014; LIU et al., 2017). No caso de modelos distribuídos, que estimam os processos espacialmente em cada pixel (ponto) do domínio da bacia, a modelagem se destaca por apresentar melhores resoluções espaciais, especialmente para aplicações em bacias hidrográficas (CORBARI et al., 2015b), além de possibilitar a geração contínua de dados após a calibração, conforme o modelo for alimentado com dados atualizados.

A utilização de ferramentas e tecnologias que favoreçam uma gestão mais competente dos recursos hídricos deve ser sempre prioritária. Em uma região onde as secas são persistentes e as dificuldades de acesso à água, até mesmo para consumo humano, são marcantes, a adoção de técnicas que possibilitem compreender melhor os processos que interferem na disponibilidade e qualidade dos recursos hídricos, espacialmente e temporalmente, é uma atividade promissora que tende a ganhar cada vez mais destaque e atenção.

OBJETIVOS

Geral:

Avaliar a eficiência de dados de sensores remotos e modelagem na estimativa e caracterização da dinâmica espaço-temporal de atributos hidrológicos e índice de seca no Semiárido, com foco na gestão dos recursos hídricos.

Específicos:

- Validar dados de precipitação obtidos pelos instrumentos TRMM e GPM no Estado de Pernambuco;
- Validar dados de umidade do solo estimados pelos satélites SMAP e SMOS em todo o Semiárido, com base em dados *in situ*;
- Calcular índices de seca meteorológicos e agrícolas a partir dos dados previamente validados para o Semiárido, com maior foco em Pernambuco;
- Estimar atributos do balanço de água e energia na Bacia do Rio Una através do modelo distribuído FEST-EWB.

HIPÓTESES

- I. Dados de sensores orbitais podem ser utilizados para caracterizar a dinâmica espaço-temporal da umidade do solo, precipitação pluviométrica e índices de seca no Semiárido Brasileiro;
- II. O modelo distribuído FEST-EWB, desenvolvido na Itália, pode ser aplicado para estimativa de atributos do balanço de água e energia em bacias hidrográficas do Nordeste Brasileiro.

CAPÍTULO I

REVISÃO BIBLIOGRÁFICA

1 REVISÃO BIBLIOGRÁFICA

1.1 RECURSOS HÍDRICOS EM REGIÕES SEMIÁRIDAS

O termo semiárido normalmente é usado para descrever uma região em que a precipitação média anual varia de 250 mm a 500 mm. A vegetação é predominantemente formada por arbustos que perdem as folhas nos meses secos ou por pastagem que seca durante os períodos menos chuvosos. Essa caracterização climática também é típica do bioma Caatinga, presente exclusivamente no Nordeste Brasileiro (CIRILO, 2008). Os índices pluviométricos que ocorrem em regiões semiáridas são suficientes para suprir as necessidades agrícolas apenas de forma parcial e limitada (ZHU et al., 2015).

Nesse contexto, 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). Apesar das severas condições climáticas, Rebouças (1997) enfatiza que o Nordeste e o Brasil, de modo geral, possuem condições favoráveis ao desenvolvimento da vida e ao 'ciclo das águas'. Outros países possuem condições áridas e semiáridas ainda mais limitantes, como Israel, por exemplo, que chega a acumulados de precipitação média anual de cerca de 30 mm em algumas regiões. No entanto, devido a uma exemplar gestão hídrica, especialmente na agricultura, o país consegue produzir até mesmo nessas áreas. A eficiência dos sistemas de irrigação utilizados chega a 90%, sendo 30% superior aos demais países que possuem condições climáticas menos severas e dependem fortemente da agricultura, como o Brasil.

Koch e Missimer (2016), realizando uma compilação de pesquisas envolvendo o gerenciamento de recursos hídricos em 14 regiões áridas e semiáridas distintas, concluíram que existe uma grande diversidade de tecnologias e métodos para avaliar e resolver problemas decorrentes do déficit e uso inadequado da água em regiões secas, incluindo medições em campo, modelagem e sensoriamento remoto. Como produtos dessas pesquisas, políticas e estratégias para fiscalização de uso da água, controle de salinização, manutenção de ecossistemas e garantia do uso sustentável desse recurso para suprir consumo público, agrícola e industrial foram desenvolvidos

com aplicações bem-sucedidas, o que reforça a importância do uso de tecnologias combinadas para dar suporte às entidades envolvidas na gestão hídrica.

O adequado manejo dos recursos hídricos em regiões semiáridas requer o conhecimento dos processos hidrológicos envolvidos, conforme supracitado. Para áreas pequenas, como microbacias, isso pode ser realizado através de observações *in situ* em conjunto com modelagem hidrológica (SOUZA e PAZ, 2016; TANGDAMRONGSUB et al., 2017). Já áreas mais extensas ou com deficiência de redes de monitoramento requerem técnicas mais sofisticadas para computar os processos que atuam no balanço hídrico, como o uso de dados orbitais, através de técnicas de sensoriamento remoto (LOUZADA, XAVIER e PEZZOPANE, 2018; ZHANG et al., 2019).

O Estado de Pernambuco possui bons exemplos na aplicação de técnicas e metodologias com potencial para auxiliar na gestão dos recursos hídricos. Em uma pequena bacia do semiárido pernambucano, em Pesqueira, Lopes et al. (2019) utilizaram diferentes técnicas de conservação do solo para avaliar a erosão e escoamento superficial em uma tentativa de encontrar soluções de baixo custo que, além de evitar o desgaste e perdas de solo, contribuíssem para a manutenção do conteúdo de água por mais tempo após as chuvas, prática de grande importância em regiões semiáridas. Os autores detectaram que o uso de cobertura morta e palma forrageira apresentaram bom desempenho, evitando perdas de sedimentos e promovendo maior infiltração no solo, sendo uma boa opção em áreas desprovidas da vegetação nativa de Caatinga.

Souza et al. (2018), utilizando dados de umidade do solo obtidos por sensoriamento remoto, detectaram que essas informações são de grande aplicabilidade na detecção de anomalias, evidenciando épocas em que o conteúdo de água no solo está abaixo do esperado para aquele período em comparação com a média histórica. Após comparação com dados de precipitação, foi confirmado o potencial do produto orbital utilizado. Esse tipo de estudo é essencial para o monitoramento da seca agrícola e pode contribuir de maneira efetiva no planejamento de suprimento de água para as culturas, promovendo maior eficiência no uso do recurso e garantindo melhor produtividade.

Em uma abordagem mais prática do ponto de vista do reaproveitamento da água, Cavalcante et al. (2017) mencionam a importância do reúso de água residuária de estações de tratamento de esgoto, especialmente no polo de produção agrícola de Petrolina. Os autores avaliaram diversos parâmetros químicos e físicos da água para inferir sobre a segurança do seu uso. A água analisada nas estações da cidade apresenta restrição química moderada quanto aos riscos de salinidade e toxicidade, com restrição severa para o risco do entupimento de tubulações. No entanto, os autores não descartam a possibilidade de uso da água residuária após tratamento adicional.

Magalhães et al. (2018) utilizaram modelagem hidrológica, através do modelo semi-distribuído *Soil and Water Assessment Tool* (SWAT), para simular e avaliar os impactos da precipitação sobre a geração de escoamento superficial e umedecimento do solo em uma microbacia do semiárido de Pernambuco. De fato, o modelo SWAT já é amplamente utilizado em regiões semiáridas para estudo de processos hidrológicos em todo o mundo, inclusive com a simulação de diferentes cenários futuros, tanto de uso e ocupação do solo quanto climáticos, para verificar os efeitos das alterações sobre os recursos hídricos e no solo (ZETTAM et al., 2017; EMAMI e KOCH, 2019; SANTOS et al., 2019).

O Estado de Pernambuco é um grande produtor de cana-de-açúcar, porém, devido à limitação hídrica, as usinas vêm suprindo as necessidades nutricionais e de água da cultura fornecendo vinhaça, que é um subproduto do processamento da cana. Silva et al. (2014), avaliando os impactos que a utilização da vinhaça poderiam trazer à salinidade de águas subterrâneas, não identificaram riscos à salinização monitorando pelo período de um ano, complementando que a vinhaça pode ser aplicada em áreas de várzea a cada safra, em regiões de elevada pluviosidade, como na área em que o estudo foi aplicado, que possui precipitação média anual de 2100 mm. Obviamente, esse tipo de estudo precisa ser replicado em condições menos favoráveis à lixiviação de sais, especialmente no semiárido.

Nesse sentido, Oliveira (2015) alerta que a exploração de águas subterrâneas deve ser feita com muito rigor. Exemplos de utilização duvidosa já são percebidos no Nordeste, como em Mossoró, no Rio Grande no Norte, que bombeia água até a profundidade de 1000 m para a irrigação de culturas

destinadas à exportação, e no Vale do Gurguéia no Piauí (Poço Violeta) que jorra água intermitentemente e com muito pouco uso.

É grande a preocupação com a utilização dos recursos hídricos em Pernambuco e no semiárido como um todo. Os estudos deixam claro que esse é um tema de pesquisa persistente. Em uma região marcada pela irregularidade natural da distribuição da água, ações oriundas dessas pesquisas são necessárias para evitar o mau uso decorrente também de origem antrópica, que é ainda mais sério e preocupante do ponto de vista de preservação e uso sustentável da água.

1.2 PRECIPITAÇÃO PLUVIOMÉTRICA

O ciclo hidrológico desempenha um papel crítico no funcionamento do sistema terrestre, atuando nas mudanças de fase da água do estado líquido para vapor, que exigem e liberam quantidades substanciais de calor. Atualmente, como o clima está mudando devido ao efeito estufa e aquecimento da superfície, é esperado que o ciclo hidrológico mude também, especialmente a precipitação, que possui estreita relação com a temperatura do ar por ser sensível às suas variações, já que esse processo interfere na evapotranspiração e balanço de água no solo e atmosfera (KLEIDON e RENNER, 2013).

A precipitação é determinante na expressão de fenômenos de seca. Ela regula os diferentes tipos de seca e a sua intensidade. Por isso, com base no período em que a precipitação é insuficiente (abaixo da média histórica), as secas podem ser classificadas como meteorológicas (deficiência de chuvas em uma região por um determinado período de tempo), hidrológica (deficiência no suprimento de águas superficiais e subsuperficiais), agrícola (deficiência de disponibilidade de água para o suprimento e crescimento vegetal) e socioeconômica (quanto a limitação dos recursos hídricos eleva o grau da seca, afetando as atividades humanas direta e indiretamente) (ALVALÁ et al., 2017; ALI, HUSSAIN e FAISAL, 2019).

Apesar de ser um fator determinante em estudos de seca, alterações no regime pluviométrico também são essenciais para compreender outros processos, como a erosão do solo, perda de biodiversidade e produtividade

agrícola. Assim, a análise estatística de propriedades inerentes à precipitação desempenha papel crucial não apenas nas avaliações de secas e cheias, mas também no manejo e gerenciamento dos recursos hídricos como um todo (LIANG, WANG e ZHANG, 2018).

Maciel et al. (2012) enfatizam que a atmosfera é muito complexa e dinâmica, e isso tem efeito direto na precipitação. Por isso, as chuvas sofrem a influência de vários fatores, tais como a posição atmosférica e a geografia da região ou país, a configuração do território, as altitudes e as linhas mestras do relevo, a latitude, a altitude, a proximidade do mar, a vegetação e o efeito da continentalidade. Ações antrópicas também vêm condicionando as alterações detectadas na precipitação, especialmente nas últimas décadas em decorrência do aquecimento global (WAN et al., 2017).

Embora seja reconhecida como uma componente essencial nos ciclos da água e energia e por desempenhar importantes papéis em diversas áreas de pesquisa, como hidrologia, meteorologia e climatologia, a precipitação é uma variável que deve ser monitorada com cuidado para que seja considerada representativa para uma determinada área (TANG et al., 2015). Devido a isso, estimativas precisas da precipitação permanecem 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, principalmente em regiões montanhosas, nos oceanos e polos. Além disso, é importante destacar que a interpolação de dados de precipitação em regiões com poucos postos pluviométricos pode levar a sérias incertezas (LU et al., 2018; WANG et al., 2017).

Nos últimos anos, diversas missões têm focado em buscar alternativas viáveis para sanar as limitações relativas ao monitoramento da precipitação. Dentre os principais produtos atualmente disponíveis, podem ser citados o *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks* (PERSIANN) (NGUYEN et al., 2018); o *Climate Prediction Center (CPC) morphing technique* (CMORPH) (XIE et al., 2017); o *Climate Hazard Group InfraRed Precipitation Satellite* (CHIRPS) (BAI et al., 2018b); o *Tropical Rainfall Measuring Mission (TRMM) Multi-satellite Precipitation Analysis (TMPA)* (ANJOS et al., 2017) e o *Integrated Multi-Satellite Retrievals (IMERG)*, da missão *Global Precipitation Measurement (GPM)* (CHEN et al.,

2018). Todos esses produtos já são amplamente difundidos globalmente e com precisão comprovada em diversos estudos.

1.3 UMIDADE DO SOLO

A umidade do solo é uma variável chave nos ciclos da água e energia em escala global. O seu conhecimento, com medições de alta qualidade, é necessário para uma série de aplicações, incluindo a previsão do tempo em curtos períodos, modelagem hidrológica, estimativa de produção agrícola, monitoramento de secas e estudos de mudanças climáticas (BROCCA et al., 2017; MORAN et al., 2015).

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, mas os recursos hídricos são bastante limitados e mal distribuídos (WU et al., 2016). Além disso, nessas regiões existe uma grande preocupação acerca da disponibilidade e qualidade dos recursos hídricos em longo prazo, situação que se agrava em consequência dos efeitos crescentes do clima, associados à reduzida disponibilidade, seja quantitativa ou qualitativa, de água superficial e subterrânea (GHEYI et al., 2012).

Devido ao fato de estar situada na interface solo-atmosfera, a umidade do solo influencia muitos processos que ocorrem na superfície, incluindo a divisão de energia em calor latente e sensível, afetando, desta forma, a evapotranspiração e temperatura do ar (SENEVIRATNE et al., 2010). Além disso, divide a água oriunda da precipitação em infiltração e escoamento superficial, afetando o fluxo, recarga de água subterrânea, absorção de água pelas plantas e, conseqüentemente, a transpiração e metabolismo do vegetal (TUTTLE e SALVUCCI, 2014; GARNAUD et al., 2016)

A umidade do solo exerce um papel importante em processos biológicos e geoquímicos (ex.: nitrificação, respiração e troca de íons no solo), além de ser usada em modelos de previsão de inundação e secas (BROCCA; MELONE e MORAMARCO, 2011; SHEFFIELD et al., 2014). Desempenha, inclusive, papel crucial para compreender os processos hidrológicos em áreas agrícolas,

possibilitando, também, inferir sobre as peculiaridades climáticas e ambientais de uma determinada região (YOUNIS e IQBAL, 2015).

O conhecimento acerca do conteúdo de água no solo é, ainda, essencial para alimentar diversos modelos hidrológicos. Monitoramento de secas, modelagem de escoamento superficial e previsão de inundações, previsão numérica do tempo, avaliação da superfície do solo e de modelos climáticos, avaliação de risco de incêndio, monitoramento agrícola e previsão de produção das culturas são algumas das aplicações beneficiadas com o monitoramento constante da umidade do solo em campo (BROCCA et al., 2017; BROCCA; MELONE e MORAMARCO, 2011; MORAN et al., 2015).

A caracterização espaço-temporal da dinâmica da umidade do solo fornece informações essenciais não apenas para a modelagem, mas também para a conservação e recuperação da vegetação, assegurando a sustentabilidade do uso do solo e facilitando a adoção de práticas mais racionais de gestão e manejo dos recursos hídricos (ZHANG e SHAO, 2013), especialmente em grandes áreas, como as bacias hidrográficas, que estão constantemente sujeitas à ação antrópica.

Quando se trata de umidade do solo, 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. A depender das condições, essas características podem verter ou reter a água, deixando o padrão de umidade do solo no estado seco muito desordenado (MONTE-MOR, 2012).

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.

Yang et al. (2012), estudando a variação espacial da umidade do solo em camadas superficiais e profundas em região semiárida da China,

concluíram que fatores topográficos, como o grau de declividade e sua posição no terreno, afetam o conteúdo de água de diferentes formas, tanto na superfície quanto em zonas mais profundas. Em contrapartida, Grayson et al. (2006) concluíram que a precipitação é o evento dominante no controle da umidade do solo em regiões áridas e semiáridas. Efeitos topográficos são mais significativos em condições de alta umidade, que propiciem fluxo subterrâneo lateral. No entanto, em condições áridas, esse efeito ocorre somente em escala pontual.

De acordo com Amri et al. (2011), no caso de regiões semiáridas, a análise sazonal da influência da vegetação pode levar a erros na estimativa da umidade do solo. De fato, como consequência de períodos frequentes de seca, a dinâmica do ciclo da vegetação pode ser altamente variável de um ano para outro, ainda que se considere um mesmo período agrícola. Assim, trabalhos que consideram apenas um índice de vegetação, mesmo que associado a outros parâmetros, como a temperatura de superfície do solo, podem levar a incertezas na quantificação do conteúdo de água, além de dificultar o estudo da sua dinâmica temporal (SOBRAL; FILHO e CANDEIAS, 2011; YOUNIS e IQBAL, 2015).

Desta forma, torna-se necessário avaliar a umidade do solo de maneira mais abrangente, tanto espacialmente quanto temporalmente. Embora seja uma atividade laboriosa e de elevado custo, existem diversas alternativas viáveis, principalmente nos últimos anos, com a popularização de técnicas de sensoriamento remoto. Para a região Nordeste do país, esta pode ser uma ferramenta de grande utilidade na compreensão da dinâmica sazonal da umidade do solo, especialmente quando se considera a escassez de estações que monitoram esta variável diretamente no solo.

1.4. SENSORIAMENTO REMOTO

O sensoriamento remoto é considerado um meio primário de aquisição de dados espaciais, medindo a radiação eletromagnética que interage com a atmosfera e os objetos sem a necessidade de contato direto com o alvo. As interações da radiação eletromagnética com a superfície da Terra podem fornecer informações não apenas sobre a distância entre o sensor e o objeto,

mas também sobre a direção, intensidade, comprimento de onda e polarização da radiação eletromagnética. Essas medições podem oferecer informações posicionais sobre os objetos e dados sobre as características dos materiais da superfície (ZHU et al., 2017).

Através do sensoriamento remoto, a observação da superfície da Terra ou da atmosfera se dá a partir do espaço ou pelo uso de veículo aéreo não-tripulado (VANT) ou drone. A aquisição de informações sobre os alvos geográficos ocorre por meio da captação por sensores da Radiação Eletromagnética (REM) refletida ou emitida, sendo os sensores equipamentos capazes de coletar e registrar a energia proveniente do objeto (ANTONIO e OLIVEIRA, 2010).

A técnica possui diversas aplicações no mapeamento de uso e ocupação do solo, agricultura, mapeamento de classes de solos, planejamento florestal, agrícola e urbano, estudos arqueológicos, observações militares, alterações de uso do solo, desflorestamento, dinâmica da vegetação, dinâmica da qualidade da água, crescimento urbano etc. (JEYASEELAN, 2004).

Os sensores orbitais variam quanto à finalidade, o que lhes confere diferentes características. Os sensores ópticos, por exemplo, mais utilizados para monitoramento ambiental e de mudanças no uso do solo, operam na faixa visível do espectro (0,4 a 0,7 μm). Os satélites que comportam esses sensores possuem órbita polar, o que lhes permite imagear toda a superfície do planeta com resoluções espacial e temporal variadas. Nesse grupo, enquadram-se, por exemplo, o LANDSAT, Terra/Aqua (MODIS), SPOT e CBERS (JOSHI et al., 2016).

Existem, ainda, os sensores com órbita geoestacionária. Como possuem velocidade de rotação igual à da Terra e giram no sentido equatorial, coletam dados sempre a partir de uma mesma posição. São usados para monitorar fenômenos que alteram constantemente, especialmente meteorológicos. Para conseguir manter essa posição, possuem altitudes bastante elevadas, normalmente superiores a 37 mil quilômetros de altitude e operam, normalmente, nas faixas do visível e infravermelho, além de possuírem canais específicos para detecção de vapor d'água. Como exemplos, podem ser citados o GOES (*Geostationary Operational Environmental Satellites*) e o METEOSAT (LITTLE et al., 2004; JOHN et al., 2019).

Para alguns tipos específicos de estudo, como monitoramento da umidade do solo e precipitação, por exemplo, é necessário um conjunto diferenciado de sensores com a habilidade de ‘enxergar’ além da camada difusa de gases que compõem a atmosfera. Além disso, 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 por esses alvos. Nesse caso, o solo. Esses sensores operam na faixa espectral de microondas, com comprimento de onda variando de 0,5 a 100 cm (BITTELLI, 2011; JOSHI *et al.*, 2016).

Os sensores desse grupo podem ser divididos em ativos (radares) e passivos (radiômetros). Radiômetros detectam a radiação emitida pela superfície da Terra, enquanto radares transmitem uma onda eletromagnética e mensura a energia refletida que retorna ao sensor (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. Fonte: (MOHANTY *et al.*, 2017).

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

1.4.1 Tropical Rainfall Measuring Mission (TRMM) Multisatellite Precipitation Analysis (TMPA)

A missão TRMM é fruto de uma sólida parceria entre a NASA e a Agência Japonesa de Exploração Aeroespacial (JAXA). Lançado em 1997, o satélite teve como principal objetivo o estudo da precipitação tropical, atuando entre as latitudes de 50° S e 50° N, dessa forma, não cobrindo os polos terrestres. A altitude do TRMM é de aproximadamente 403 km, com uma elevada resolução temporal (3 horas), o que lhe confere grande potencial para estudos de precipitação (ANJOS, NÓBREGA e CANDEIAS, 2017). Devido a problemas de órbita, a missão TRMM começou a ser encerrada em 2015. A NASA garantiu o fornecimento dos dados do produto até meados de 2016. No entanto, essas expectativas foram superadas e a missão continuou gerando dados até 31 de dezembro de 2019.

A resolução espacial do TRMM é de 0.25° x 0.25°, o que corresponde a aproximadamente 27 x 27 km. As estimativas de precipitação são feitas combinando informações do sensor de microondas e infravermelho. O satélite possui três sensores primários para estimativa da precipitação, incluindo: *TRMM Microwave Imager* (TMI), que fornece informações do volume precipitado, água líquida da nuvem, intensidade da chuva e os tipos de precipitação (convectiva e estratiforme); *Precipitation Radar* (PR), que emite informações do tamanho das gotículas nas nuvens, oferecendo informações da estrutura vertical da precipitação, também fornecendo mapas tridimensionais da estrutura da precipitação; *Visible Infrared Scanner* (VIRS), que faz a conexão entre a precipitação derivada usando técnicas visíveis e infravermelhas (IR) e coleta informações sobre o tipo de nuvem e temperatura no topo das nuvens. Além disso, há o *Lightning Imaging Sensor* (LIS), sensor óptico passivo que detecta eventos de raios na faixa do oxigênio e o *Clouds and the Earth's Radiant Energy System* (CERES), que fornecia dados da energia trocada entre o Sol, a atmosfera e a superfície (Figura 1). Esse último, no entanto, funcionou apenas até o ano de 2000 (AMEKUDZI et al., 2016).

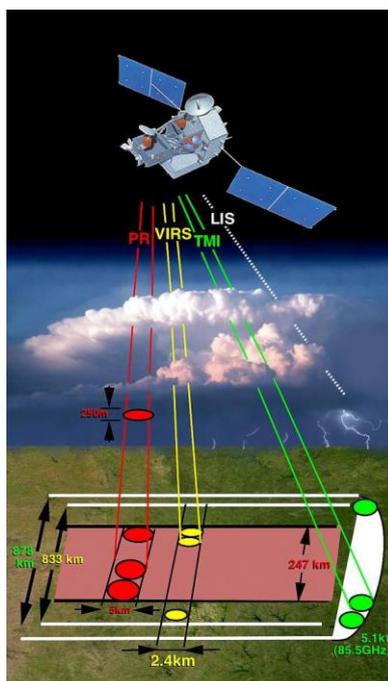


Figura 1. Principais sensores presentes no TRMM. Fonte: NASA (2011).

O TRMM possui diversos produtos com resolução temporal de 3 horas ou diários (3B42 e 3B42 Real Time – 3B42RT) e mensal (3B43). O produto 3B43 é idêntico ao 3B42, sendo apenas acumulado mensalmente. Já os produtos horários ou diários 3B42 e 3B42RT possuem diferenças. O primeiro só é fornecido vários dias após a passagem do satélite porque passa por calibração usando como base de referência dados de estações em superfície para correção de tendência, por isso, é o mais indicado para pesquisas e, principalmente, validação. O segundo fornece dados em tempo quase real, porém sem qualquer tipo de correção. É indicado para aplicações mais emergenciais e previsão do tempo, mas não assegura a qualidade do dado obtido.

1.4.2 Global Precipitation Measurement (GPM) Core Observatory

O GPM é também fruto da parceria NASA/JAXA e foi lançado em 2014 com o objetivo de dar continuidade à missão TRMM, assegurando a continuidade da série de precipitação. São quatro as principais diferenças entre o GPM e o seu antecessor: 1) o GPM possui resolução espacial maior, de 0,1° (~11 km), o que o torna mais preciso na detecção de microvariações da precipitação; 2) a resolução temporal é de apenas 30 min., tornando o GPM uma excelente ferramenta para aplicações que requerem dados constantes de precipitação. Além disso, por ter esse alto poder temporal de detecção, acaba

sendo mais preciso, já que a precipitação altera bastante a intensidade em curtos períodos; 3) ao contrário do TRMM, o GPM estima a precipitação em escala global, com cobertura espacial de 60° S a 60° N; 4) é formado por uma constelação de satélites, daí o fato de também ser designado de 'Core Observatory', isso porque o GPM funciona como o núcleo, que recebe, processa e distribui os dados de precipitação coletados por um total de 10 satélites, além de também possuir sensores próprios para estimativa do fenômeno (CHEN et al., 2018; XU et al., 2017). A constelação de satélite que integra a missão GPM, bem como os países que fazem aliança com a NASA, podem ser observados na Figura 2.

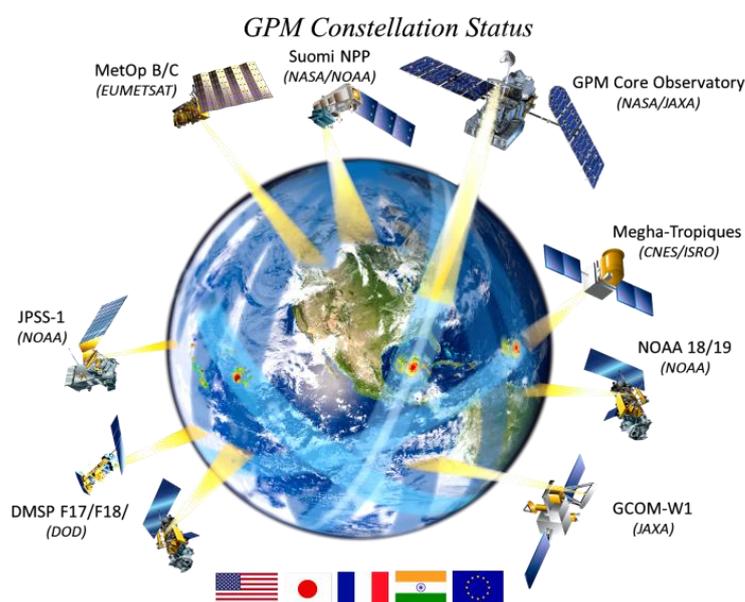


Figura 2. Conjunto de satélites e países que formam a constelação GPM Core Observatory. Fonte: NASA (2019).

O GPM é o primeiro satélite a carregar um radar de precipitação que opera em duas frequências (a banda Ku com 16,3 GHz e a banda Ka com 35,5 GHz), além de um imageador de microondas multicanal (GMI), com frequência que varia de 10 a 183 GHz, o que estende o potencial do GPM quando comparado ao TRMM. Esse conjunto permite que o satélite possa detectar a precipitação em volumes muito baixos, menores que $0,5 \text{ mm h}^{-1}$, além de precipitação de neve (BERIA et al., 2017).

Atualmente, os produtos do GPM estão na versão 5 (v5) e são distribuídos com a nomenclatura de *Integrated Multi-satellite Retrievals for GPM* (IMERG), justamente por considerar a compilação de diferentes plataformas orbitais. Segundo a NASA, via página de distribuição dos produtos

(<https://pmm.nasa.gov/data-access/downloads/gpm>), o algoritmo do IMERG destina-se a intercalar, fundir e interpolar “todas” as estimativas de precipitação por satélite, juntamente com estimativas de satélite infravermelho (IR) calibradas por microondas, análises de calibração de precipitação e outros estimadores de precipitação em tempo e espaço ao longo de todo o globo. O sistema é executado várias vezes para cada tempo de observação, primeiro fornecendo uma estimativa rápida (“início imediato” do IMERG) e gerando sucessivamente melhores estimativas à medida que mais dados chegam (“última execução” do IMERG). A etapa final usa dados de indicadores mensais para criar produtos em nível de pesquisa (“execução final” do IMERG). O produto final, destinado à pesquisa, é chamado de “*Research - Final Run*”.

1.4.3 Soil Moisture and Ocean Salinity (SMOS)

O satélite SMOS foi lançado pela Agência Espacial Europeia (ESA) em novembro de 2009 com o objetivo de monitorar a umidade do solo à profundidade de até 5 cm, com acurácia de $0,04 \text{ m}^3 \text{ m}^{-3}$, em escala global e com tempo de revisita de 1 a 3 dias. O SMOS foi o primeiro satélite dedicado especificamente a monitorar a umidade do solo, operando na banda L (1.4 GHz), com passagem de órbita ascendente às 06:00h e descendente às 18:00h, em horário local (KERR et al., 2010; LEROUX et al., 2014).

O sensor do SMOS que estima os dados de umidade do solo é o *Microwave Imaging Radiometer with Aperture Synthesis* (MIRAS), radiômetro passivo que detecta a radiação de microondas emitida pela superfície da Terra com frequência de 1.41 GHz (comprimento de onda de 21,2 cm; banda L).

O produto oficial do SMOS, chamado SMOSL3 (SMOS Level 3), é fornecido publicamente pelo *Centre Aval de Traitement des Données* (CATDS; <https://www.catds.fr/sipad/>), que integra dados globais de umidade do solo com resoluções temporais de 1, 3 e 10 dias ou mensais e resolução espacial de 27 km (LEROUX et al., 2014; WAGNER et al., 2014). Os dados são fornecidos no formato NetCDF com grid EASE (*Equal Area Scalable Earth grid*) (AL-YAARI et al., 2014).

No entanto, o SMOS gera outros produtos que são reprocessados para filtrar picos máximos e mínimos nos dados fornecidos pelo CATDS, que nem

sempre correspondem com a realidade. A exemplo, tem-se o SMOS-BEC, produzido pelo *Barcelona Expert Center* (SOUZA et al., 2018) e o SMOS-IC (SMOS-INRA-CESBIO), uma versão alternativa do SMOSL3 desenvolvida pelo INRA (*Institut National de la Recherche Agronomique*) e CESBIO (*Centre d'Etudes Spatiales de la Biosphère*).

O SMOS-IC diferencia-se do SMOSL3 e SMOS-BEC por possuir um algoritmo mais simples, sendo o mais independente possível de dados auxiliares, considerando os pixels como homogêneos, além de possuir melhorias nos parâmetros de rugosidade do solo e relacionados à vegetação (NICLOS et al., 2016). Fernandez-Moran et al. (2017), comparando os produtos SMOSL3 e SMOS-IC entre os anos de 2010 a 2015 em escala global, constataram que o segundo possui melhorias acentuadas no coeficiente de correlação, bem como menores erros de estimativa, tanto para a umidade do solo quanto para a profundidade óptica da vegetação. No entanto, por apresentar filtros mais 'severos' para a remoção de picos nas leituras dos MIRAS, a resolução temporal do SMOS-IC não é regular como nos produtos anteriores. Em alguns casos, é comum passar mais de 3 dias sem nenhum registro, o que reduz o número de observações ao longo do mês e ano.

O princípio do algoritmo da versão L3 (v300) do SMOS é similar ao da versão L2, em que observações multiangulares são usadas para obter, simultaneamente, a umidade do solo (quantificada diretamente em $m^3 m^{-3}$) e a profundidade óptica da vegetação no nadir (τ -NAD), que está relacionada à biomassa (AL-YAARI et al., 2014; NICLOS et al., 2016).

Devido ao fato de o sensor MIRAS trabalhar na banda L, possui algumas vantagens sobre outros sensores orbitais de umidade do solo. Isso ocorre porque os demais sensores trabalham com altas frequências de microondas, que são mais susceptíveis à presença de nuvens, densidade de dossel vegetal e topografia da superfície. Ao contrário deles, o MIRAS está menos propenso a ruídos relacionados ao conteúdo de água na atmosfera, já que as nuvens têm efeito relativamente insignificante na banda L (ANAM et al., 2017).

1.4.5 Soil Moisture Active Passive (SMAP)

O SMAP, resultado de esforços da NASA para ingressar e sair à frente no que diz respeito ao monitoramento de umidade do solo em escala global, foi lançado em 2015 com uma grande novidade: carregava um sensor ativo (radar) e um passivo (radiômetro), ambos operando na banda L, assim como o MIRAS, do SMOS. O SMAP veio com a proposta de levar as estimativas de umidade do solo a outro patamar. O radar possuía resolução espacial de 3 km, o radiômetro de 36 km e, a fusão dos dois sensores, resultava em produtos com resolução de 9 km (ZHANG et al., 2017). Infelizmente, devido a problemas de hardware, o radar parou de funcionar ainda em 2015 (CHEN et al., 2017), de modo que o SMAP, atualmente, conta apenas com o radiômetro. A resolução temporal é de 1-3 dias.

O radiômetro, sensor atual do SMAP, detecta as diferenças mínimas nos sinais de microondas causados pela presença de umidade na superfície do solo. Em geral, uma superfície seca (como areia do deserto) emite quantidades maiores de radiação de microondas, enquanto superfícies úmidas emitem quantidades muito baixas de radiação (VELPURI, SENAY e MORISETTE, 2015). Os produtos são fornecidos no formato HDF com grid EASE2 (*Equal Area Scalable Earth-2*), no entanto, existe possibilidade de conversão para diferentes formatos, como NetCDF e GeoTIFF (<https://smap.jpl.nasa.gov/data/>). Atualmente, os produtos do SMAP estão nas versões 3 e 4 (Level 3-4). O produto adequado vai depender das necessidades, já que contam com resolução espacial e parâmetros.

Sensores que operam na faixa de microondas, mais especificamente na banda L, são bastante vulneráveis à interferência de rádio frequência (RFI), que podem comprometer seriamente a qualidade dos dados registrados. Esse problema é ainda mais agravante em áreas densamente urbanas e tecnológicas, como nos grandes centros da China. No entanto, como existem esforços sucessivos para mitigar os impactos de RFI, o SMAP acaba sendo menos afetado que o MIRAS (SMOS), por ser um produto mais recente (BAI et al., 2018a; HAJJ et al., 2018). Isso é evidente, já que o SMOS, especialmente nas versões operacional e reprocessada fornecidas pelo CATDS, tendem a

apresentar picos bastante elevados de umidade do solo (AL-YAARI et al., 2014; JACKSON et al., 2015).

1.5 VALIDAÇÃO DE DADOS ORBITAIS

A validação de dados orbitais é um grande desafio por duas razões principais: primeiro porque dados de precipitação e umidade do solo são muito variáveis no espaço-tempo, tornando muito difícil combinar as medições de satélite (espaciais) com dados de referência em superfície (pontuais); segundo porque não há um conjunto de dados de referência que represente exatamente a mesma quantidade física medida pelo satélite (WAGNER et al., 2013; WANG et al., 2018). A título de exemplo, satélites de umidade do solo normalmente estimam o conteúdo de água até 5 cm (camada bastante superficial), já as redes de monitoramento *in situ*, que não são montadas especificamente para a validação, são representativas de profundidades de 10 cm (0, 10, 20, ..., N cm). Nesse caso, a menor profundidade média amostrada (0 a 10 cm) já é motivo de incertezas nas validações, visto que o satélite monitora a umidade do solo em condições diferentes (SOUZA et al., 2018). O mesmo é válido para dados de precipitação, já que postos pluviométricos em superfície são representativos de apenas uma pequena área circundante, ao passo que satélites, como o TRMM, determinam a precipitação como sendo igual para uma região de ~729 km², correspondente à área fixa do pixel (REIS, RENNÓ e LOPES, 2017).

Apesar dessas limitações, são grandes os esforços para a validação de dados de sensoriamento remoto em diferentes escalas espaciais e temporais ao longo do globo, sendo a maior parte deles bem-sucedidos. Rahmani et al. (2016) utilizaram dados do SMOS para realizar comparações com informações obtidas por estações em campo, em todo o Irã, avaliando geograficamente o país com base em diferentes sub-regiões. Da forma similar, Anam et al. (2017) utilizaram dois sensores (AMSR-E e SMOS) para realizar as suas validações em todo o território do Paquistão. Nos dois casos, foram observados bons resultados, notando-se a mesma tendência entre dados de campo e de satélite. Em Pernambuco, Souza et al. (2018) utilizaram dados do SMOS-BEC (versão alternativa do SMOSL3) para validação com base em uma extensa rede de monitoramento em superfície. Os resultados foram encorajadores e confirmam a eficiência do produto.

Em escala global, Al-Yaari et al. (2014) validaram a precisão dos sensores ASCAT e SMOS, levando em conta também anomalias de umidade do solo para intervalos mensais, visando identificar padrões sazonais de variação. Já Rebel et al. (2012) fizeram estudo similar com o AMSR-E, porém considerando modelagem global da umidade do solo nas comparações, além de dados de campo.

Em se tratando de dados de precipitação, no Brasil existe uma grande quantidade de estudos. Na Paraíba, Soares et al. (2016) validaram dados do TRMM com base em 212 postos pluviométricos, alertando que o satélite tende a apresentar melhor desempenho conforme a escala temporal é aumentada (acumulados semanais ou mensais). Em Pernambuco, Anjos et al. (2017) compararam dados do TRMM com dados de superfície, utilizando uma técnica geoestatística conhecida como *krigagem* para interpolar os dados dos postos e, em seguida, comparar com os dados também interpolados a partir dos pixels do TRMM. Os autores encontraram bons resultados para as estimativas do satélite. De forma similar, Silva Lelis et al. (2018) também compararam dados do TRMM e GPM com dados de referência interpolados por meio de *krigagem*, no Estado de São Paulo, indicando boa precisão dos dois satélites e grande similaridade entre eles, já que as mesmas técnicas de correção de bias são aplicadas aos produtos.

É importante ressaltar que não apenas em larga escala (ex.: estado, país, continente, globo) os dados obtidos de sensores remotos de microondas podem ser utilizados. Mesmo em bacias hidrográficas essas informações são úteis. No entanto, devido à limitada escala espacial, é necessária uma rede de monitoramento com dados bastante consistentes. Brocca et al. (2013) conseguiram comprovar a eficiência de um sensor de umidade do solo em uma bacia da Itália com apenas quatro estações em solo para validação. Em escala ainda mais reduzida, Niclos et al. (2016) usaram dados obtidos do SMOS para validação em uma área agrícola da Argentina, evidenciando a grande aplicabilidade do sensor em áreas menores.

1.6 NORDESTE BRASILEIRO E O IMPACTO DAS SECAS

As secas representam um fenômeno natural caracterizado por alterações no regime pluviométrico. No Nordeste Brasileiro (NEB), elas afetam

a população, principalmente aquela mais vulnerável, localizada na região semiárida. As secas constituem um fenômeno grave que coloca em risco a segurança alimentar, energética e hídrica da região (MARENGO et al., 2018a).

Souza e Paz (2016) enfatizam que a população que habita a região Nordeste, mais precisamente o semiárido, sofre bastante pela escassez hídrica e pela gestão inadequada dos recursos hídricos. Aliado a isso, há também os longos períodos de estiagem, que dificultam o desenvolvimento das atividades agropecuárias.

De fato, as secas constituem um problema histórico no NEB. Episódios de seca são reportados desde o século XVI. Em 2016, houve uma atualização da lista de eventos de seca, que apontam os seguintes períodos como sendo marcados por precipitação pluviométrica abaixo da média histórica, trazendo períodos de seca ao NEB: 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 (MARENGO et al., 2018b).

No ano de 2012, o NEB passou pela seca mais severa dos últimos 30 anos. Essa seca se estendeu com grande severidade até 2015, mas permaneceu nos anos de 2016 e 2017. A situação foi ainda mais crítica no Estado da Bahia, onde aproximadamente 230 municípios foram afetados. Municípios dos Estados de Alagoas e Piauí também foram severamente afetados pela ausência de chuvas. A seca trouxe muitos prejuízos às principais fontes de renda da região: pecuária e cultivo de milho e feijão (ROSSATO et al., 2017).

Marengo et al. (2018a) afirmam que a seca desse período atingiu quase nove milhões de pessoas e que, nesse período, algumas políticas foram impulsionadas para mitigar os problemas da seca, como a concessão de linhas de crédito aos pequenos agricultores e a distribuição de água por meio de carros pipa, o que fez diminuir os impactos. No entanto, as políticas de gestão

hídrica podem ter sido insuficientes para suportar a seca excepcional registrada em 2012-2015.

Em virtude das mudanças climáticas, existe uma grande perspectiva de aumento do déficit hídrico sobre o NEB aliado a maior aumento de temperatura nos últimos anos. Isso coloca em evidência o fenômeno das secas e gera preocupação em diversos setores, desde social, agrícola, hídrico e econômico até o setor ambiental, já que eventos de seca recorrentes, se não corretamente monitorados e mitigados, podem trazer sérios impactos ambientais, ocasionando a degradação de ecossistemas.

1.7 MUDANÇAS CLIMÁTICAS

Segundo o Painel Intergovernamental de Mudanças Climáticas (IPCC, 2001), o termo *mudança climática* é usado para designar “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”.

Como o aquecimento global deverá se intensificar no século 21, novos desastres hidroclimáticos como a escassez de água na forma de secas, devem ser antecipados. Já que os impactos das mudanças climáticas não apenas reduzirão os recursos hídricos disponíveis, mas também aumentarão as demandas de água por parte das culturas, produzindo impactos negativos na produção agrícola, o primeiro passo inevitável para preparar as sociedades afetadas para essa escassez de água e para avaliar esses impactos adversos dos recursos hídricos é a identificação das variações climáticas, seguida de uma previsão das condições hidroclimáticas para o futuro (EMAMI e KOCH, 2019).

O 5º relatório do IPCC aponta que a mudança do clima impõe uma grande ameaça ao desenvolvimento sustentável, já que afeta direta ou indiretamente a sociedade por interferir em diversos setores. Além disso, o IPCC aponta impactos de grandes proporções sobre a América do Sul, especialmente nos recursos hídricos e setores correlatos que dependem da água (DUARTE et al., 2018).

De acordo com Miranda et al. (2018), o Brasil é um dos principais emissores de gases do efeito estufa (GEE), principalmente em decorrência de atividades agropecuárias. Essa situação desafia o setor a produzir para alimentar uma população cada vez mais crescente, ao mesmo tempo em que o obriga à adoção de novas práticas para reduzir as emissões. Esta situação exige a proposição de novas práticas agrícolas e o conhecimento de que as ações humanas desencadeiam alterações no clima e no ambiente.

No NEB, o bioma Caatinga é o mais vulnerável às mudanças climáticas, pois o aumento da temperatura, associado às atividades antrópicas de remoção da vegetação natural de caatinga, poderão levar a processos de desertificação e aridização (GUIMARÃES et al., 2016). Marengo (2009), estudando as tendências de mudanças de clima utilizando diferentes modelos propostos pelo IPCC, identificaram tendência de aquecimento em todo o Brasil. No NEB, foi identificada probabilidade de redução das chuvas, possivelmente associada ao aquecimento global.

Avaliando o impacto das mudanças climáticas especificamente no NEB, Guimarães et al. (2016) concluíram que as projeções são de aumento de temperatura em todos os aspectos, e mais acentuado no cenário de maior emissão de GEEs, com a evapotranspiração de referência (ET_o) tendo projeções no mesmo sentido da temperatura. Além disso, a combinação das projeções de aumento de ET_o e diminuição da precipitação resultaram em valores de índice de aridez futuro menor para a maioria dos modelos analisados pelo autor, com um dos modelos promovendo projeção de aumento na extensão da zona árida do NEB em +3.480% no cenário mais extremo, com altas emissões de GEEs. Obviamente, os modelos do IPCC estão sujeitos a viés nas suas projeções, por isso, normalmente, são trabalhados em conjunto para a obtenção de uma média representativa, mas esse resultado não deixa de ser alarmante.

1.8 UMIDADE DO SOLO E PRECIPITAÇÃO APLICADOS AO MONITORAMENTO DE SECAS

De acordo com Farias et al. (2014), as secas geralmente são classificadas em quatro categorias: a) *Seca meteorológica*, definida como um déficit de precipitação pluvial sobre uma região durante um período de tempo;

b) *Seca agrícola*, que refere-se à baixa disponibilidade de água no solo, que torna o suprimento insuficiente às culturas para repor as perdas por evapotranspiração; c) *Seca hidrológica*, que está relacionada com uma deficiência no volume de água disponível, incluindo lençol freático, reservatórios e rios; c) *Seca socioeconômica*, associada à insuficiência de sistemas de recursos hídricos para atender às demandas de água, associando, assim, secas com a oferta e a procura de um bem econômico. Ocorre quando a demanda por um bem é superior à oferta.

Existem diversos índices utilizados para avaliar os efeitos da seca, incluindo sua duração, intensidade e gravidade. Os dados de entrada também são vários e dependem do tipo de seca e do índice que será utilizado. Podem ser utilizados, por exemplo, dados de precipitação para análise da seca meteorológica, vazão para seca hidrológica, umidade do solo, precipitação e temperatura para seca agrícola.

Nesse contexto, a umidade do solo é uma 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.

Devido ao tempo de operação dos sensores, esses índices são obtidos para curto prazo, ao contrário dos índices baseados na precipitação, que utilizam longas séries históricas. No entanto, para modelar a seca a partir da umidade do solo, há a necessidade de possuir uma boa rede de monitoramento em campo, com dados de anos antecedentes para validar os resultados obtidos pelos sensores remotos.

Considerando que há grandes limitações ao monitoramento da umidade do solo, uma alternativa bastante viável é utilizar dados de séries históricas de precipitação para modelar índices de seca, levando em conta a estreita relação entre as duas variáveis. Um dos indicadores mais utilizados atualmente é o

SPI, proposto por Mckee et al. (1993), que permite quantificar, padronizar e comparar a seca meteorológica, em base espacial e temporal.

O monitoramento probabilístico da variabilidade temporal dos totais de chuva, proposto pelo modelo do SPI, tem sido amplamente utilizado por programas estaduais e federais na detecção de regiões com déficits severos de precipitação pluvial. Isso favorece a rápida adoção de políticas de combate aos efeitos desse fenômeno meteorológico (BLAIN, 2011). Em regiões áridas e semiáridas, esse monitoramento é ainda mais importante, principalmente em condições similares às de Pernambuco, em que há grande variação nos índices pluviométricos dentro dos limites geográficos do próprio Estado.

Estudos de SPI em grandes áreas normalmente utilizam um número definido de postos pluviométricos e, por meio de métodos de interpolação, mapeiam o índice para a região de interesse. Trabalhos mais recentes têm demonstrado que essa técnica pode, até certo ponto, comprometer os resultados, dada a grande variabilidade da precipitação, falhas nos postos de coleta e, em muitos casos, falta de homogeneidade na obtenção das informações. Com base nessas observações, alternativas com o uso de satélites vêm sendo desenvolvidas, especialmente o TRMM, da NASA, que estima os índices de chuva em escala global desde 1998, com resolução de 27 x 27 km (JESUS et al., 2016; LI, ZHANG e YE, 2013).

Os dados do TRMM estarão disponíveis até meados de 2019, quando a missão será permanentemente descontinuada após baixa na órbita do satélite. No entanto, desde 2014, já está em operação o GPM, que utiliza um sistema avançado formado por radar e radiômetro para estimar a precipitação.

O TRMM tem se mostrado uma ferramenta em potencial para estudos dessa natureza, dada a sua boa precisão para estimar eventos de chuva quando comparado com dados mensurados em campo (AMEKUDZI et al., 2016; XU et al., 2017). Conseqüentemente, resultados com o SPI também são consistentes e indicados, principalmente pela regularidade de passagem do satélite e maior quantidade de dados quando comparado aos pontos em terra, na maioria dos casos (AUGUSTO et al., 2017).

São diversas as aplicações do TRMM para modelagem da seca por meio do índice SPI, em variadas escalas espaciais. Jesus et al. (2016), por exemplo, utilizaram dados para o período de 1998 a 2014 para modelar o SPI em todo o México, realizando a validação com base em três estações de referência, em diferentes regiões do país. No Brasil, Augusto et al. (2017) calcularam o SPI entre os anos de 1998 e 2013 em uma porção da Bacia do Rio São Francisco, encontrando bons resultados e confirmando a vantagem deste índice em relação a outros que utilizam mais dados de entrada. No entanto, os autores não validaram os dados do satélite com base em estações em campo, o que pode levar a incertezas nas informações obtidas.

Apesar da grande aplicabilidade do TRMM e demais produtos de umidade do solo, há uma limitação prática: normalmente são utilizadas as séries de dados para calcular os índices de seca, sem considerar características adicionais de solo, por exemplo, que podem dar indícios reais acerca da disponibilidade de água para o suprimento vegetal. 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., 2018a; MARTÍNEZ-FERNÁNDEZ et al., 2016), gerando informações mais consistentes, especialmente do ponto de vista agrícola.

1.9 MODELAGEM HIDROLÓGICA

Um modelo pode ser definido como uma representação simplificada de um sistema do mundo real. O melhor modelo é aquele que dá resultados próximos da realidade com o uso de poucos parâmetros e menor complexidade. Os modelos são usados principalmente para prever o comportamento do sistema e entender vários processos hidrológicos, sendo constituídos de vários parâmetros que definem as suas características. De modo geral, dois dados de entrada importantes são necessários para todos os modelos: precipitação e área de drenagem. Juntamente com estas características, dados de solo, cobertura vegetal, topografia de bacias hidrográficas, umidade do solo, características do aquífero de água subterrânea também podem ser considerados (GANASRI, 2015).

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. 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 (VIANA et al., 2018).

Para a avaliação dos recursos hídricos em bacias hidrográficas, existem diversos modelos. No Brasil e na América do Sul, um dos destaques é o modelo MGB-IPH, que é distribuído e foi concebido para simular processos hidrológicos em grandes bacias, descrevendo a dinâmica espacial dos processos, daí a classificação do modelo como 'distribuído'. O MGB-IPH representa vários processos hidrológicos, incluindo a interceptação; o balanço de água no solo; a evapotranspiração; os escoamentos superficiais, subsuperficiais e subterrâneos nas microbacias e o escoamento na rede de drenagem (BAYER e COLLISCHONN, 2016; SOUZA e PAZ, 2016).

No Nordeste Brasileiro, um grande esforço tem sido desenvolvido nos últimos anos no sentido de descrever os processos hidrológicos em bacias hidrográficas da região como suporte ao gerenciamento de recursos hídricos, especialmente no Estado de Pernambuco. Conhecido como Sistema de Unidades de resposta hidrológica para Pernambuco (SUPer, <https://super.swat.tamu.edu/>), o projeto utiliza como base o modelo *Soil and Water Assessment Tool* (SWAT), desenvolvido na Texas A&M University.

O SWAT 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, incluindo o ArcGIS e QGIS. No entanto, o SWAT foi desenvolvido para representar de forma simplificada o movimento da água, sedimentos e nutrientes em um sistema natural, por isso deve ser sempre calibrado com dados observados. No geral, o modelo apresenta bons

resultados após a realização desse processo (ANDRADE et al., 2017a; ANDRADE et al., 2017b; MARONEZE et al., 2014).

Em outras regiões do mundo, existe grande diversidade de modelos que, muitas vezes, são adaptados às condições locais. Na Itália, o modelo também distribuído *Flash-flood Event-based Spatially distributed rainfall-runoff Transformation–Energy Water Balance* (FEST-EWB), baseado no sistema de balanço de energia e água em função da temperatura da superfície da terra, é bastante utilizado para caracterizar todos os processos e variáveis envolvidos nos ciclos da água e energia, incluindo dados relevantes para monitoramento de inundações e neve, que são comuns no país (CORBARI et al., 2011). Apesar da grande quantidade de dados de entrada necessários para executar o modelo, como mapas de propriedades físicas e hidráulicas de solo, índice de área foliar, resistência estomática, curva-número, modelo digital de elevação e albedo, o modelo apresenta bons resultados e a calibração utiliza como referência apenas dados espaciais de temperatura de superfície do solo. Normalmente, opta-se por dados do MODIS, da NASA (CORBARI e MANCINI, 2014).

Os modelos hidrológicos, especialmente os distribuídos, assemelham-se aos dados de sensoriamento remoto no sentido de suprir a deficiência ou inconsistência de dados mensurados *in situ*, especialmente em regiões com escassez de redes de monitoramento, como é o caso do Nordeste Brasileiro. Obviamente, nos dois casos, um tratamento especial dos dados é necessário, com foco na calibração e validação, visto que se trata de dados estimados que, dependendo das condições, podem não representar adequadamente a realidade.

CAPÍTULO II

**VALIDAÇÃO E USO DE DADOS DE PRECIPITAÇÃO DO TRMM 3B42
PARA MONITORAMENTO DA SECA NO ESTADO DE PERNAMBUCO**

Validação e uso de dados de precipitação do TRMM 3B42 para monitoramento da seca no Estado de Pernambuco

RESUMO: em 2012, o Nordeste Brasileiro enfrentou a seca mais severa das últimas décadas, que afetou diversos setores produtivos e, conseqüentemente, a sociedade, alertando aos órgãos ambientais e governamentais sobre a necessidade de monitorar esse tipo de evento com o intuito de mitigar os impactos decorrentes de sua persistência. Esse estudo teve como objetivo verificar a aplicabilidade de dados de precipitação estimados pelo satélite *Tropical Rainfall Measuring Mission* (TRMM) na estimativa da seca em Pernambuco, entre os anos de 1998 e 2017, com base no Índice de Precipitação Padronizada (SPI), que possui simples aplicação e considera apenas dados de precipitação, que é a principal variável hidrológica reguladora da seca. Antes do uso, os dados do TRMM foram validados no Estado utilizando oito estações do INMET. Os resultados indicaram que o TRMM possui bom desempenho na estimativa da precipitação em Pernambuco, com coeficientes de correlação (CC) superiores a 0,86 em escala mensal e 0,80 em escala anual. Os altos valores de CC levaram a bons resultados na estimativa da seca com o SPI, já que o índice é padronizado. O SPI, nas diferentes escalas temporais adotadas, indicou os momentos e pontos críticos em que a seca foi mais severa. Entre 2012 e 2013, mais de 80% do Estado esteve em condições de seca extrema, mesmo em parte da Zona da Mata e do Litoral. Quando comparadas com as anomalias do índice de vegetação NDVI, calculadas anualmente, as anomalias de precipitação do TRMM na mesma escala temporal apresentaram grande similaridade, indicando que a alteração no vigor vegetal respondeu de forma coerente às alterações da precipitação registradas pelo satélite. Os resultados indicam o potencial do uso de dados de sensoriamento remoto para monitoramento ambiental no Estado de Pernambuco e alertam à necessidade de monitoramento contínuo, com o intuito de assegurar melhor gestão dos recursos hídricos frente a eventos de seca e possibilitar a mitigação de impactos decorrentes de sua persistência, auxiliando na adoção de técnicas de convivência produtiva com as secas.

Palavras-chave: recursos hídricos, gestão, semiárido, validação, SPI.

Validation and use of TRMM 3B42 precipitation data for drought monitoring in Pernambuco State, Brazil

ABSTRACT: in 2012, the Brazilian Northeast faced the most severe drought of recent decades, which affected several productive sectors and, consequently, the society, alerting the environmental and governmental agencies about the need to monitor this type of event in order to mitigate the impacts resulting of your persistence. This study aimed to verify the applicability of precipitation data estimated by Tropical Rainfall Measuring Mission (TRMM) satellite to estimate drought in Pernambuco between 1998 and 2017, based on the Standardized Precipitation Index (SPI), which has simple application and considers only precipitation data, which is the main hydrological variable regulating drought. Firstly, TRMM data were validated in the state using eight INMET stations. The results indicated that TRMM has good performance in estimating precipitation in Pernambuco, with correlation coefficients (CC) greater than 0.86 on a monthly scale and 0.80 on an annual scale. The high CC values allowed good results in drought estimation with SPI, since the index is standardized. The SPI, in the different time scales adopted, indicated the moments and critical points in which the drought was more severe. Between 2012 and 2013, over 80% of the State was in extreme drought conditions, even in part of the Zona da Mata and Litoral. When compared with NDVI vegetation index anomalies, calculated annually, the TRMM precipitation anomalies on the same time scale showed great similarity, indicating that the change in plant vigor responded coherently to the rainfall changes recorded by the satellite. The results indicate the potential of using remote sensing data for environmental monitoring in the State of Pernambuco and warn of the need for continuous monitoring in order to ensure better management of water resources in the presence of drought events, allowing impact mitigation and helping in the adoption of productive coexistence techniques with droughts.

Keywords: water resources, management, semiarid, validation, SPI.

1 INTRODUÇÃO

O Brasil é bastante vulnerável às mudanças climáticas, especialmente em áreas que compreendem a Amazônia e o Nordeste Brasileiro (NEB). Enquanto na primeira região os eventos extremos de chuva ocasionam inundações, na segunda, eventos extremos de seca causam impactos em diversos setores (elétrico, econômico, abastecimento), atingindo diretamente a sociedade (MARENGO, TORRES e ALVES, 2017; RODRIGO et al., 2017).

Diversos estudos enfatizam que a precipitação é o fator primário no controle da formação e persistência de eventos de seca (DAMBERG e AGHAKOUCHAK, 2014). Nesse sentido, a correta detecção da intensidade e frequência das chuvas é essencial para entender o fenômeno de forma mais precisa, espacialmente e temporalmente (TAO et al., 2016). Essa é uma preocupação ainda mais crescente nos últimos anos em virtude das mudanças climáticas.

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 (WANG et al., 2017), 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). Além disso, constantes falhas e perda de dados em postos pluviométricos comprometem a confiabilidade dos dados para utilização em diversas aplicações (LU et al., 2016).

Em um esforço global, diversos satélites e produtos foram lançados, nas últimas décadas, com o intuito de monitorar atributos climáticos, incluindo a precipitação. Dentre eles, destacam-se o *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks* (PERSIANN) (Nguyen et al., 2018); o Climate Prediction Center (CPC) *morphing technique* (CMORPH) (Xie et al., 2017); o *Climate Hazard Group InfraRed Precipitation Satellite* (CHIRPS) (BAI et al., 2018b); o *Tropical Rainfall Measuring Mission* (TRMM) *Multi-satellite Precipitation Analysis* (TMPA) (ANJOS et al., 2017) e o

Integrated Multi-Satellite Retrievals (IMERG), da missão *Global Precipitation Measurement (GPM)* (Chen et al., 2018).

Os TRMM, lançado pela NASA, fornece dados desde 1998 com resolução espacial de $0,25^\circ$ (~27 km) e temporal de 3 horas. Dessa forma, representa uma boa opção para aplicação em estudos de seca, já que detecta eventos de chuva com intervalo temporal bastante reduzido (LI, ZHANG e YE, 2013; TAN et al., 2017). Diversas aplicações utilizando o Índice de Precipitação Padronizada (SPI) já foram realizados ao longo do globo, evidenciando o grande potencial do TRMM quando comparado a postos em superfície (JESUS et al., 2016; TAO et al., 2016). No entanto, por representar algumas limitações na resolução espacial, criteriosa validação dos seus dados é necessária para identificar se os padrões de precipitação estimados pelos sensores correspondem ao volume precipitado em superfície. Somente após isso pode-se assegurar a correta aplicação da sua série para a modelagem da seca.

Considerando a importância dos dados de precipitação para o monitoramento de eventos extremos de seca em regiões semiáridas, o objetivo desse estudo foi avaliar o potencial do satélite TRMM, da NASA, na detecção do fenômeno de secas no Estado de Pernambuco.

2 MATERIAL E MÉTODOS

2.1 Área de estudo

O estudo foi desenvolvido no Estado de Pernambuco, localizado na região Nordeste do Brasil e ocupando uma área de aproximadamente 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.

De acordo com Possas et al. (2012), os menores índices pluviométricos ocorrem nas mesorregiões do Sertão Pernambucano e São Francisco, com médias anuais variando de 400 a 800 mm, principalmente no São Francisco, onde as chuvas são ainda mais escassas. A região Agreste já possui um incremento na média, de 600 a 1000 mm, ao passo que na Zona da Mata e RMR, os valores variam de 1000 a 2265 mm.

Silva et al. (2010) enfatizam ainda que, no que concerne ao regime pluvial, o Estado de Pernambuco possui ao menos três mesorregiões distintas: Sertão, Agreste e Zona da Mata/Litoral. No Sertão, as chuvas concentram-se de janeiro a abril; o Agreste está em zona intermediária de transição entre os climas úmidos e secos, tendo o período chuvoso principal de fevereiro a junho (setor ocidental) e março a julho (setor oriental). Já a Zona da Mata/Litoral apresenta regime chuvoso mais longo, de seis meses (março a agosto).

O relevo do Estado de Pernambuco é variável. O setor leste, localizado no litoral, é caracterizado por baixas altitudes, próximas de zero. No entanto, esses valores aumentam em direção ao setor oeste, especialmente nas mesorregiões do Agreste e Sertão Pernambucano, com picos que chegam a até 1200 m (Figura 3). Apesar das menores altitudes no litoral, as condições climáticas favorecem maiores volumes pluviométricos nessa região, ao contrário do Sertão Pernambucano e parte do Agreste, que se encontram em clima semiárido, mesmo apresentando picos de altitude mais propícios à maior incidência de chuvas.

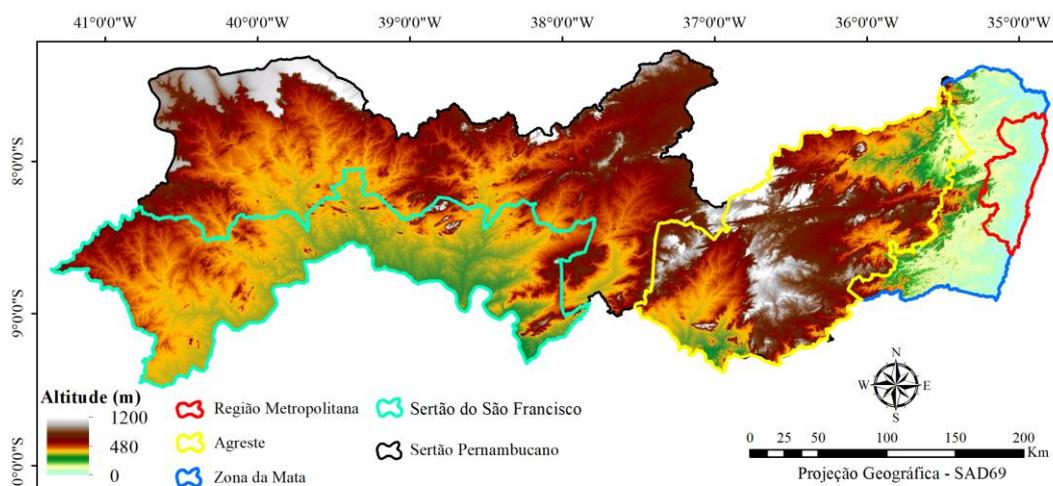


Figura 3. Modelo digital de elevação do Estado de Pernambuco obtido a partir da base SRTM (NASA), com resolução de 30 m. Em destaque as mesorregiões do Estado.

2.2 Base de dados

- **TRMM 3B42V7**: os dados de precipitação utilizados foram obtidos através do Tropical Rainfall Measuring Mission – TRMM, produto 3B42V7 (TRMM 3B42, versão 7), da NASA, com dados acumulados diários (<https://pmm.nasa.gov/data-access/downloads/trmm>). O TRMM possui

resolução espacial de $0,25^\circ \times 0,25^\circ$ ($\sim 27 \times \sim 27$ km), totalizando 234 pontos na grade que cobre o estado (Figura 4). Cada ponto corresponde a um 'pluviômetro' virtual que fornece dados acumulados de precipitação em escala temporal diária ou a cada três horas (JESUS et al., 2016). Os dados do TRMM 3B42V7 são calibrados globalmente com o auxílio de dados observados de precipitação, a cada mês. No entanto, devido às variações de escala nas aplicações realizadas com esse satélite, existe a necessidade de realizar a validação dos seus dados para condições específicas, como é o caso do Estado de Pernambuco.

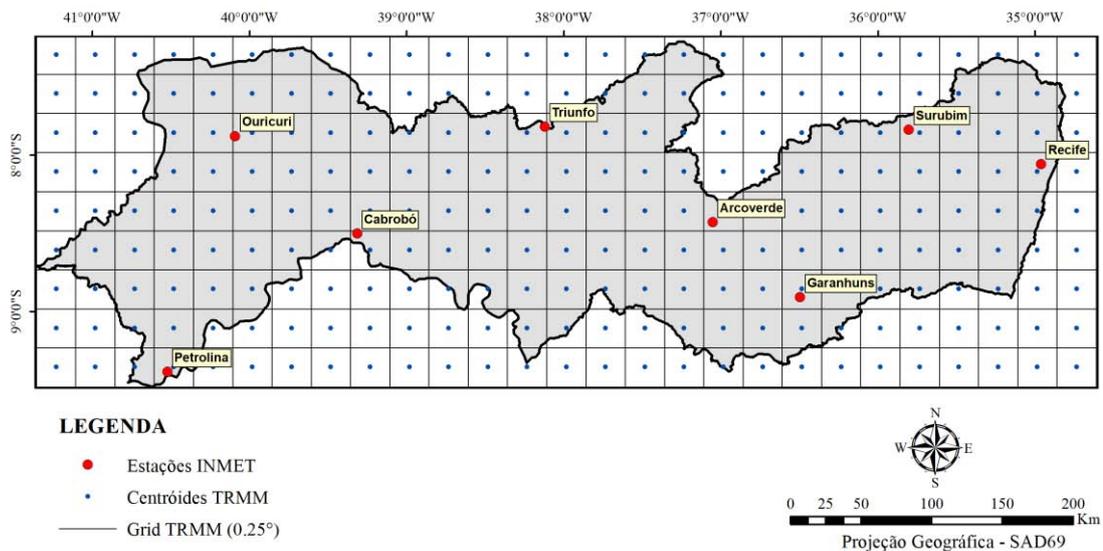


Figura 4. Disposição da grade do produto TRMM 3B42V7 no Estado de Pernambuco, com destaque para a localização das estações INMET dentro de cada pixel.

Para cada ponto da grade do TRMM, está associado um valor 'z' correspondente à precipitação para um dia específico, referente a uma área de 729 km^2 ($\sim 27 \text{ km} \times \sim 27 \text{ km}$). Esse valor é único para todo o ponto, obtido a partir do valor médio para aquela área. Sabe-se que a precipitação varia bastante espacialmente em virtude de vários fatores. No entanto, esta será a resolução utilizada no estudo por ser a fornecida pelo TRMM em escala global e, principalmente, devido à sua boa aplicação em vários estudos, com bons resultados.

A Figura 5 representa um pixel (ponto) do TRMM em uma condição ideal de estimativa da precipitação. À esquerda, cinco estações distribuídas ao longo do pixel, evidenciando a tendência da precipitação de reduzir na parte inferior. Essa redução pode ser causada, por exemplo, por uma variação topográfica. À

direita, o pixel com o centroide do TRMM, onde o valor de precipitação é fornecido. Neste caso evidenciando o valor da média aritmética das cinco estações.

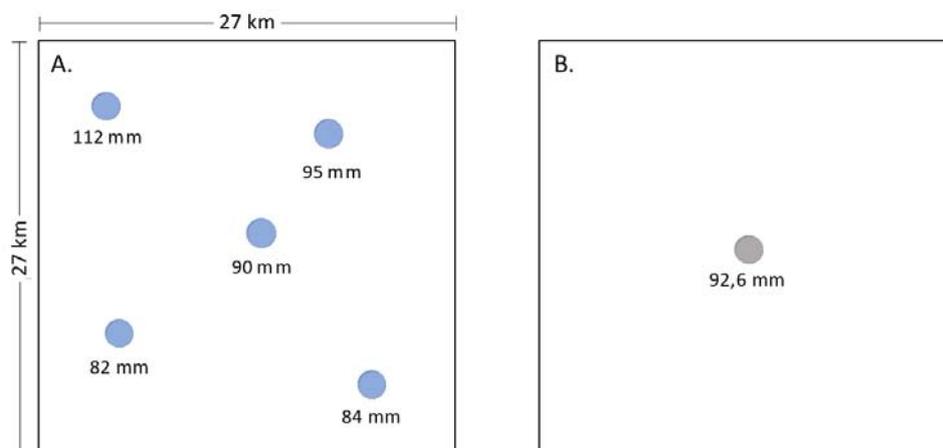


Figura 5. Representação de um pixel hipotético do TRMM 3B42V7 com valores acumulados diários de precipitação em cinco estações (A) e valor médio estimado pelo satélite (B) em uma condição ideal (valor estimado igual a média aritmética das estações).

Com os dados diários do TRMM, foram calculadas médias mensais de precipitação e a sua distribuição será obtida por interpolação espacial, utilizando o método do Inverso do Quadrado da Distância (IQD). O período para avaliação do índice de seca foi de janeiro de 1998 a dezembro de 2017, totalizando 19 anos. Conforme Jesus et al. (2016) e Augusto et al. (2017), é um intervalo de tempo suficiente para este tipo de estudo, levando em conta que o TRMM iniciou a coleta de dados em 1998.

- **In situ**: para a validação do produto de precipitação e seca do TRMM, foram utilizadas oito estações do Instituto Nacional de Meteorologia (INMET), para o mesmo período (janeiro de 1998 a dezembro de 2017).

A escolha da localização das estações foi influenciada pelas diferentes condições pluviométricas do estado, visando validar o TRMM em variadas situações. Já a quantidade baseou-se de literatura recente. Augusto et al. (2017) avaliaram o Índice de Precipitação Padronizada (SPI) em uma parte da bacia do São Francisco, porém sem validação dos dados do TRMM. Já Jesus et al. (2016), que fizeram estudo similar em todo o México, utilizaram apenas três estações de referência para validação.

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 TRMM. Esse também é o intervalo de agregação temporal utilizado para cálculo do índice de seca.

2.3 Validação dos dados do TRMM 3B42V7

Antes da utilização do produto de precipitação do TRMM, os seus dados foram validados em dois aspectos: tanto para a precipitação quanto para o índice de seca. A validação é importante para garantir a confiabilidade dos dados mensurados pelo satélite, especialmente os dados sazonais, que são muito importantes para modelagem da seca. 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 TRMM e comparar diretamente com o posto pluviométrico correspondente, inserido dentro da 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 TRMM 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 o TRMM mais consistentes e precisas, dias com falhas nas estações também foram removidos da série do TRMM utilizadas para validação.

A remoção de dias com falhas obedeceu a alguns critérios: (1) para cada dia com falha, nos 20 anos, 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 TRMM. No entanto, se (2) não houve registro de precipitação nesse período e chuvas também não foram detectadas pelo TRMM, 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 dentro da janela deslizante de 15 dias, (3) a falha foi removida da série do INMET e igualmente retirada da série do TRMM, mesmo que o segundo indicasse precipitação igual a zero.

Como cada mesorregião do Estado possui condições climáticas muito semelhantes e a série utilizada nesse estudo foi longa (aproximadamente 20 anos), não houve a necessidade de utilizar uma rede muito densa para validação.

2.4 Índices estatísticos

Para avaliação da precisão do produto TRMM 3B42V7 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:

- *Coeficiente de correlação de Pearson (CC)*: avalia o grau de concordância entre o TRMM e os postos pluviométricos (Eq. 1), variando de -1 a 1. Valores positivos de CC indicam correlação positiva, enquanto valores negativos indicam correlação negativa.

$$CC = \frac{1}{N} \sum_{n=1}^N (\text{satélite}_n - \overline{\text{satélite}}) (\text{in situ}_n - \overline{\text{in situ}}) \quad 1$$

$$\sigma_{\text{satélite}} \sigma_{\text{in situ}}$$

- *Raiz do erro quadrático médio (RMSE)*: usado para representar a magnitude média do erro (Eq. 2):

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

- *Bias relativo (RB)*: indica subestimativa ou superestimativa dos dados mensurados pelo TRMM, conforme a magnitude do valor (negativo ou positivo) (Eq. 3):

$$RB = \frac{1}{N} \sum_{n=1}^N (in\ situ_n - sat\acute{e}lite_n) \times 100 \quad 3$$

em todos os casos, considera-se que: $\sigma_{sat\acute{e}lite}$ e $\sigma_{in\ situ}$ s\~ao os desvios-padr\~ao dos dados do TRMM e dos postos pluviom\~etricos, respectivamente. N \~e o total de dados de um determinado posto; $\overline{sat\acute{e}lite}$ e $\overline{in\ situ}$ representam as m\~edias de precipita\~c\~ao para os dados de sat\acute{e}lite e de superf\~icie.

2.5 Din\~amica espa\~co-temporal da precipita\~c\~ao em Pernambuco

Ap\~os a valida\~c\~ao dos dados do TRMM, acumulados mensais para a s\~erie de 20 anos foram utilizados para caracteriza\~c\~ao da din\~amica espacial e temporal da precipita\~c\~ao com o intuito de detectar padr\~oes ao longo das diferentes mesorregi\~oes e em toda a s\~erie do sat\acute{e}lite. A avalia\~c\~ao consistiu apenas da interpola\~c\~ao dos dados de cada pixel, visando permitir melhor visualiza\~c\~ao dos dados, e produ\~c\~ao de mapas com a m\~edia de volume precipita\~c\~ao sazonalmente e anualmente. Al\~em disso, cada pixel foi utilizado para caracterizar os per\~iodos secos e chuvosos na \~area corresponde (0,25\~o).

2.6 Quantidade de dias secos e \~umidos por ano

Com base nos dados de precipita\~c\~ao di\~aria, foram identificadas as quantidades de dias secos e \~umidos anuais, considerando todos os pontos da grade do TRMM (PASSOS, 2015).

Foram considerados como dias secos aqueles em que a precipita\~c\~ao foi abaixo de 1 mm. J\~a para os dias \~umidos, foram levados em conta os dias com precipita\~c\~ao superior a 1 mm. Os mapas finais foram interpolados pelo m\~etodo do inverso do quadrado da dist\~ancia (IQD).

2.7 Índice de Precipitação Padronizada – SPI

O SPI é um índice calculado para períodos de tempo pré-determinados e indica como a precipitação se comportou em relação à climatologia do período em questão. Normalmente são utilizadas faixas de tempo de 1, 3, 6, 9, 12, 24 ou mais meses, dependendo da dimensão da série histórica e dos objetivos do estudo. Valores positivos de SPI indicam precipitação acima da média, enquanto valores negativos são indicativos de precipitação abaixo da média.

Uma das limitações de calcular o SPI para uma grande faixa de tempo é a disponibilidade de dados em campo e a presença de falhas pelo mau funcionamento das estações. Nesse sentido, o TRMM e outros satélites que monitoram diariamente a precipitação em escala global servem como uma grande alternativa e vêm sendo amplamente estudados nos últimos anos (LI, ZHANG e YE, 2013; NAUMANN et al., 2014).

Neste estudo, foram utilizadas escalas de tempo do SPI de 1, 3, 6, 9, 12, 24 e 48 meses, onde foram calculadas médias móveis das séries temporais do SPI centrada nos 12 meses do ano. De acordo com Santos et al. (2013), o SPI correspondente a um curto período (ex.: SPI-1 e SPI-3) 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. Nesse caso, serão considerados 19 anos, que abrangem o início e final da missão do TRMM.

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 que possuem 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 4 (WILKS, 2006):

$$g(x) = \frac{X^{\alpha-1} e^{-\frac{x}{\beta}}}{\beta^{\alpha} \Gamma(\alpha)} \text{ para } X > 0 \quad 4$$

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 5:

$$\alpha = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right) e \hat{\beta} = \frac{\bar{x}}{\alpha} \quad 5$$

em que \bar{x} = precipitação média.

$$A = \ln(\bar{x}) - \frac{\sum \ln(x)}{n}, \text{ em que } n \text{ é o número de observações.} \quad 6$$

Assim, a distribuição cumulativa é transformada em distribuição de probabilidade normal (média igual e 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, conforme equação 7:

$$SPI = Z_i = \frac{(P_i - \bar{P}_i)}{\sigma_i} \quad 7$$

em que i é a escala de tempo (1, 3, 6, 9, 12, 24 ou 48 meses); P_i é a precipitação observada; \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 2).

Tabela 2. 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

Assim como os dados de precipitação obtidos pelo TRMM, o SPI também foi validado com base nos sete postos pluviométricos em superfície. Para a correta estimativa do SPI, a principal hipótese é de que a alta correlação temporal das duas séries seja mais importante do que a correta estimativa do volume precipitado pelo satélite. Desse modo, o satélite pode subestimar ou superestimar a precipitação, no entanto, se ele consegue registrar as tendências de flutuação temporal adequadamente, o SPI será bem modelado, já que se trata de um índice normalizado. A validação focou principalmente nesse aspecto.

2.8 Anomalias de precipitação

Além do SPI em diferentes escalas temporais, anomalias anuais de precipitação foram calculadas para confirmar se o TRMM estima a seca de forma coerente com os relatos presentes na literatura. As anomalias de seca, por serem bastante similares, reforçam os dados obtidos pelo SPI, indicando os anos em que a precipitação acumulada anual foi superior ou inferior à média histórica em todo o Estado.

Por ainda não possuir uma série muito extensa (> 30 anos) que permite caracterizar adequadamente a climatologia de Pernambuco, essa aplicação também tem o intuito de checar se o satélite possui boa sensibilidade na detecção espacial e temporal dos fenômenos de seca.

2.9 Comparação com outras fontes de dados

Além da validação do produto TRMM 3B42V7 utilizando como base referencial os postos pluviométricos, outras fontes de dados espaciais de maior resolução foram utilizadas em uma tentativa de comprovar o grau de precisão da precipitação e anomalias de seca obtidas pelo satélite.

Dados de precipitação do *Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS) foram utilizados para comparação com o TRMM. O CHIRPS possui resolução temporal diária e espacial de ~5 km, contra as resoluções espacial e temporal de ~27 km e 3 horas do TRMM. O CHIRPS, no entanto, não é um sensor orbital, mas um produto resultante da combinação de diversas fontes de dados, incluindo o próprio TRMM e estações *in situ* (SHRESTHA *et al.*, 2017). Os dados do CHIRPS são geridos e fornecidos pelo *Climate Hazards Group* – CHG (<http://chg.geog.ucsb.edu/data/chirps/>).

Para verificar o padrão da seca estimado pelo TRMM de forma mais consistente, o *Normalized Difference Vegetation Index* (NDVI) também foi utilizado. O produto selecionado foi o MOD13C2, do instrumento *Moderate-Resolution Imaging Spectroradiometer* (MODIS – Terra), da NASA, com resolução espacial de ~5 km e temporal de um mês (o produto refere-se a uma composição média mensal do produto de NDVI). Por possuir uma série mais curta, iniciada em 2000, as anomalias de NDVI para os anos de 1998 e 1999 não puderam ser calculadas. Os dados de NDVI foram obtidos através do portal NASA Giovanni, que disponibiliza uma compilação de produtos de todos os sensores orbitais e modelos geridos pela agência (<https://giovanni.gsfc.nasa.gov/giovanni/>).

3 RESULTADOS E DISCUSSÃO

3.1 Comparação da precipitação mensal com base no produto TRMM 3B42V7 e estações pluviométricas para série de 20 anos

Os dados de precipitação diários extraídos do TRMM foram agrupados em acumulados mensais e comparados com aqueles registrados nas estações pluviométricas, na mesma resolução temporal. Em algumas estações, foram filtrados períodos com falhas em dados de precipitação, não havendo validação nesses intervalos específicos.

Os gráficos que representam as falhas dos dados de precipitação, nas oito estações validadas, podem ser observados na Figura 6. Por se tratar de dados de acumulados mensais, foram poucos os meses descartados nas avaliações. No entanto, nota-se que nas estações de Cabrobó (Figura 6A), Garanhuns (Figura 6C), Ouricuri (Figura 6D), Triunfo (Figura 6G) e Arcoverde (Figura 6I), essa filtragem foi necessária em alguns períodos críticos, onde havia grandes falhas em dados diários que corresponderam a eventos de chuva registrados pelo TRMM na mesma data.

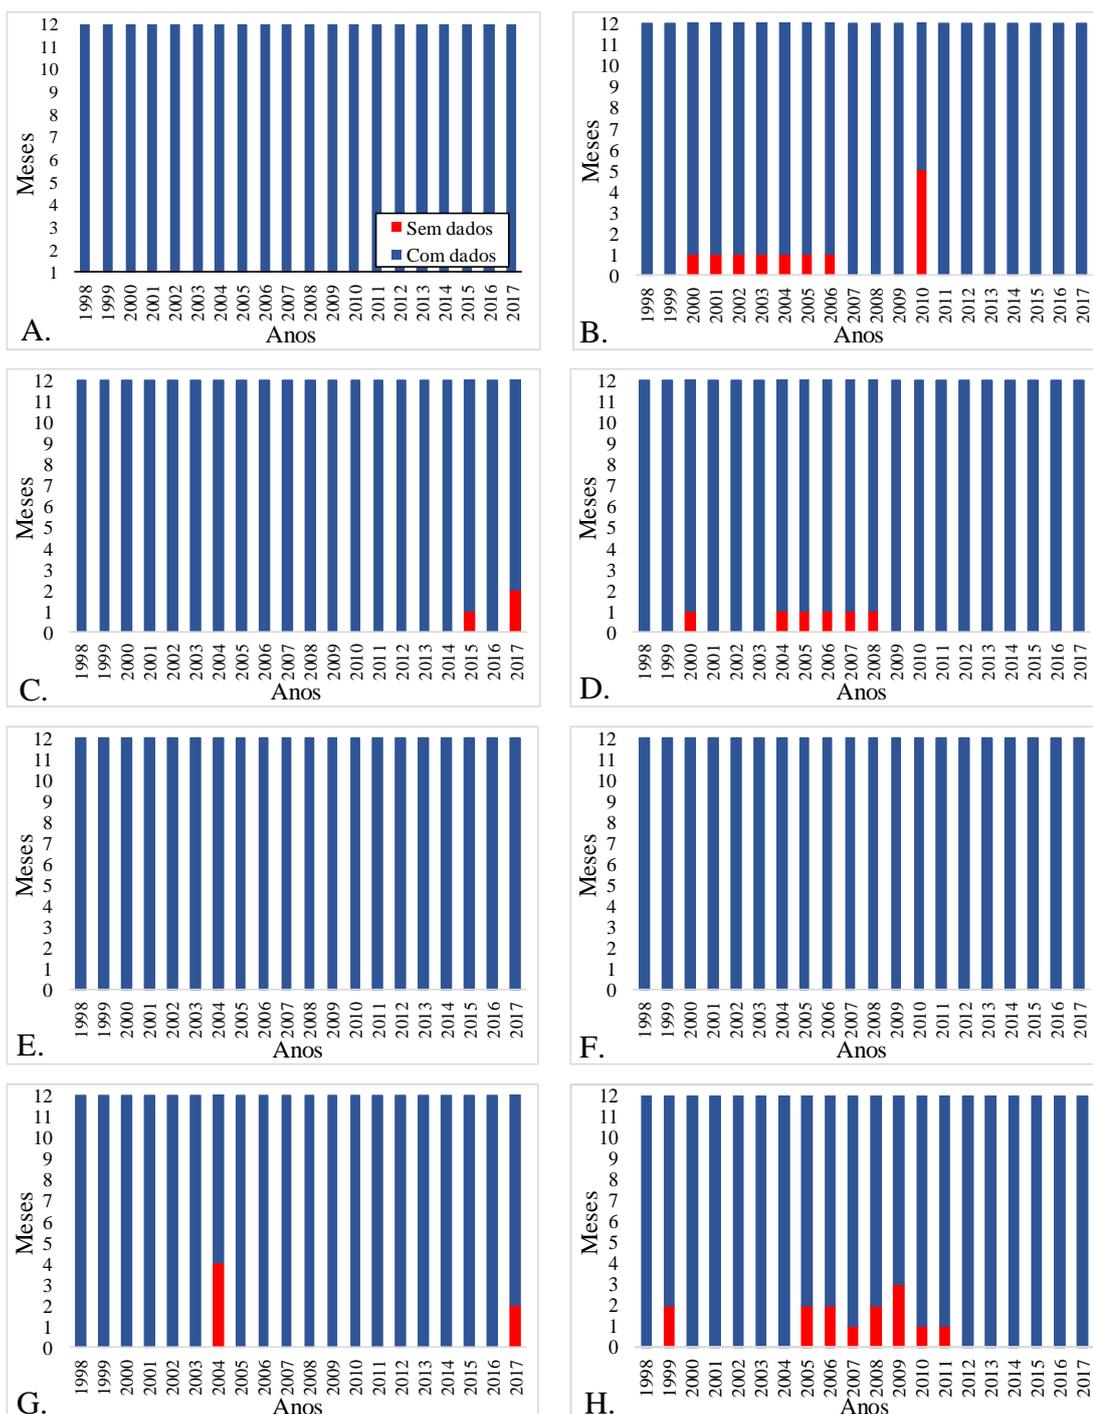


Figura 6. Incidência de falhas em dados de precipitação nas estações validadas durante o período avaliado. (A) Petrolina, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Arcoverde.

Em escala mensal, os coeficientes de correlação foram altos em todos os casos (maior que 0,86), indicando forte similaridade entre os dados estimados pelo TRMM e mensurados nos pluviômetros, embora o satélite tenha subestimado significativamente os dados nas estações de Triunfo e Recife (Figura 7E e G). Em áreas de baixa altitude, inclusive no litoral brasileiro, essa tendenciosidade do TRMM em subestimar dados de precipitação já foi notada anteriormente (SOARES et al., 2016). Além disso, não é novidade que o satélite apresente a característica de superestimar menores valores de precipitação, como ocorreu em quase todas as estações do semiárido, e subestime maiores valores, como foi notado em Recife (bias = -30,87%) e Triunfo (bias = -20,87%). Esse fato já foi confirmado em diversos estudos e em variadas condições geográficas e climáticas (ADEYEWA e NAKAMURA, 2003; CAO, ZHANG e WANG, 2018).

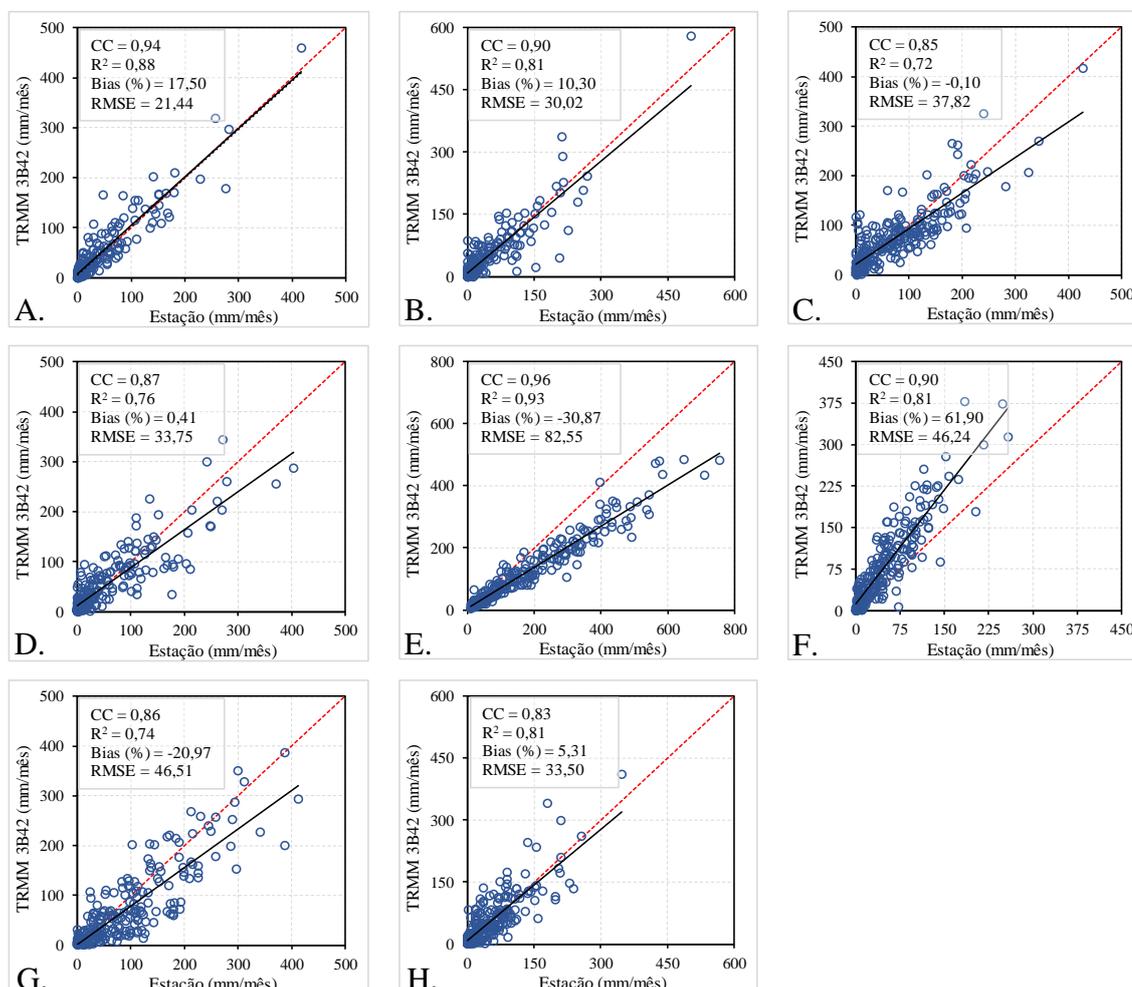


Figura 7. Diagramas de dispersão dos dados de precipitação estimados e mensurados durante o período avaliado, em escala mensal. (A) Petrolina, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Arcoverde.

A estação de Triunfo, apesar de estar inserida no semiárido, possui altitude de 1.010 m e precipitação anual média de 1.243 mm, total semelhante ao alcançado na Zona da Mata litorânea (OLIVEIRA et al., 2006). A característica supracitada de apresentar alto volume pluviométrico em uma região marcada por baixas precipitações anuais pode ter ocasionado a limitação de detecção pelo satélite, dada a sua baixa resolução espacial. Dessa forma, a precipitação registrada nos pixels do entorno pode ter influenciado nas detecções do pixel em que a estação está inserida.

O padrão anteriormente discutido pode ser visualizado com maior clareza na Figura 8, onde estão representados os eventos (quantidade de meses) em que a precipitação foi subestimada ou superestimada pelo TRMM. A estação de Surubim foi a que teve maior quantidade de eventos de chuva superestimados pelo TRMM, ao passo que na estação de Recife o padrão foi inverso, com 216 eventos subestimados em um total de 240 meses (20 anos). Assim como na estação de Recife, em Triunfo houve grande quantidade de eventos subestimados. Nas três estações, os erros (bias e RMSE) foram os mais expressivos, indicando que a tendenciosidade do satélite impacta diretamente na qualidade da estimativa, o que pode ser comprovado pela maior diferença entre os valores de precipitação acumulada nas duas séries (pluviômetro e satélite). No entanto, como os coeficientes de correlação (CC) são sempre elevados, a correção de tendência desses dados é possível para garantir maior precisão das estimativas.

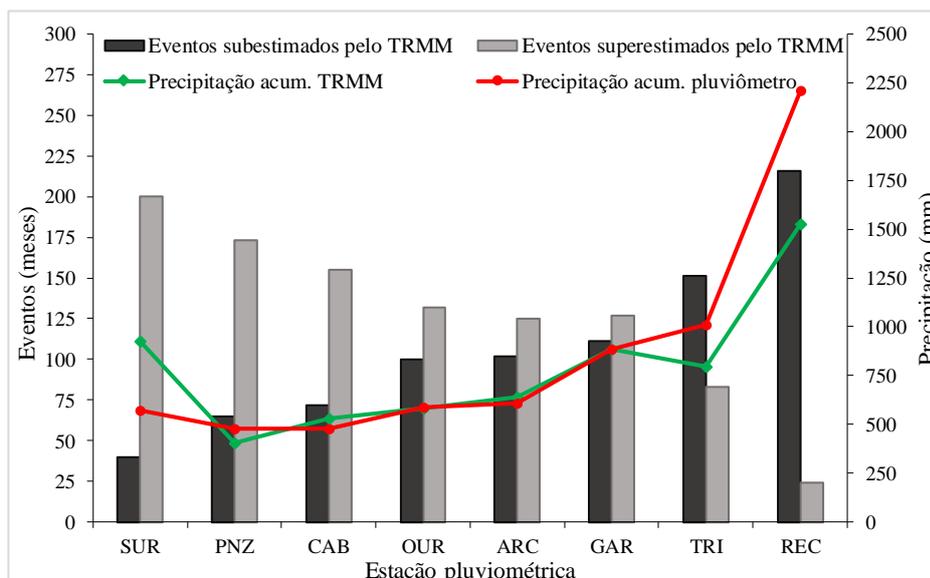


Figura 8. Quantidades de eventos subestimados e superestimados pelo TRMM nas estações validadas para o período de 1998 a 2017.

Ao longo do Estado de Pernambuco e do Nordeste Brasileiro, muitos já foram os esforços para validação do TRMM, em diferentes escalas espaciais e temporais. O foco principal é verificar o potencial do satélite para preenchimento de falhas e aplicação em modelagem hidrológica, considerando a escassez de dados *in situ* ou presença comum de falhas, tornando-os pouco aplicáveis e precisos. Na Paraíba, Soares et al. (2016) avaliaram o desempenho do TRMM em todo o Estado, em escala temporal diária, semanal e mensal. Para dados mensais, os coeficientes de correlação também foram todos bastante elevados, assim como as tendências de subestimativa dos dados de precipitação no litoral, o que acarretou maiores valores de erro médio absoluto (EMA) e raiz do erro quadrático médio (RMSE).

No Estado de Pernambuco, Anjos, Candeias e Nóbrega (2017a) realizaram estudos de mapeamento da precipitação observada pelos postos pluviométricos e estimada pelo TRMM na microrregião de Itaparica, comparando os resultados obtidos e detectando algumas disparidades entre as duas séries de dados. Em novo estudo voltado para a detecção de possíveis causas de erros de estimativa do sensor, no mesmo local, os autores detectaram que o tipo de coleta de dados de precipitação (automática ou convencional) não interfere nos índices estatísticos, além de confirmarem que as diferenças na qualidade das estimativas do TRMM não possuem

dependência espacial ou padrão claramente definido (ANJOS, NÓBREGA e CANDEIAS, 2017b).

Para as estações validadas nesse estudo, todas convencionais, o TRMM apresentou distribuição temporal sempre similar à dos dados medidos (Figura 9), embora, como já discutido anteriormente, tenha evidenciado a tendência de subestimar ou superestimar, em alguns casos. Deve-se ressaltar que o satélite tem resolução espacial de $0,25^\circ$ (~ 27 km x 27 km), 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).

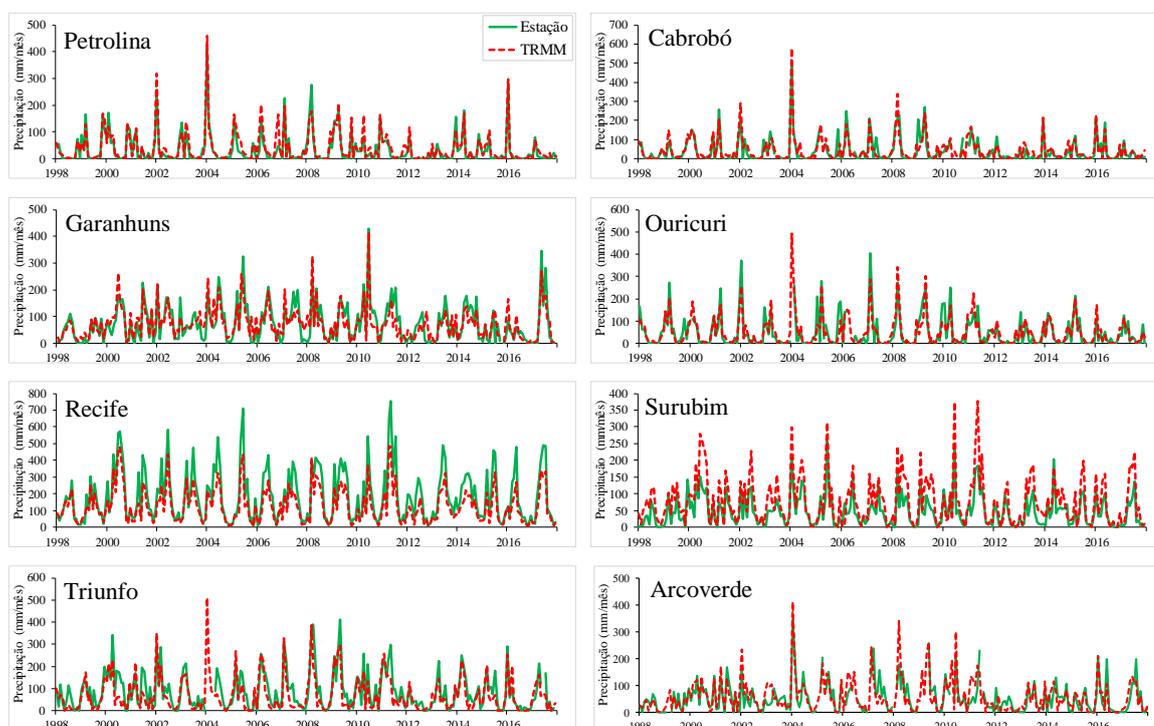


Figura 9. Precipitação estimada pelo TRMM e mensurada pelas estações pluviométricas, em escala temporal mensal, para o período de 1998 a 2017.

3.2 Comparação da precipitação sazonal com base no produto TRMM 3B42V7 e estações pluviométricas para série de 20 anos

Além da precipitação acumulada mensal, a variação sazonal das chuvas é essencial para caracterizar o clima de uma região, apontando os períodos com maior e menor índice pluviométrico. Esse conhecimento favorece diversas

aplicações, especialmente voltadas à agricultura em regiões semiáridas que dependem, em grande parte, do volume de água precipitado. Silveira et al. (2013) reforçam a importância de utilizar a variação sazonal da precipitação para validação de dados estimados, seja por satélites ou modelos que recriam dados passados, atuais e futuros, visto que a variação sazonal é indispensável para a avaliação de impactos no clima, agricultura e recursos hídricos, já que o início de plantio das culturas e regime fluvial são condicionados pela distribuição das chuvas ao longo do ano.

As estações de Petrolina, Cabrobó, Garanhuns e Ouricuri (Figura 10) apresentaram precipitação sazonal estimada muito próxima da mensurada nas estações pluviométricas, evidenciando a precisão do satélite, especialmente em condições de menor pluviosidade. Esse padrão também foi detectado na validação de dados mensais em toda a série, considerando que o TRMM apresenta menos tendências nos dados para esses locais. Já nas estações de Recife, Ouricuri, Surubim e Arcoverde houve maior diferença entre as séries de dados, embora a flutuação temporal tenha se mantido semelhante.

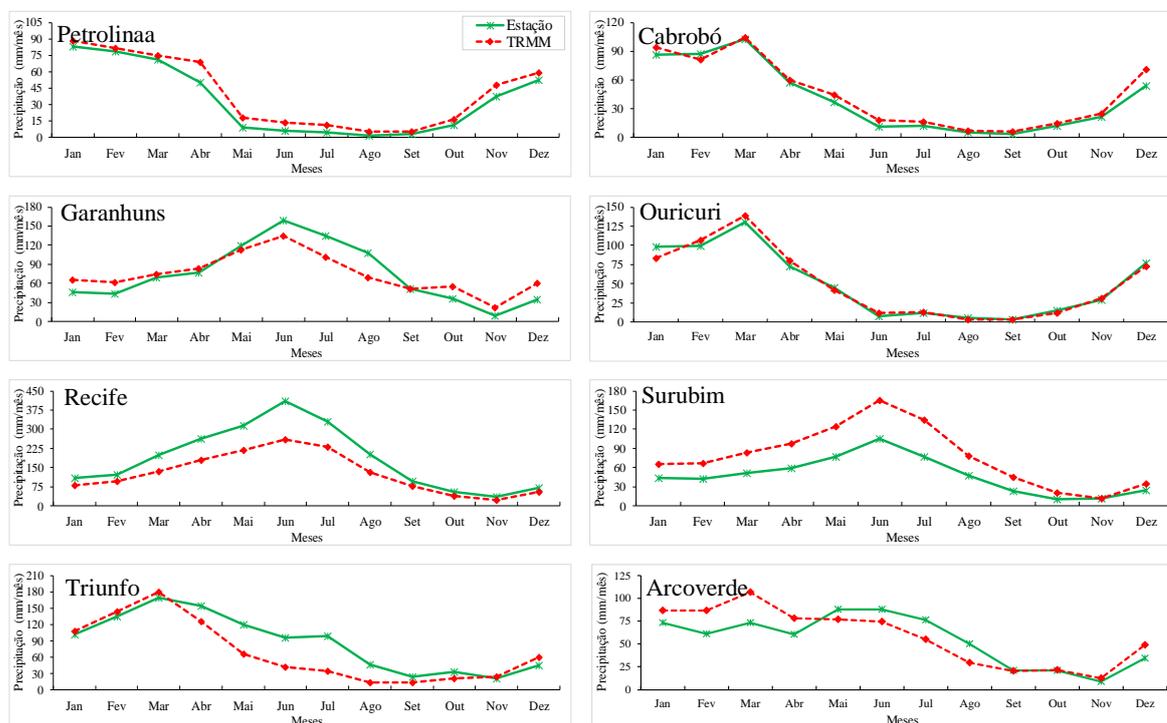


Figura 10. Variação sazonal da precipitação com base nas estações pluviométricas e produto TRMM 3B42V7.

A avaliação da dinâmica sazonal da precipitação é aplicada em quase todos os estudos com o TRMM ao longo do planeta (CAO, ZHANG e WANG,

2018; PRASETIA, AS-SYAKUR e OSAWA, 2013; WANG et al., 2017). Em diversas aplicações hidrológicas, a precipitação sazonal exerce grande influência nos dados de saída, além de permitir compreender, de forma mais adequada, a dinâmica de diversos processos que podem intervir na distribuição da água sobre uma determinada região. Em modelos de projeção de cenários futuros baseados em mudanças climáticas, a precipitação sazonal também é uma das formas mais eficientes de validar os dados gerados pelos diversos fornecedores, visto que, devido à grande quantidade de dados simulados para diversos anos, considerar apenas a variação anual da precipitação para o toda série pode gerar grandes incertezas, especialmente em avaliações de seca (GUIMARÃES et al., 2016; ONGOMA, CHENA e GAOA, 2018; SILVEIRA et al., 2013).

Apesar de em alguns casos (Garanhuns, Recife, Surubim e Triunfo) o TRMM ter subestimado ou superestimado os dados de referência, mensurados pelos postos pluviométricos, essa tendência pode ser corrigida pelo uso de diversas técnicas, a depender da aplicação que será realizada, especialmente para fins de modelagem hidrológica. Nesse sentido, Liu et al., (2017), utilizaram dados do TRMM 3B42V7 em conjunto com séries *in situ* para modelagem hidrológica, realizando a remoção de erros sistemáticos para os dados do satélite. Já em determinadas aplicações, essa correção pode não ser necessária. Na modelagem de índices de seca como o SPI (Índice de Precipitação Padronizada), por exemplo, mais importante que os erros de subestimativa ou superestimava entre as séries de precipitação é a sua alta correlação ao logo do tempo. Quando os dados do satélite não são validados previamente para confirmar esse padrão, o índice pode não representar de forma correta a dinâmica da seca em curto ou longo prazo (JESUS et al., 2016). Em todas as estações validadas, os coeficientes de correlação foram bastante elevados, indicados que os dados do TRMM tendem a flutuar de forma similar ao dos postos pluviométricos e, em decorrência disso, apresentam grande potencial para modelagem da seca.

Uma outra forma de validar dados de modelagem ou oriundos de satélites é por meio de gráficos com curvas de frequência acumulada (Figura 11). A frequência acumulada indica a quantidade de vezes em que a variável, nesse caso a precipitação, assume um valor igual ao inferior a um determinado

valor “y”, representado pelo eixo das frequências acumuladas do gráfico. Quanto melhor for a qualidade dos dados estimados, mais próximas serão as curvas comparativas entre o valor previsto (TRMM 3B42V7) e registrado (postos pluviométricos).

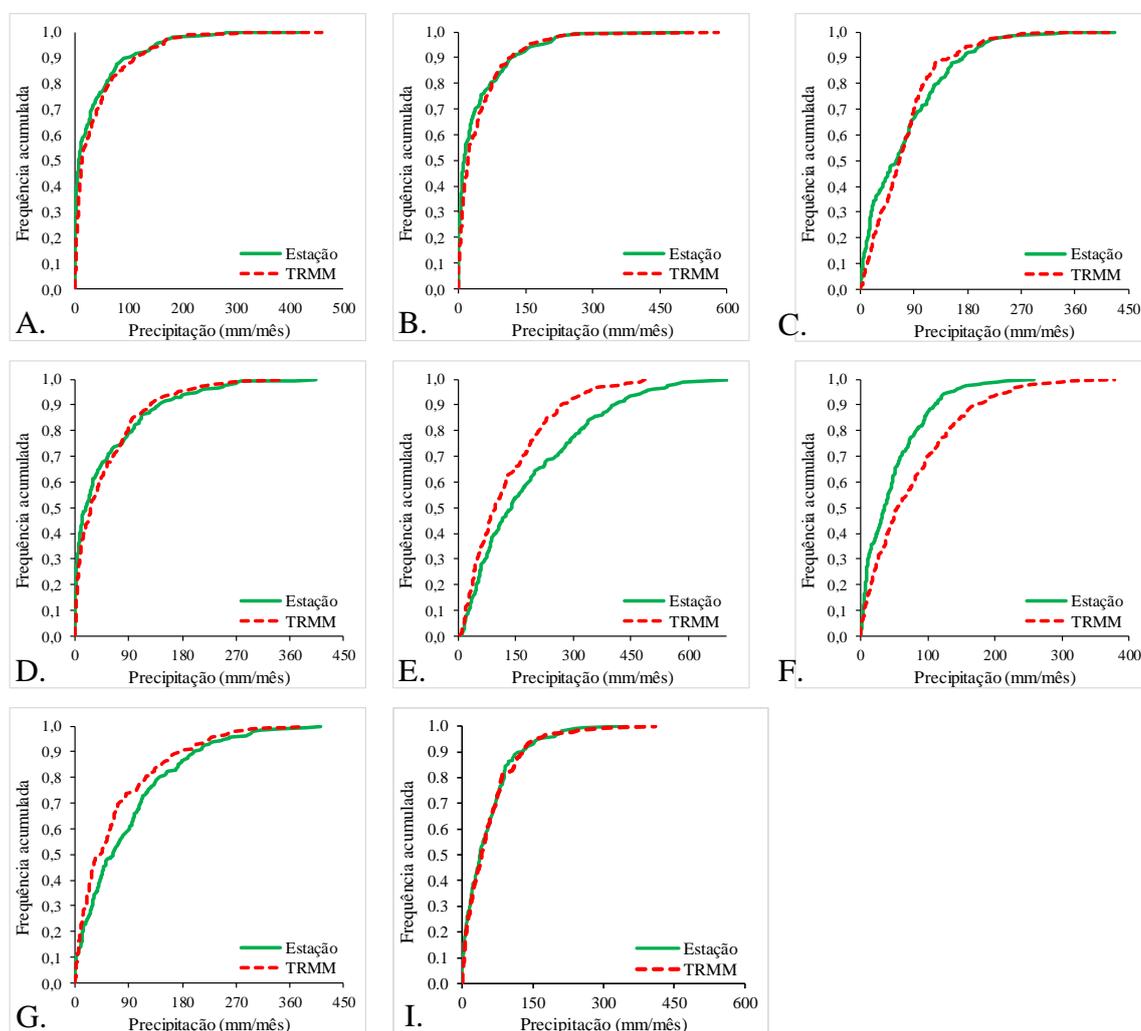


Figura 11. Frequência acumulada para os dados de precipitação estimados e mensurados em escala temporal mensal. (A) Petrolina, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (I) Arcoverde.

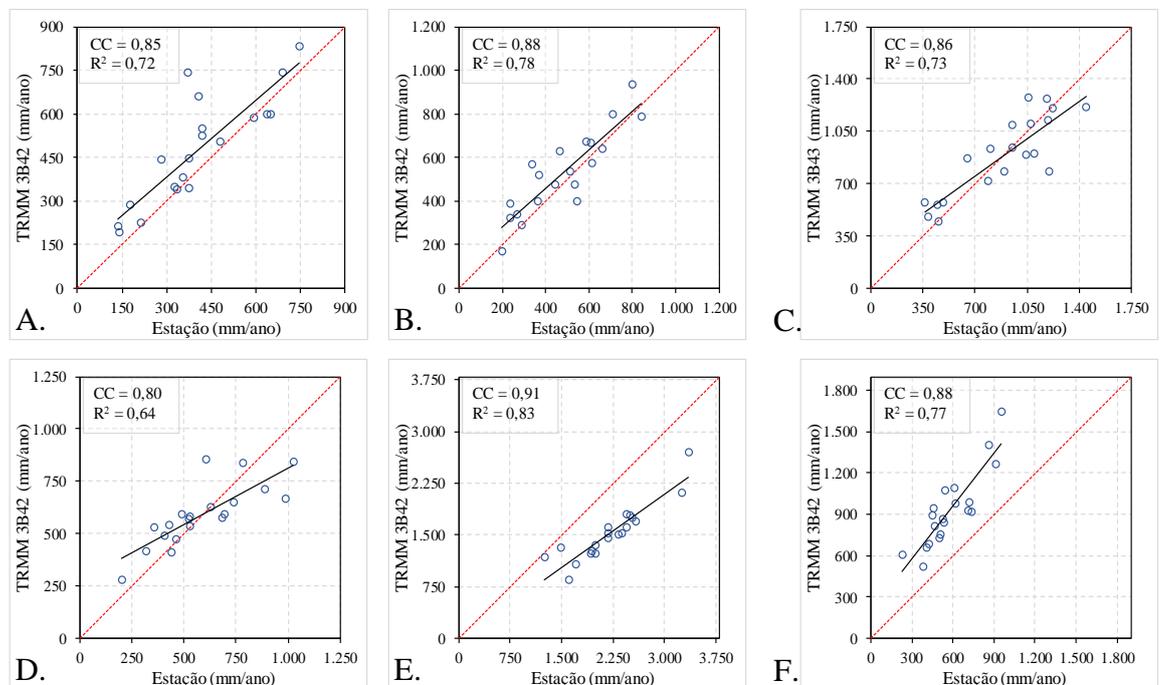
Novamente, nota-se a similaridade entre as duas séries, embora fique mais clara a tendência de o TRMM subestimar ou superestimar os dados de precipitação em algumas estações, conforme discutido anteriormente.

3.3 Comparação da precipitação anual com base no produto TRMM 3B42V7 e estações pluviométricas para série de 20 anos

Diversos estudos apontam a tendência de os dados de precipitação de sensores remotos aumentarem a correlação com dados *in situ* quando a escala

temporal é incrementada. Por exemplo: quando o acumulado é alterado de 3 horas para 24 horas e deste último para uma semana, um mês ou um ano, ocorre maior correlação entre dados estimados pelos sensores e mensurados pelas estações pluviométricas. Esse padrão foi detectado por Soares, Paz e Piccilli (2016), no estado da Paraíba, e Mantas et al. (2015), na Cordilheira dos Andes, Peru. Os dois estudos foram em regiões com climas distintos, mas a resposta do TRMM foi similar nesse aspecto. Isso, mais uma vez, reforça a importância da validação em diferentes escalas temporais, bem como sazonalmente.

No estado de Pernambuco, o TRMM 3B42V7 apresentou maior correlação temporal quando comparado a algumas estações pluviométricas em escala mensal (Figura 12). Em outros casos, porém, o desempenho foi maior em escala anual. O padrão de subestimar ou superestimar os dados mensurados manteve-se similar nas duas escalas temporais, indicando que essa tendência se mantém ao longo de todo o ano e não apenas em meses esporádicos. Mais uma vez, vale destacar a influência de fatores topográficos na qualidade da estimativa do dado, considerando que a intensidade e qualidade do sinal recebido pelos sensores do TRMM variam globalmente.



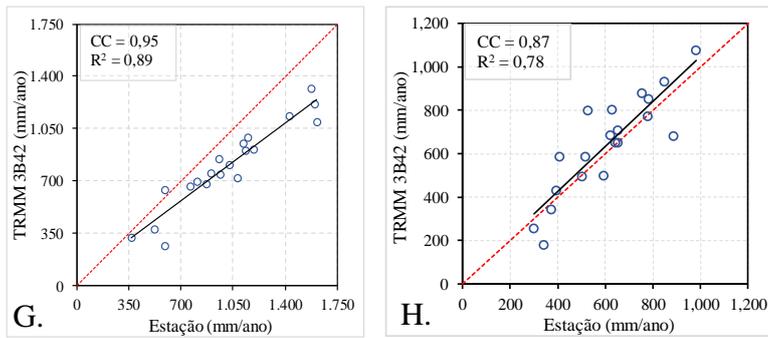
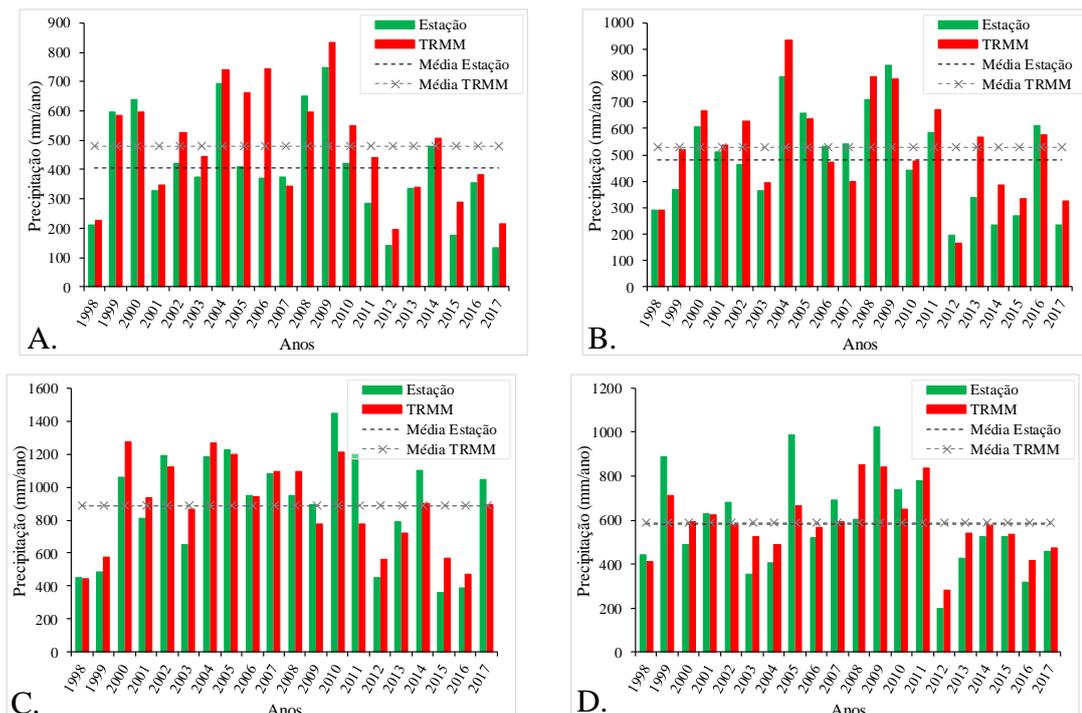


Figura 12. Diagramas de dispersão dos dados de precipitação estimados e mensurados durante o período avaliado, em escala anual. (A) Petrolina, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Arcoverde.

O TRMM apresentou valores médios de precipitação para toda a série (1998-2017) praticamente igual aos registrados nas estações de Garanhuns e Ouricuri (Figura 13). Os erros médios (EM) foram de 0,86 mm e 3,91 mm, respectivamente. Na estação de Cabrobó, os valores também foram bastante similares (EM = 49,35 mm). Houve variação quanto à capacidade de o satélite superestimar ou subestimar a precipitação em alguns anos. As diferenças geradas por essa variação acabaram levando a um maior equilíbrio e redução dos erros médios nessas estações. Nos demais casos, os erros foram mais significativos e, no caso de Triunfo e Recife, onde o satélite subestimou os eventos em quase todos os casos, os EM foram de -211,92 mm e -681,55 mm, respectivamente.



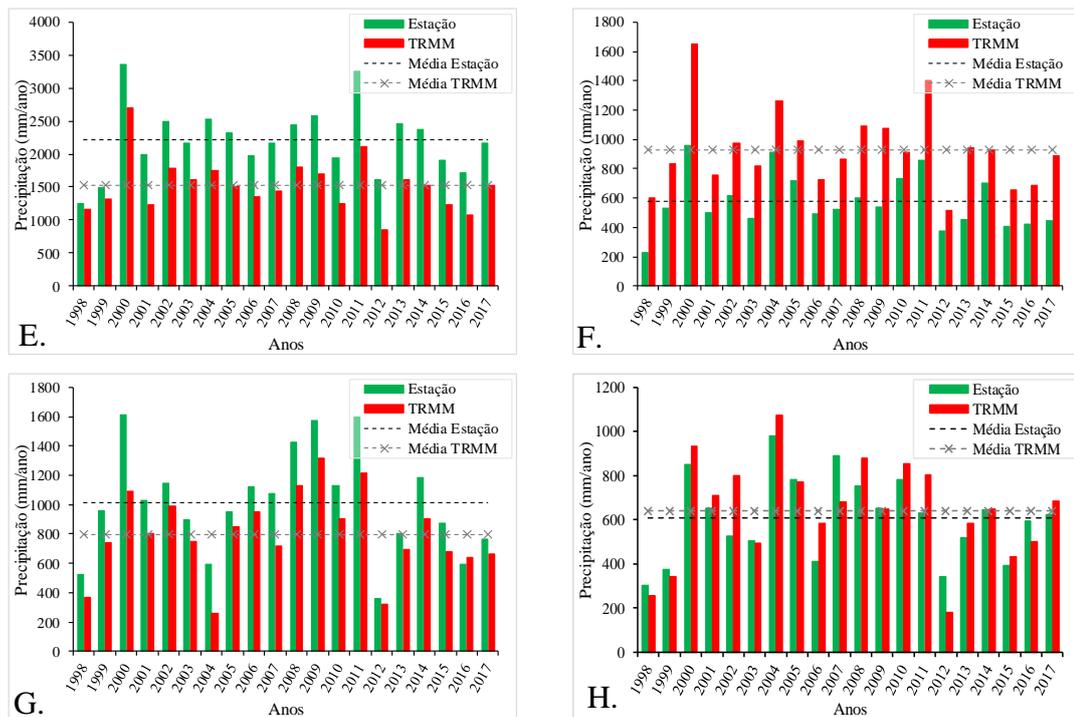


Figura 13. Comparação dos dados de precipitação estimados e mensurados durante o período avaliado, em escala anual. (A) Petrolina, (B) Cabrobó, (C) Garanhuns, (D) Ouricuri, (E) Recife, (F) Surubim, (G) Triunfo, (H) Arcoverde.

Wang et al. (2018), avaliando a aplicabilidade do TRMM em região árida da China, detectaram valores de *bias* superiores a 110% em escala temporal mensal. Os erros também variaram com as condições topográficas e climáticas da região e evidenciaram que esses fatores claramente interferem na precisão do satélite. No estado de Pernambuco, o maior valor de *bias* (%) em escala mensal foi de 61,90 na estação de Surubim, indicando que o TRMM superestimou, nessa magnitude, os dados de precipitação mensurados em superfície.

A Tabela 3 resume os índices estatísticos utilizados para avaliação do desempenho do TRMM, 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.

Tabela 3. Índices estatísticos utilizados para avaliação do desempenho do TRMM 3B42V7 em escala temporal mensal e anual.

Estação	Mensal				Anual			
	CC	R ²	Bias (%)	RMSE	CC	R ²	Bias (%)	RMSE
Petrolina	0,94	0,88	17,48	21,44	0,85	0,72	17,48	122,22
Cabrobó	0,90	0,81	10,30	30,02	0,88	0,78	10,30	102,16
Garanhuns	0,85	0,72	-0,10	37,82	0,86	0,73	-0,10	162,57
Ouricuri	0,87	0,76	0,41	33,75	0,80	0,64	0,67	131,26
Recife	0,96	0,93	-30,87	82,55	0,91	0,83	-30,87	716,87
Surubim	0,90	0,81	61,90	46,24	0,88	0,77	61,90	380,77
Triunfo	0,86	0,74	-20,97	46,51	0,95	0,89	-20,97	245,38
Arcoverde	0,83	0,81	5,31	33,50	0,87	0,78	5,31	115,22

3.4 Precipitação acumulada anual obtida a partir da série de dados do TRMM

A partir de dados de precipitação diários do TRMM, 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). Neste caso, cada pixel do satélite representou um ponto (ou posto pluviométrico virtual), espaçados em ~27 km, o que confere boa aplicabilidade da técnica. 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 TRMM.

O TRMM identificou adequadamente os anos em que as chuvas excederam a média histórica, especialmente no Agreste e Zona da Mata. Vale destacar os acumulados anuais para os anos de 2000 e 2011. No primeiro caso, a precipitação registrada chegou a ultrapassar 3000 mm ano⁻¹ no litoral. Outros anos, como 2002, 2004, 2008 e 2009 também apresentaram volumes de água precipitada superiores aos demais, na maior parte do Estado. O mesmo ocorreu com os anos mais secos. É sabido que a região semiárida do Nordeste Brasileiro enfrenta, desde 2012, uma grave crise hídrica, com taxas de precipitação pluviométrica inferior àquelas registradas nos últimos 30 anos (ROSSATO et al., 2017). Esse padrão também foi detectado. Através da Figura

14, é possível notar que os últimos anos, a partir de 2012, apresentaram grande predisposição à seca na região do semiárido.

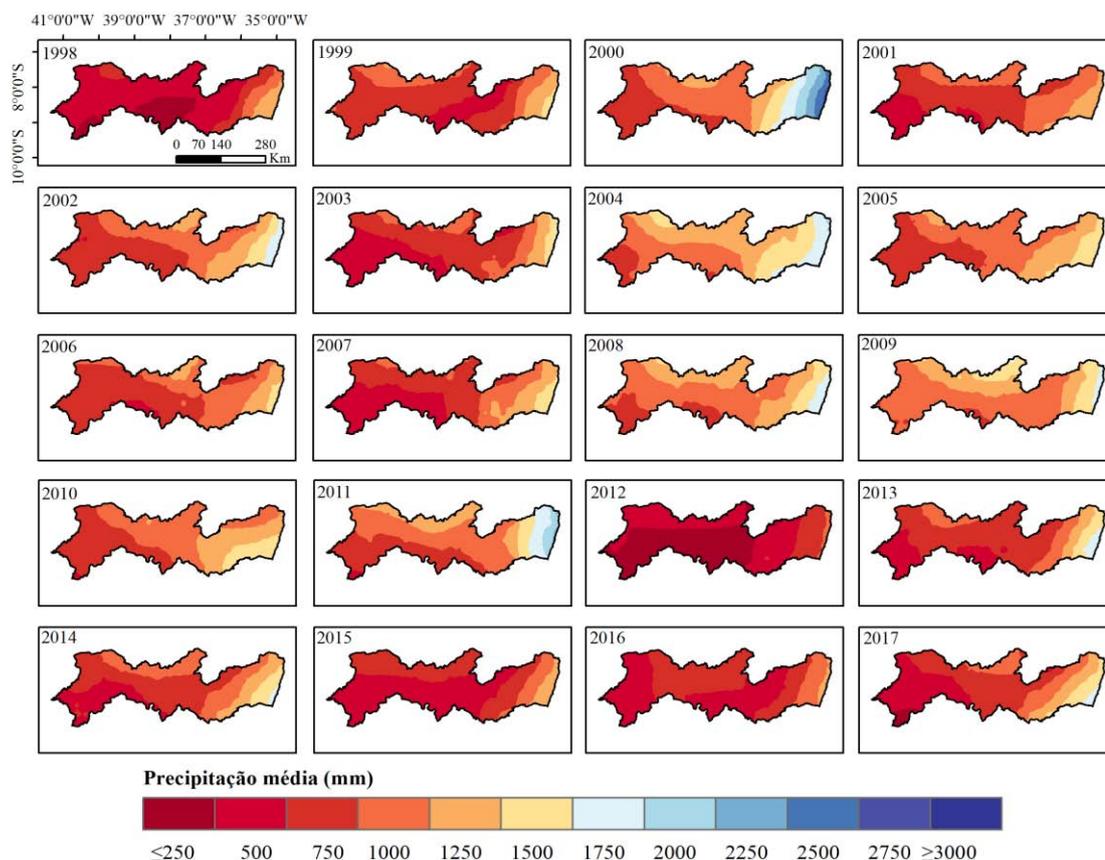


Figura 14. Precipitação acumulada anual obtida a partir do TRMM 3B42V7 para o Estado de Pernambuco.

A precipitação média anual estimada pelo TRMM 3B42V7 é bastante similar e segue o mesmo padrão de distribuição espacial já registrado na literatura. A maior diferença é percebida apenas nos valores de volume precipitado no litoral do Estado, dada a tendência de o satélite subestimar a precipitação nessa região.

Silva, Queluz e Klar (2013), avaliando a distribuição da precipitação com base em 45 estações meteorológicas ao longo do estado, perceberam alguns pontos na Zona da Mata e Litoral em que o acumulado médio mensal ultrapassa 2800 mm ano^{-1} . Já Possas et al. (2012), realizando o mesmo estudo, porém com uma quantidade maior de postos pluviométricos ($n = 146$), identificaram precipitação média máxima de 2265 mm ano^{-1} , o que deixa claro que o volume precipitado podem variar em função da quantidade e localização dos postos utilizados. De qualquer forma, o viés na estimativa do TRMM é evidente, considerando que o satélite, no litoral, registrou valor médio máximo

de 1600 mm ano⁻¹, embora no semiárido, o volume tenha sido bastante similar ao detectado nos estudos anteriores (Figura 15). Para melhor ilustrar a variação espacial da precipitação dentro do Estado em comparação com as áreas vizinhas, nesse caso, a superfície do mapa não foi interpolada para torná-la contínua e suavizada como nas imagens anteriores, sendo mantida a resolução nativa do TRMM.

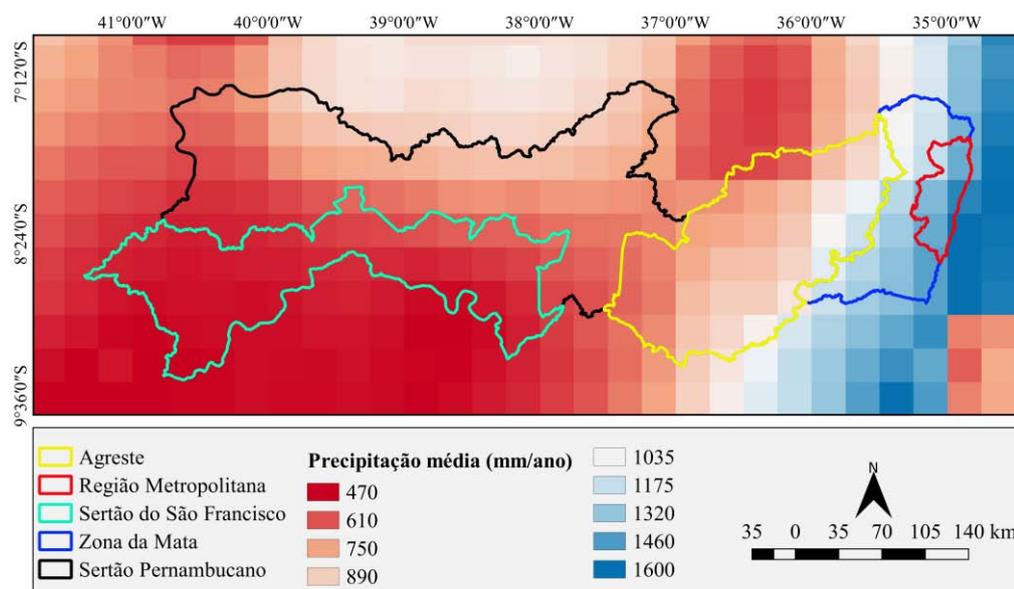


Figura 15. Precipitação média anual obtida a partir do TRMM 3B42V7 para o Estado de Pernambuco.

3.5 Precipitação acumulada mensal obtida a partir da série de dados do TRMM

A utilização de dados de precipitação é essencial na avaliação da precipitação sazonal, 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.

Nesse sentido, Silva et al. (2013) enfatizam que, com o aumento da temperatura média nos últimos anos, a agricultura de sequeiro é uma prática de alto risco no semiárido. Desta forma, é necessária a identificação de áreas que apresentam bom potencial agrícola e, ao mesmo tempo, estejam expostas ao menor risco climático possível. Uma das formas de detectar essas áreas é a

partir de séries históricas de dados de precipitação, embora em uma região bastante seca, como o semiárido, essa avaliação requeira a integração com dados complementares, como a temperatura.

A partir dos dados gerados pelo TRMM é possível reconhecer as épocas mais ou menos chuvosas em cada área do Estado ao longo do ano. Nas mesorregiões do Sertão e São Francisco, por exemplo, a estação chuvosa tem início no mês de dezembro e estende-se até maio. Na Zona da Mata e Agreste, o período com maior registro de índices pluviométricos vai de março a agosto (Figura 16).

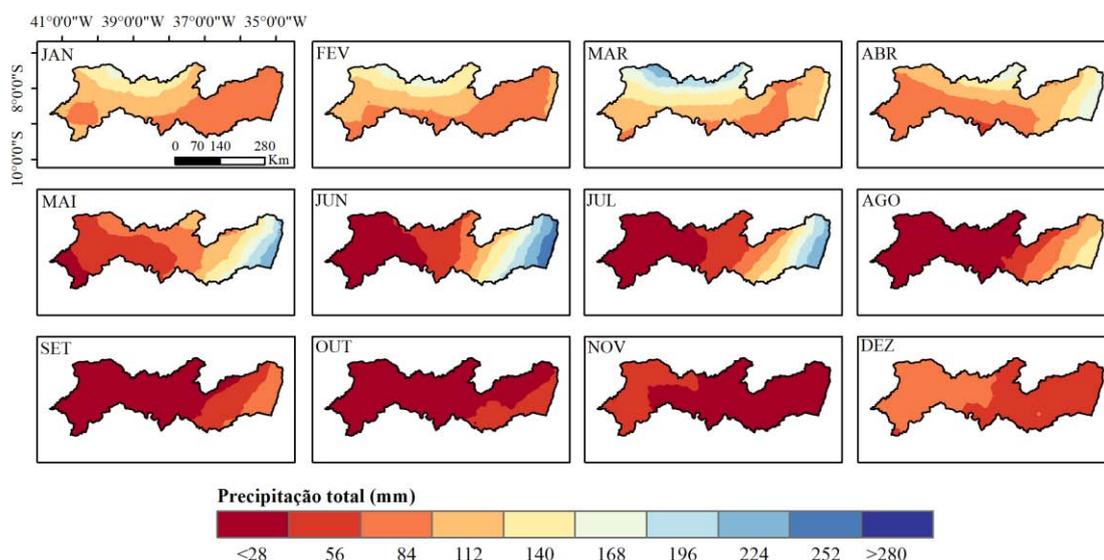


Figura 16. Precipitação acumulada mensal obtida a partir do TRMM 3B42V7 para o Estado de Pernambuco.

Para melhor compreensão e visualização da distribuição sazonal das chuvas no Estado, considerando a conhecida variação do regime pluviométrico desde o setor ocidental (clima semiárido) de Pernambuco até o litoral (clima tropical), foram calculados os histogramas de precipitação a partir de cada pixel do TRMM, utilizando como referência toda a série de 20 anos, desde o início das operações com o satélite até o ano de 2017.

Na porção ocidental, as chuvas de maior intensidade têm início do final do ano, a partir de meados de novembro, persistindo até o mês de maio. Conforme se avança em direção ao litoral, esse padrão vai sendo gradativamente alterado, o que pode ser constatado pela forma do histograma, que vai ficando cada vez mais com uma aparência 'triangular' (Figura 17). Isso indica que os maiores índices pluviométricos estão concentrados no meio do

ano, como ocorre em Recife, por exemplo, com período chuvoso de março a agosto.

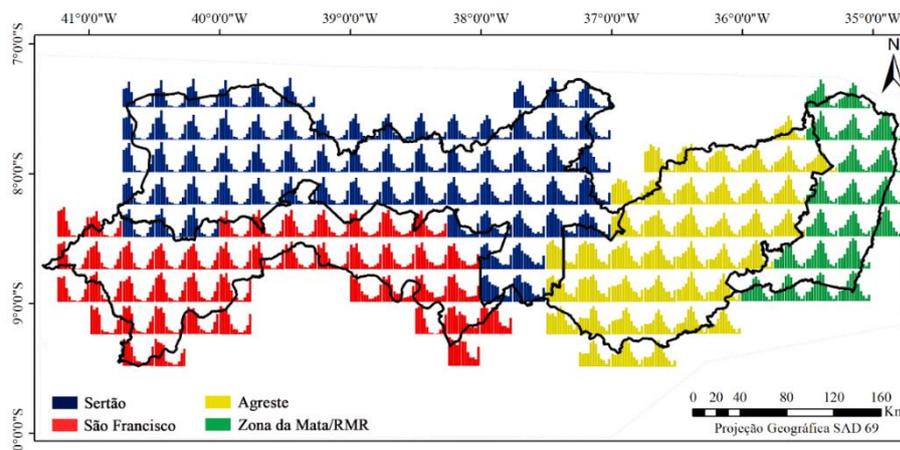


Figura 17. Histogramas de precipitação obtidos a partir do TRMM 3B42V7 para o Estado de Pernambuco.

A distribuição sazonal da precipitação registrada pelo TRMM ao longo de 20 anos é consistente com grandes séries de dados mensuradas em superfície. Esse padrão, no entanto, é uma referência e pode ser alterado nos últimos anos. Em virtude das mudanças climáticas e aquecimento global, alterações no regime pluviométrico já vêm sendo percebidas em todo o globo e, ao longo dos anos, essas variações podem interferir até mesmo na sazonalidade das chuvas (DORE, 2005).

3.6 Quantidades de dias secos e úmidos por ano

No último século, a comunidade científica concentra sua atenção nas crescentes alterações climáticas em escala global. Com isso, surge a necessidade de analisar as tendências da precipitação em diferentes escalas espaciais e temporais. Evidências alarmantes indicam que o aquecimento global e mudanças regionais no clima têm levado a alterações significativas nos padrões das chuvas (TRENBERTH et al., 2003).

Essas alterações podem ser percebidas através da avaliação da quantidade de dias secos e úmidos por ano. Com base em uma série histórica de precipitação, é possível verificar a tendência de a quantidade de dias secos ou úmidos aumentarem ou diminuir em decorrência de fenômenos de seca ou cheias. O TRMM pode ser utilizado e tem boa aplicabilidade nesse tipo de avaliação (HUANG et al., 2018; ODOULAMI e AKINSANOLA, 2018). Embora

sua série de dados ainda seja recente, a continuidade está garantida pela NASA através do *Global Precipitation Measurement (GPM)*, que iniciou a coleta de dados em 2014, aumentando ainda mais o potencial desse tipo de estudo.

A irregularidade das chuvas interfere não somente no volume precipitado, como também na distribuição anual da precipitação. No ano de 2000, o mais chuvoso da série, a quantidade média de dias secos (precipitação $< 1 \text{ mm dia}^{-1}$) foi de 309,27 em todo o estado. Já no ano mais seco, em 2012, a média foi de 338,59, quase 30 dias a mais com ausência de chuvas. Os dias chuvosos, no entanto, não indicam grande volume precipitado, visto que a metodologia considera como dia 'não seco' aqueles em que a precipitação foi superior a 1 mm.

A tendência de aumento na distribuição dos dias secos apresenta padrão similar em todo o estado, inclusive no litoral, confirmando que os anos mais secos são também aqueles com menor quantidade de dias chuvosos (Figura 18). Isso indica que as secas não estão relacionadas apenas ao volume precipitado, como também à distribuição temporal das chuvas. Em vários pontos do estado na faixa do semiárido, especialmente durante os anos mais secos, a quantidade de dias secos ao ano foi maior que 360, indicando quase que total ausência de chuvas detectadas pelo satélite. Os anos de 2012 e 2017 foram os mais críticos. De fato, o período compreendido entre esses dois anos é o mais severo em termos totais de chuva desde 1911. Como resultado, há uma intensificação dos efeitos da seca ao longo desse período, que podem ser agravados ainda mais pela perspectiva de anos subsequentes também secos (MARTINS e MAGALHÃES, 2015).

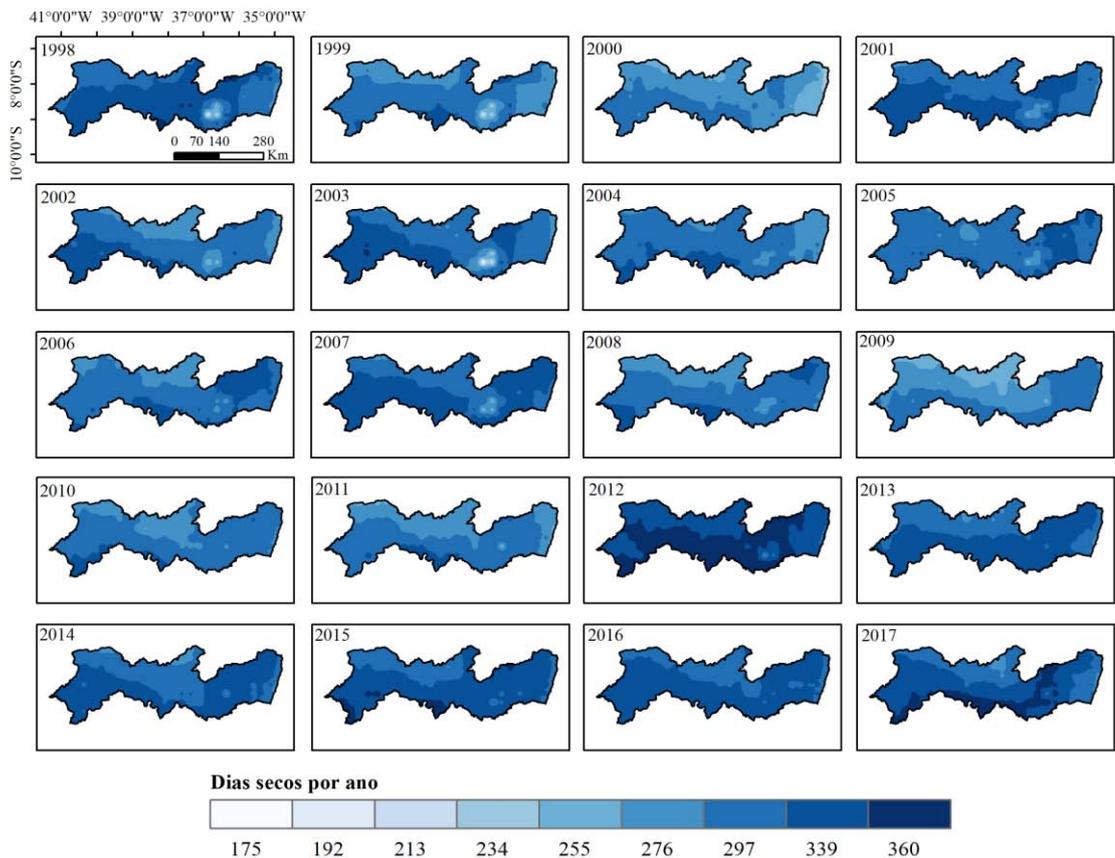


Figura 18. Quantidade de dias secos por ano obtidos a partir do TRMM 3B42V7 para o Estado de Pernambuco.

A quantidade de dias úmidos por ano (precipitação > 1 mm dia⁻¹) tem, obviamente, uma distribuição inversa à quantidade de dias secos, sendo sempre inferiores e com maior predominância na Zona da Mata e Litoral (Figura 19). Vale destacar, mais uma vez, o ano de 2012, em que 85% do estado enfrentou uma quantidade de dias com chuva inferior a 10 mm, mesmo em grande parte do Agreste, onde as precipitações são bem distribuídas e chegam a atingir acumulados anuais superiores a 1000 mm (POSSAS et al., 2012).

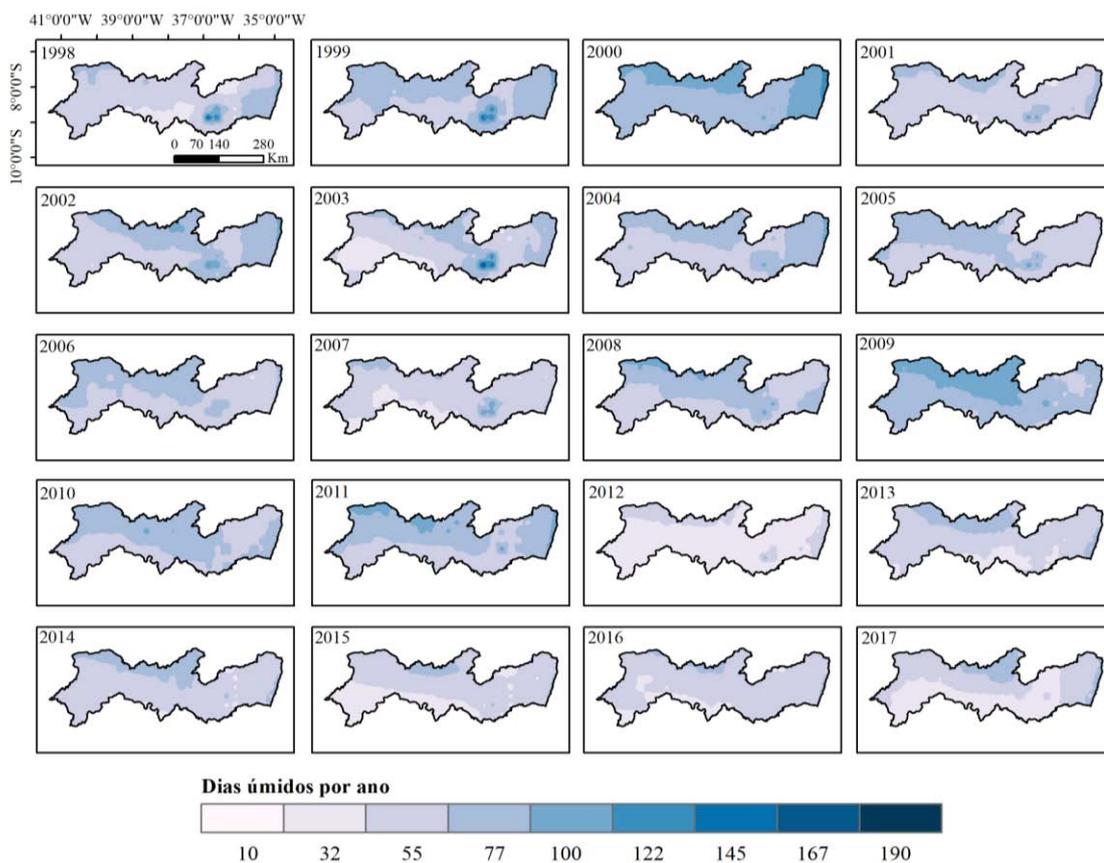


Figura 19. Quantidade de dias úmidos por ano obtidos a partir do TRMM 3B42V7 para o Estado de Pernambuco.

No que concerne à variabilidade climática no Nordeste, Marengo et al. (2017) destacam que eventos de seca ou cheia estão frequentemente associados a fenômenos de larga escala, como os episódios de El Niño e La Niña, ou com um gradiente aumento de temperatura do oceano no Atlântico tropical. No entanto, de todos os 46 eventos de El Niño que ocorreram desde 1849 até 1992, apenas 21 deles estão associados com eventos de seca, de modo que o El Niño explica apenas uma fração da variabilidade das chuvas no Nordeste. Nas secas mais recentes, incluindo as de 1992, 1998, 2002, 2010 e 2012-2016, apenas as de 1998, 2002 e 2015-16 ocorreram durante o El Niño. Em contrapartida, a seca de 2012 ocorreu durante o La Niña. Além disso, a seca que teve início nesse mesmo período também está associada ao gradiente de aumento de temperatura das águas do oceano Atlântico, que rege o deslocamento meridional da Zona de Convergência Intertropical (ITCZ). Sendo assim, não é apenas um único evento ou sistema atuante que explica a intermitência e magnitude das secas no Nordeste.

3.7 Variabilidade espacial da precipitação em relação ao perfil longitudinal

Conforme discutido nas seções anteriores, a precipitação ao longo do Estado de Pernambuco tende a aumentar gradativamente do setor ocidental em direção ao setor oriental. Isso ocorre porque o primeiro está inserido no semiárido, com baixos índices pluviométricos e eventos frequentes de seca; já o segundo encontra-se em uma outra condição climática, com chuvas bem distribuídas e em grande volume durante o ano.

Dados de superfície obtidos por interpolação, assim como estimativas por modelagem ou sensoriamento remoto, evidenciam com clareza essa tendência, embora não deixem tão explícito como se dá a dinâmica da variação dentro do perfil longitudinal. Na Figura 20 é possível notar que, em todos os anos, a precipitação aumenta de forma gradativa no sentido oeste-leste do estado. Esses dados foram obtidos diretamente do TRMM, após a discretização espacial dos pixels de ~27 km usando o IQD. Embora a tendência seja sempre a mesma, o padrão não é igual. Na maioria dos anos, a distribuição tende a apresentar o formato 'exponencial', com um grande aumento do volume precipitado do semiárido ao litoral, especialmente no ano de 2000, quando a precipitação máxima chegou perto de 3000 mm. Já em 2010, por exemplo, a distribuição lembra a 'linear', com um crescimento mais constante. Esse padrão, evidentemente, também tem relação com os fenômenos de seca. Em 2012 e 2015, anos mais secos da série, quase não foi percebida variação de precipitação dentro do perfil longitudinal até metade do Agreste, já próximo da Zona da Mata e Litoral.

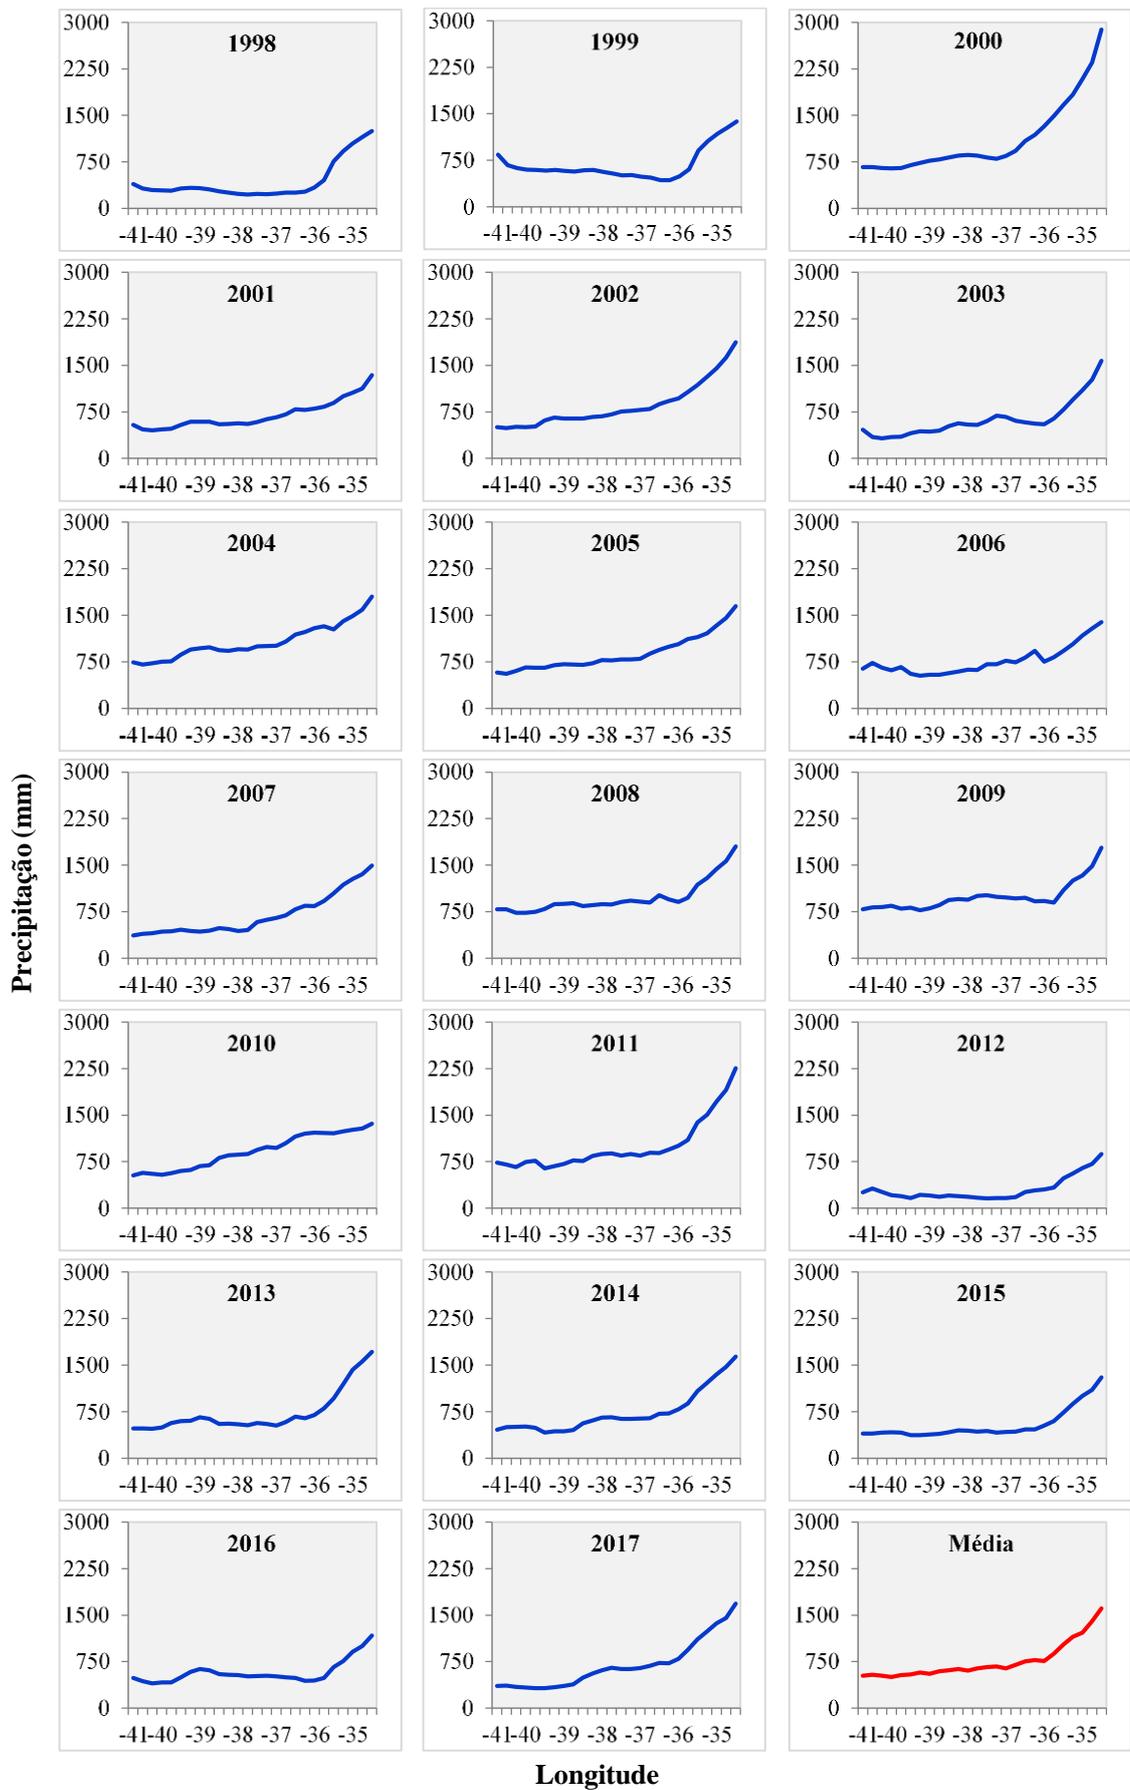


Figura 20. Variação espacial da precipitação em função do perfil longitudinal.

3.8 Validação do índice de precipitação padronizada (SPI) obtido pelo produto TRMM 3B42

O índice de precipitação padronizada (SPI) utiliza como dado entrada apenas valores mensais de precipitação. Sendo a chuva o principal regulador da seca, esse índice se destaca pela facilidade de aplicação, aliado aos bons resultados na modelagem de eventos secas e cheias. O SPI pode ser calculado em diferentes escalas de tempo (cada uma com uma aplicação definida), possibilitando o alerta prévio da seca e ajudando a avaliar a sua severidade. A principal desvantagem desse índice é a necessidade de dados preliminares já existentes e consistentes (FERNANDES et al., 2009).

Para análises espaciais, quanto mais densa for a rede de postos pluviométricos e maior for a série, melhores serão os resultados obtidos. Além disso, postos com falhas podem representar um problema na modelagem desse índice, especialmente por longos períodos. Uma saída que nos últimos anos vem sendo adotada é a utilização de dados de sensores remotos ou dados globais de precipitação obtidos por reanálise para o cômputo do SPI, como é o caso do TRMM (MERONI et al., 2017; TAN et al., 2017; TAO et al., 2016), CHIRPS (GAO et al., 2018; GUO et al., 2017), GPCP (RODRIGO et al., 2017; SANTOS et al., 2017) e PERSIANN-CDR (GUO et al., 2016).

Vale destacar que, para a modelagem do SPI ou demais índices de seca baseados na precipitação, a precisão do satélite ou produto em relação ao real volume precipitado não é o mais importante. O satélite pode, por exemplo, subestimar ou superestimar o volume de chuvas sem que isso interfira no seu desempenho para a modelagem da seca. No entanto, a correlação temporal dos dados deve ser bastante alta para garantir bons resultados, já que o satélite precisa ter a mesma sensibilidade das estações em superfície para detectar os padrões sazonais da precipitação, gerando o mínimo de falsos positivos. Isso é possível porque, apesar de o SPI ser gerado a partir de dados mensais de precipitação, é um índice padronizado (JESUS et al., 2016).

Para a estação de Recife, o TRMM apresentou correlação espacial de 0,93 para acumulados mensais. No entanto, o satélite subestimou bastante o volume total, especialmente durante o período mais chuvoso. Esse padrão não interferiu no SPI justamente porque a similaridade temporal entre as duas

séries é muito elevada. Após a padronização das precipitações acumuladas mensais, os valores resultantes de SPI foram muito similares em todas as escalas temporais: SPI-1, 3, 6, 12 e 24 (Figura 21).

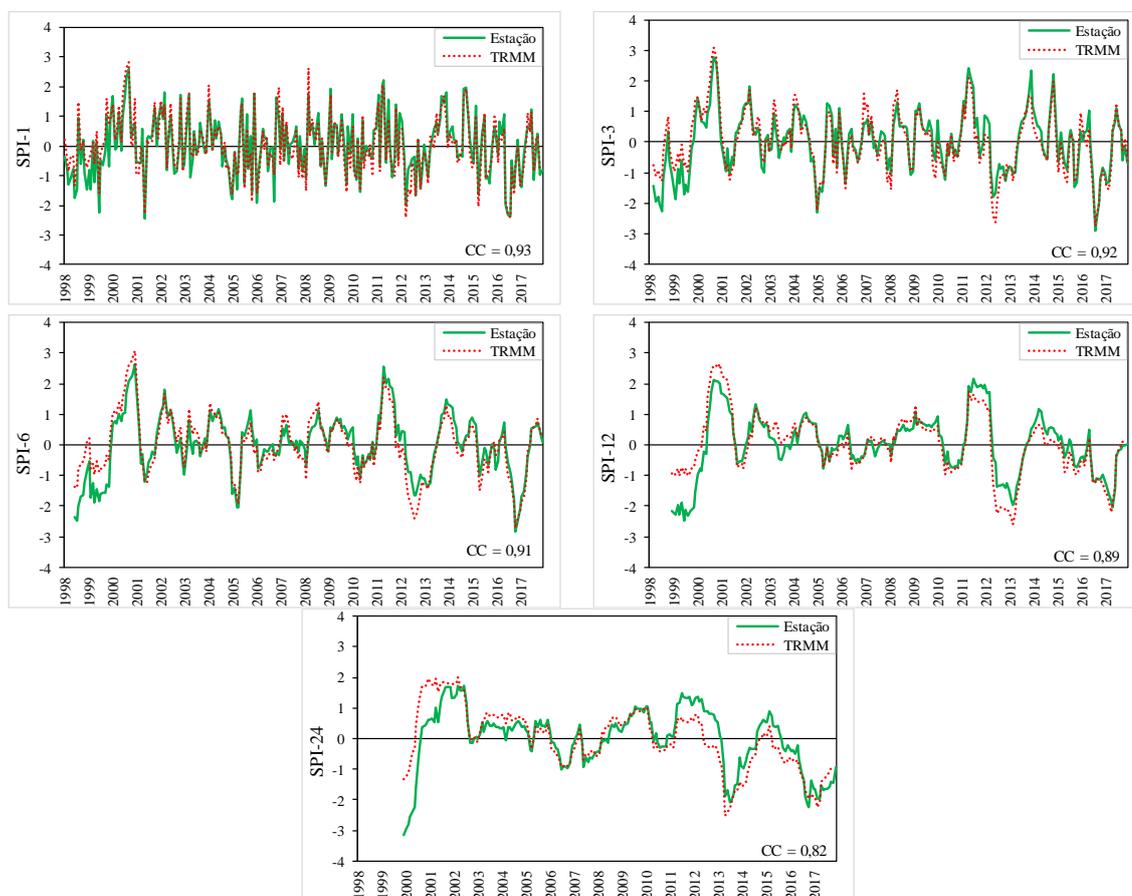


Figura 21. Índice de precipitação padronizada (SPI) para o município de Recife obtido pelo TRMM 3B42V7 e postos pluviométricos em superfície, referente ao período de 1998 a 2017.

Atentando-se apenas à similaridade entre as duas séries e deixando de lado os padrões da seca, por enquanto, é visível a alta similaridade do TRMM com os postos em superfície, especialmente para escalas temporais menores (SPI-1 e SPI-3). A correlação, mesmo se mantendo sempre elevada, tende a diminuir com o aumento da escala temporal. O aumento de tempo do SPI corresponde a uma maior janela de 'meses' utilizados na estimativa da seca. Como o TRMM tendeu a apresentar queda de desempenho na validação anual do volume precipitado, a redução no SPI também pode ter relação com esse padrão.

Na estação de Recife, o TRMM apresentou os maiores valores de coeficiente de correlação – CC (0,96) e de determinação – R^2 (0,93).

Considerando apenas esses índices, o pior cenário foi detectado para a estação de Garanhuns (CC = 0,85; $R^2 = 0,72$). No entanto, mesmo com uma maior diferença no padrão temporal de detecção da seca pelo satélite, o SPI ainda apresenta alta similaridade com os valores obtidos *in situ*, evidenciando o potencial do sensor na detecção de secas. Nesse caso, porém, os valores de CC aumentaram até o SPI-12, passando a reduzir no SPI-24 (Figura 22).

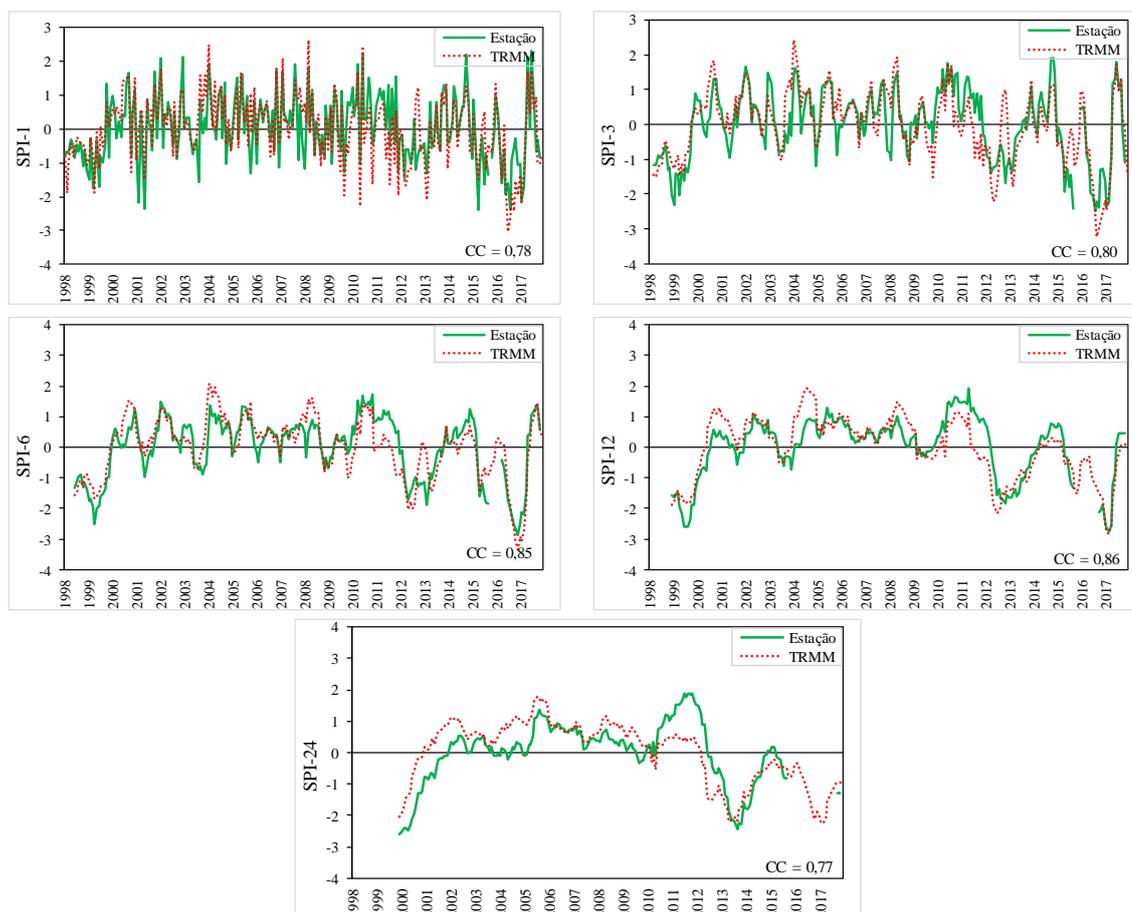


Figura 22. Índice de precipitação padronizada (SPI) para o município de Garanhuns obtido pelo TRMM 3B42V7 e postos pluviométricos, referente ao período de 1998 a 2017.

Vale destacar que a missão do TRMM, apesar de ter sido descontinuada, foi substituída pelo GPM, que continua a coleta de dados globais de precipitação a cada 30 minutos (um avanço em relação à resolução temporal de 3 horas do TRMM). A resolução espacial também passou de ~27 km para ~11 km, possibilitando uma maior espacialização das secas. Obviamente, o potencial do GPM só poderá ser melhor explorado em longo prazo, visto que o satélite ainda não possui uma grande série de dados. No

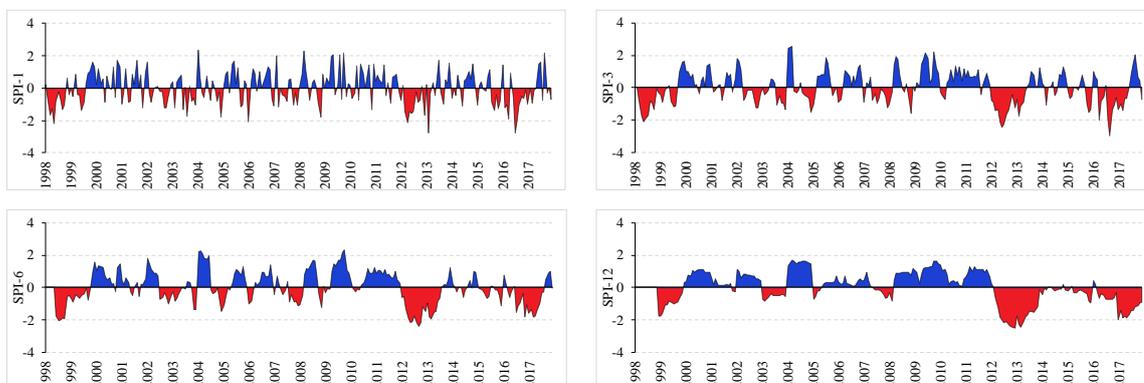
entanto, técnicas de interpolação geoestatística e agregação temporal podem ser usadas para igualar a sua série à do TRMM, estendendo os seus dados.

Nas demais estações, os resultados também foram satisfatórios. Em todos os casos, os coeficientes de correlação foram superiores a 0,7 para todas as escalas de tempo do SPI.

3.9 Incidência e severidade da seca no Estado de Pernambuco com base no produto TRMM 3B42V7

Após validação do SPI obtido pelo TRMM nos sete postos pluviométricos de referência, foram gerados valores médios de SPI para cada mesorregião separadamente e, sem seguida, o SPI médio para todo o estado com base nos pixels do satélite, após interpolação espacial usando o IQD.

O SPI para o São Francisco, mesorregião mais seca do estado, pode ser visualizado na (Figura 23), nas escalas temporais de SPI-1, 3, 6, 12, 24 e 48 meses. O SPI-1 tem grande aplicabilidade para avaliação 'imediate' da seca, especialmente do ponto de vista meteorológico. No entanto, sabe-se que a ausência de chuvas em um curto período também pode comprometer diretamente a produção agrícola. Assim, o SPI variando de 1 a 6 meses também pode trazer grandes informações sobre a seca agrícola dentro desse período (SANTOS et al., 2013). Dentro desse cenário, os SPI para a janela temporal de 1 mês e de 6 meses apresentaram valores mais negativos nos anos de 2012-2013 e 2016-2017 quando se considera a última década da série. Esse período coincide com a grande seca no semiárido brasileiro, que trouxe grandes impactos econômicos e sociais (ROSSATO et al., 2017).



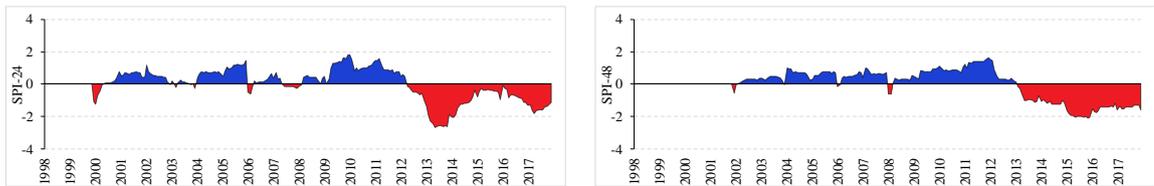
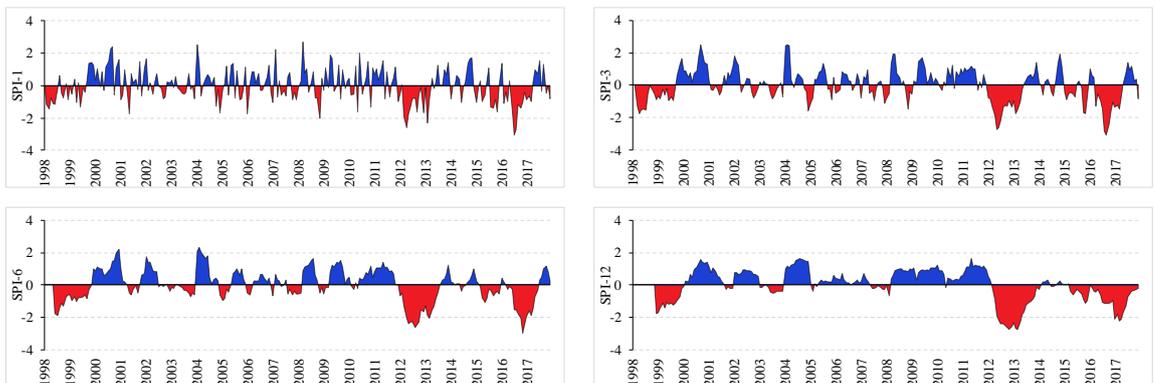


Figura 23. Índice de precipitação padronizada (SPI) médio para a mesorregião do São Francisco obtido pelo TRMM 3B42V7, referente ao período de 1998 a 2017.

Aumentando-se à janela temporal do SPI, nota-se que o período a partir de 2012 foi o mais crítico dos últimos 20 anos. Períodos de SPI maiores que 12 meses refletem padrões de precipitação de longo prazo, sendo utilizados para monitorar a variabilidade anual e interanual, bem como nível de reservatórios e disponibilidade de água, tendo grande destaque do ponto de vista hidrológico.

Considerando todo o Estado de Pernambuco, a situação não é muito diferente quando se considera a média espacial do SPI. Cerca de 80% do território encontra-se inserido no semiárido (GALVÍNCIO e MOURA, 2005), que foi severamente afetado pelo déficit hídrico iniciado em 2012 (Figura 24). Mesmo a região inserida na Zona da Mata e Litoral sentiu os impactos da escassez hídrica vivenciada nesse período. Assim, é esperado que o SPI tenha uma distribuição similar em todo o estado. Esse padrão pode ser percebido até mesmo se o índice for calculado pixel a pixel a partir dos dados do TRMM. A sensibilidade do SPI é a mesma, independente de a região ser mais ou menos chuvosa, já que o índice compara o valor acumulado de precipitação atual com aquele registrado na média dos últimos 20 anos para o mesmo período. Como toda a região Nordeste apresentou redução nos índices pluviométricos a partir de 2012, toda ela também passou por períodos mais secos nesse período quando comparado à média histórica.



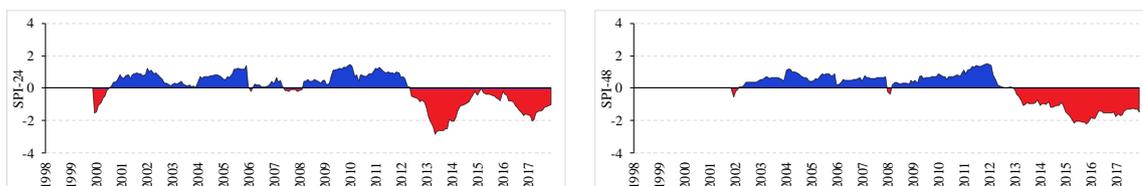
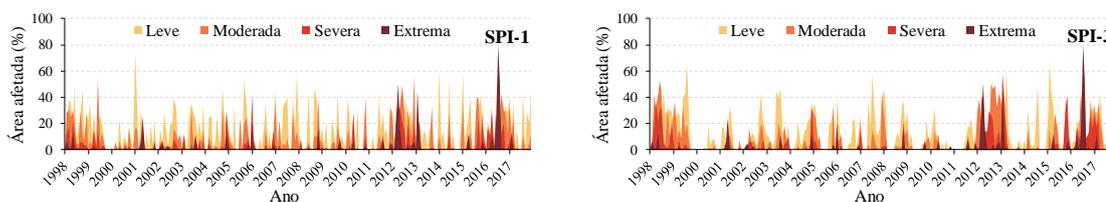


Figura 24. Índice de precipitação padronizada (SPI) médio para Estado de Pernambuco obtido pelo TRMM 3B42V7, referente ao período de 1998 a 2017.

Ao longo dos 20 anos utilizados para avaliação da seca, todo o estado foi afetado em diferentes magnitudes. Em alguns meses a precipitação foi maior do que o registrado na média histórica. Com isso, houve predomínio de meses úmidos. Em outros meses, o volume precipitado foi inferior à média histórica, caracterizando meses levemente secos a extremamente secos. Um mês considerado úmido para um determinado tempo de SPI, no entanto, pode ser severamente seco em outra janela temporal. Isso ocorre porque os ‘tempos’ do SPI correspondem à quantidade de meses que são utilizados na normalização do índice. O SPI-1 do mês de janeiro, por exemplo, compara a precipitação do mês atual com a média de todas as demais precipitações do mesmo mês, para toda a série. Já o SPI-12 para janeiro, compara o mês atual com a média dos 11 meses anteriores.

Para os SPI-1 e 3, nota-se que ocorreram secas em Pernambuco para quase todos os meses da série. Essas secas foram predominantemente leves a moderadas até o ano de 2011. Quando se iniciou a grande crise hídrica de 2012, a seca passou a ser majoritariamente severa e atingiu grande quantidade do território do estado, chegando a 80% de área afetada em determinados momentos (Figura 25). Conforme discutido anteriormente, os SPI-1 a 6 meses estão relacionados às secas que podem causar grande impacto na agricultura e pecuária. De fato, nos anos de 2012 e 2013, foram grandes as quedas de produtividades em todas as lavouras temporárias no semiárido, incluindo grãos (milho e feijão), tubérculos (mandioca) e leite. Essa queda foi percebida em todos os estados do Nordeste (MARTINS e MAGALHÃES, 2015).



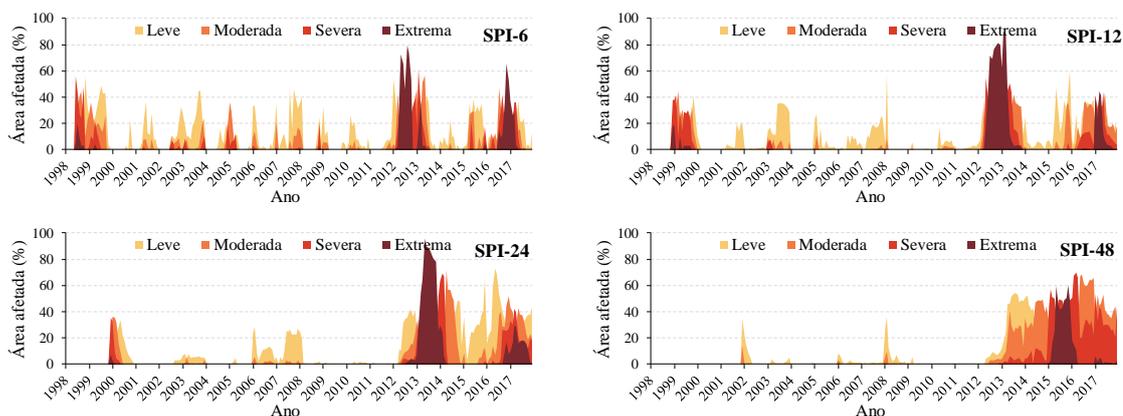


Figura 25. Percentual de área afetada por secas em Pernambuco entre os anos de 1998 a 2017.

Secas de intervalos maiores (SPI-12, 24 e 48) já passam a ganhar mais destaque do ponto de vista hidrológico e meteorológico, com maior ênfase na distribuição anual da precipitação e disponibilidade de água. Assim, a grande quantidade de área seca a partir de 2012 evidencia que o semiárido passou, de fato, por uma grave crise hídrica nesse período, chegando a quase 100% da área afetada severamente em alguns meses. Rossato et al. (2017), avaliando o impacto das secas em todo o Brasil a partir do ano de 2000 usando o Índice de Severidade da Seca de Palmer (PDSI), detectaram que o Nordeste Brasileiro sofreu severamente e em grande quantidade de área a partir do ano de 2012.

A evolução da seca no ano de 2012 pode ser observada na Figura 26 para o SPI-12. Vale destacar que, nessa escala de tempo, a precipitação acumulada em um determinado mês é comparada com a precipitação média antecedente dos 11 meses anteriores, em cada ano da série. Dessa forma, o índice indica que, dentro do SPI-12, a seca teve início no mês de março de 2012 e foi crescendo em proporção e intensidade. Nos meses de novembro e dezembro, os mais secos do ano, a seca já tinha atingido proporções extremas em quase toda a área de Pernambuco, sendo que já a partir de maio todo o estado estava enfrentando uma grave crise, mesmo o litoral e Zona da Mata. A seca permaneceu em grande intensidade até o primeiro semestre de 2013, quando passou a reduzir, porém continuando persistente. Nos anos seguintes (2014, 2015, 2016), ainda presente no Estado, apresentou intensidade de leve a extrema, voltando a atingir proporções severas no primeiro semestre de 2017 em diferentes regiões.

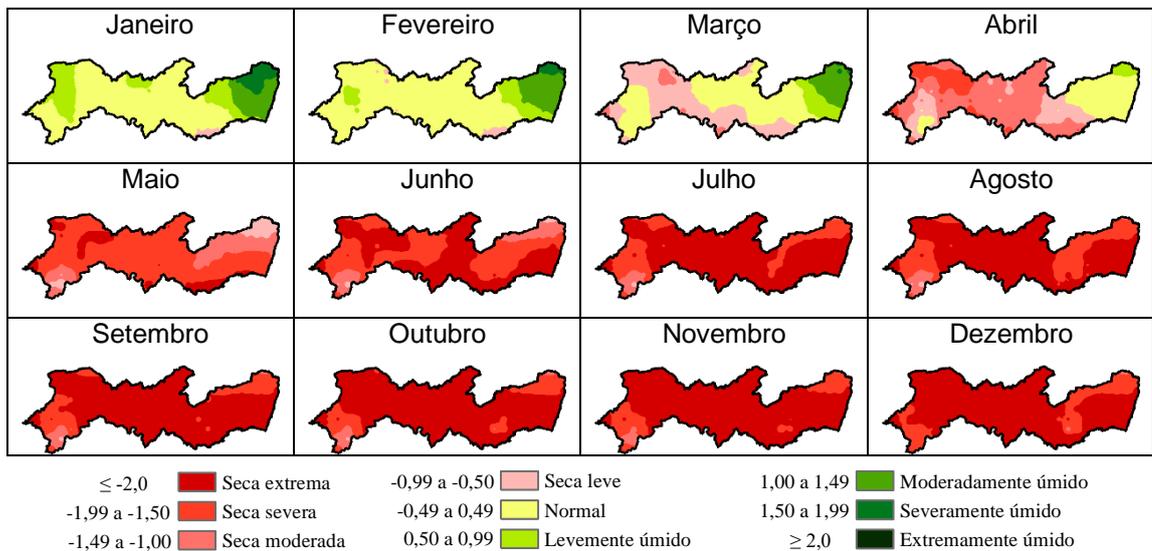


Figura 26. Monitoramento de seca baseado no SPI-12 obtido pelo produto TRMM 3B42V7 no Estado de Pernambuco, para o ano de 2012.

O SPI-24 está normalmente ligado a fluxos de água, níveis de reservatórios e até mesmo níveis de água subterrânea em escalas de tempo mais longas. Em algumas localidades, O SPI-24 também pode estar fortemente relacionado ao PDSI, e os dois índices podem refletir condições similares ou análogas.

Para o estado de Pernambuco, a seca iniciada em 2012 passou a causar maiores impactos do ponto de vista hidrológico a partir do ano de 2013, com base no SPI-24 (Figura 27). Obviamente, a severidade da seca no ano anterior não deixou de trazer consequências devastadoras, mas em maior expressividade na distribuição deficitária da precipitação (com base no SPI-12) e atividades agropecuárias (SPI-1, 3 e 6). Em escala de tempo maior, o comprometimento do prolongamento da seca nos níveis de rios e reservatórios passou a ganhar mais destaque a partir do ano de 2013. Dessa forma, fica clara a necessidade de avaliar o SPI em diferentes escalas de tempo e com base no objetivo do estudo (monitoramento de seca meteorológica, agrícola ou hidrológica). Obviamente, índices de seca baseados na umidade do solo esclarecem com maior precisão e em menores períodos de tempo acerca da disponibilidade de água no solo para as plantas, a exemplo do Índice Padronizado de Umidade do Solo (SSI), também obtido por sensoriamento remoto a partir de dados do satélite *Soil Moisture Active Passive* (SMAP), da NASA (XU et al., 2018). No entanto, o SPI não deixa de representar um grande

potencial, especialmente em regiões semiáridas e com reduzida disponibilidade de dados.

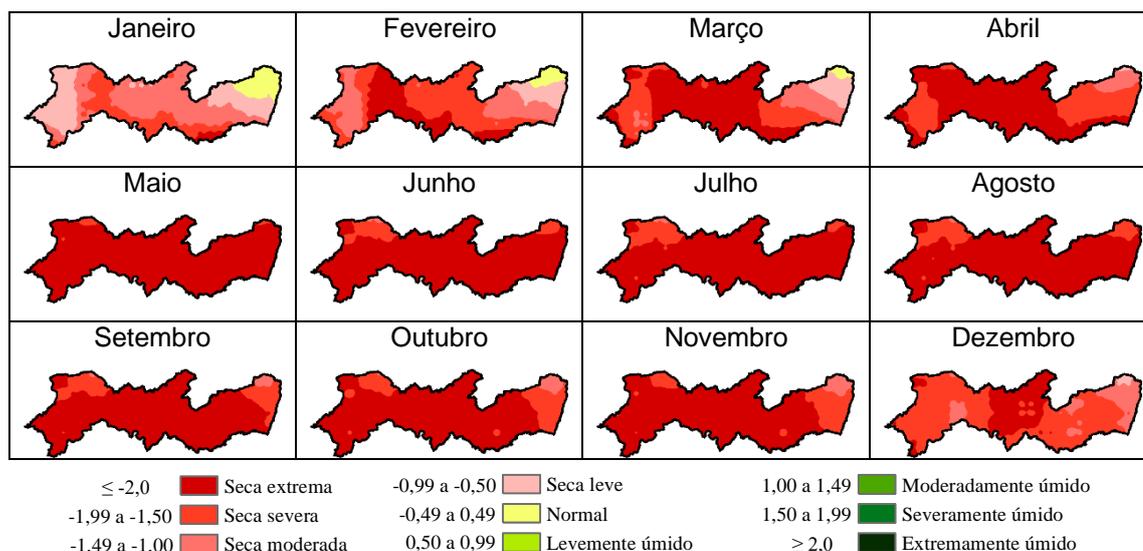


Figura 27. Monitoramento de seca baseado no SPI-24 obtido pelo produto TRMM 3B42V7 no Estado de Pernambuco, para o ano de 2013.

3.10 Anomalias climáticas

O SPI é um índice bastante utilizado por ser de simples aplicação e grande utilidade, já que dá uma visão geral da seca em diferentes passos de tempo. Assim, no SPI-1 são evidenciados os efeitos mais imediatos da seca; já no SPI-24, são refletidos os impactos que a seca causou meses depois, especialmente do ponto de vista hidrológico. Além disso, o SPI possui boa concordância com outros índices que usam dados adicionais, como o SPEI, por exemplo, que agrega também séries de temperatura para estimativa da evapotranspiração.

No entanto, para dar uma visão mais clara da seca ao longo dos 20 anos da série disponibilizada pelo TRMM, foram gerados mapas de anomalias de precipitação anuais, destacando (em porcentagem), os períodos em que as chuvas excederam ou foram inferiores à média histórica. Essa aplicação é também necessária para confirmar se o satélite, sem uma climatologia de 30 anos completa, consegue espacializar a seca corretamente, principalmente para o período crítico de 2012 a 2017.

Com base no mapa de anomalias de precipitação anual (Figura 28), é possível perceber o mesmo padrão de secas e cheias identificado pelo SPI.

Dois períodos de seca foram críticos para a série: 1998 a 2012. De fato, 1998 também foi um ano bastante seco, embora não tão crítico quanto 2012. Khan et al. (2005) enfatizam que, embora a seca de 1998 tenha sido anunciada com um ano de antecedência, ainda atingiu mais de 10 milhões de pessoas no Nordeste, principalmente no semiárido. Ainda de acordo com os autores, o ano de 2001 também foi seco, trazendo impactos em diversos setores. Comparando as anomalias com o SPI-12 (mesma escala temporal), existe grande similaridade no padrão. Em 2012 foi registrada seca severa, que reduziu a intensidade, mas manteve-se em 2013. Em 2014 a seca regrediu e a precipitação aproximou-se da normal em grande parte do estado. Porém, como não houve excedentes pluviométricos, os impactos resultantes dos anos anteriores se mantiveram. Em 2015 a seca dá sinais de retorno, atingindo picos, novamente, em 2017 e afligindo severamente a mesorregião do Sertão do São Francisco.

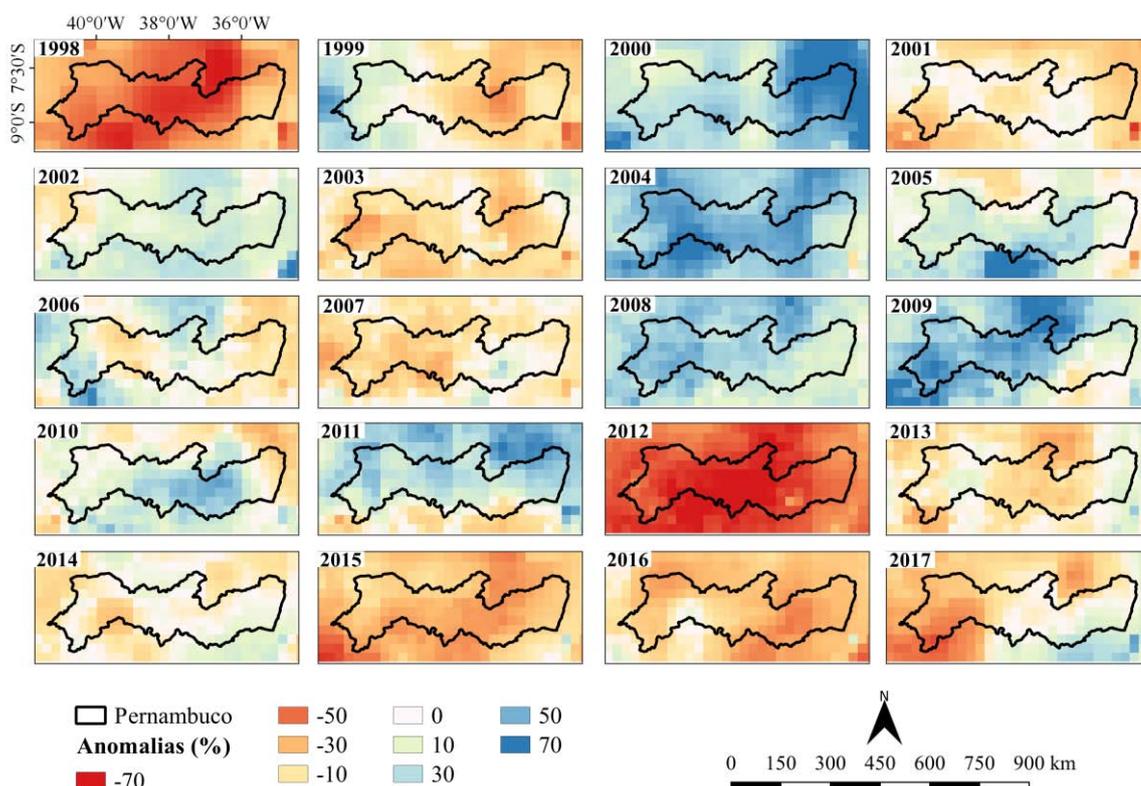


Figura 28. Anomalias de precipitação obtidas pelo TRMM para o período de 1998 a 2017.

As anomalias deixam claro que o TRMM consegue expressar os eventos de seca de forma satisfatória, inclusive em escala de mesorregião, em concordância com relatos presentes na literatura. Esse é um grande ponto positivo do satélite, que ainda não possui uma série de precipitação longa (> 30

anos). Além disso, o TRMM apresenta algumas limitações de resolução espacial (0,25 graus) e temporal (3 horas). Essa última, especialmente, poderia ser uma grande limitante para a detecção adequada de eventos de chuva com alta intensidade e curta duração, comuns no semiárido.

A climatologia de variáveis atmosféricas é padronizada com base em observações de no mínimo 30 anos, que caracterizam as Normais Climatológicas, segundo a Organização Meteorológica Mundial (OMM). Nesse sentido, apesar de o TRMM ter modelado adequadamente a seca quando comparado com os dados mensurados *in situ* para o mesmo período (1998-2017), o satélite ainda não possui uma série completa de 30 anos que caracterize com precisão o padrão sazonal das chuvas. Apesar disso, a OMM recomenda que, caso não seja possível trabalhar com registros longos de 30 anos, sejam utilizadas as Normais Climatológicas Provisórias (NCP), que devem ser computadas com no mínimo 10 anos de dados, começando em 1º de janeiro dos anos que terminem com o dígito 1. No caso do TRMM, somente o período de 1º de janeiro de 2001 a 31 de dezembro de 2018 (18 anos) já atende a esse requisito (REBOITA e KRUSCHE, 2018).

Outra possível limitação do TRMM, já citada, é a baixa resolução espacial, de aproximadamente ~27 km. Para estudos pontuais ou em pequenas áreas, seu uso pode ser inviabilizado. Nesse caso, outras fontes de dados podem ser avaliadas para um possível uso, como o CHIRPS, com resolução espacial de ~5 km. Esse último, no entanto, é uma 'compilação' de diferentes fontes de dados que incluem o próprio TRMM e registros de superfície. A baixa resolução espacial do TRMM, no caso do Estado de Pernambuco, não representou um problema para a estimativa de seca mesmo em escala pontual. Quando o valor médio gerado pelo pixel de ~729 km² foi comparado com o valor calculado a partir dos registros do posto pluviométrico, que é pontual, os coeficientes de correlação foram sempre elevados, com o valor mínimo de 0,70 para o SPI-1 na estação de Cabrobó. A alta correlação entre valores estimados e observados de SPI, naturalmente, indicam que o TRMM também estima de forma adequada as anomalias anuais de precipitação.

Além disso, existe a resolução temporal de 3 h., que para estudos de seca não é uma grande limitante, mas pode ser importante em outras aplicações, como a modelagem hidrológica. Essa resolução temporal pode não

ser suficiente para perceber eventos de alta intensidade e curta duração. Pensando nisso, a NASA aumentou a resolução temporal do GPM, sucessor do TRMM, para 30 min. O que representa um grande salto. A resolução espacial também passou a ser de ~11 km. Obviamente, essa nova configuração favorecerá ainda mais os estudos de seca, agora em escala global.

Considerando principalmente a limitação de resolução espacial do TRMM, as anomalias, para o mesmo período, foram geradas utilizando o *Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS), que possui resolução espacial de ~5 km. Embora não tenha sido validado nesse estudo, a aplicação com o CHIRPS tem o intuito apenas de comparar os resultados gerados pelo TRMM e verificar a consistência dessas informações frente a outra fonte de dados. Para tornar as comparações mais adequadas, os pixels não foram interpolados usando o inverso do quadrado da distância (IQD) para suavizar e tornar a superfície contínua, como ocorreu com o TRMM nas etapas anteriores. Por isso, optou-se por gerar mapas dos dois produtos com a resolução nativa.

O CHIRPS mensura a precipitação continental em escala global. Ao contrário do TRMM, não estima os eventos sobre os oceanos. O principal objetivo do CHIRPS é a utilização dos dados em estudos sazonais de precipitação e estimativa de seca. Como a resolução temporal é diária, algumas aplicações que requerem dados em menor espaço temporal, como modelagem hidrológica, podem ficar comprometidas. Além disso, o CHIRPS não é um satélite ou sensor orbital. Trata-se de um produto gerado a partir de diversas fontes de dados, incluindo o próprio TRMM e estações em superfície (FUNK et al., 2015; LIMA et al., 2018; SHRESTHA et al., 2017).

As anomalias estimadas com o CHIRPS (Figura 29) seguem o padrão exato do TRMM em quase todos os anos. Em alguns períodos, como 2014, por exemplo, embora similar, a espacialização é um pouco diferente. O CHIRPS detecta anomalias mais positivas no Sertão e São Francisco do que o TRMM. Esse produto, no entanto, não foi validado com dados em superfície. Os mapas gerados têm efeito puramente comparativo, dada a sua maior resolução temporal. Dinku et al. (2018) ainda enfatizam que, por utilizar dados de estações em superfície na estimativa da precipitação, o CHIRPS pode

apresentar algumas heterogeneidades em algumas partes do globo onde a disponibilidade de dados dos postos é inconsistente ou falha ao longo do tempo. Como o produto não estima a precipitação nos oceanos, os dados nessas áreas não apresentam dado (em branco).

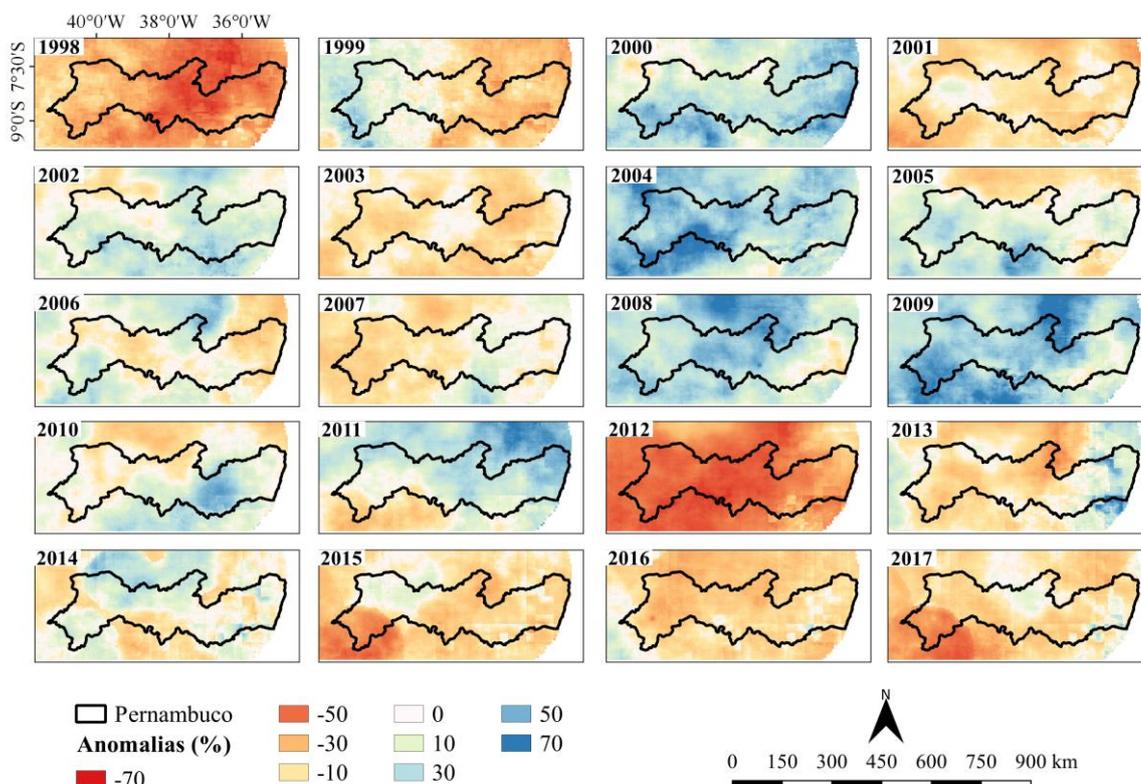


Figura 29. Anomalias de precipitação obtidas pelo CHIRPS para o período de 1998 a 2017.

Uma análise comparativa baseada na correlação espacial das duas séries (TRMM e CHIRPS) foi realizada para evidenciar o grau de agregação dos produtos (Figura 30). Por possuir maior resolução espacial, as imagens do CHIRPS foram reamostradas para a mesma resolução espacial do TRMM (~27 km) através de interpolação bilinear. Após isso, os pixels dos produtos foram alinhados para que os centroides coincidisse, se sobrepondo, de forma a evitar viés na análise. A comparação foi feita para um ano chuvoso (2004) em relação à série e um ano seco (2012), permitindo detectar as discrepâncias em duas condições distintas.

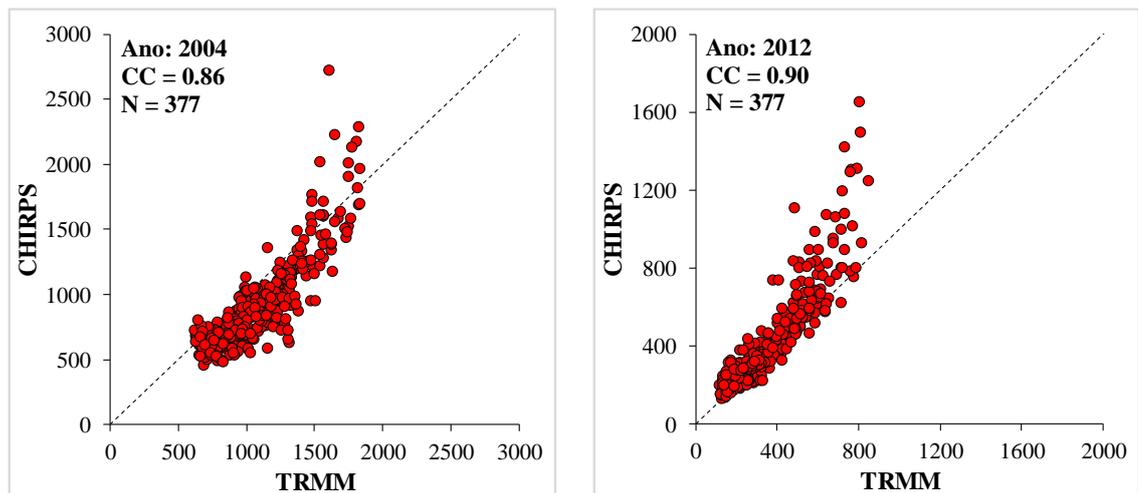


Figura 30. Comparação dos dados de precipitação do TRMM e CHIRPS para os anos de 2004 e 2012.

A correlação entre os dados estimados pelo TRMM e CHIRPS é alta ($p < 0,005$). Em alguns pixels, no entanto, o CHIRPS tende a superestimar a precipitação média anual em relação ao TRMM. Os maiores valores superestimados pelo CHIRPS foram encontrados em alguns pixels na faixa costeira e Zona da Mata; no restante do Estado, as diferenças foram pouco expressivas. Essa variação de estimativa é justificada porque o CHIRPS utiliza dados de superfície não apenas para calibração (como o TRMM), mas como parte de sua série. Essa discrepância, no entanto, só é percebida em condições de alto volume precipitado, sendo mais evidente para precipitações anuais acima de 1500 mm (2004) e 900 mm (2012).

Uma outra forma de confirmar os resultados gerados pelo TRMM, tanto pelo SPI quanto pelas anomalias, é utilizar algum índice biofísico que responde à presença de chuvas. Os mais comumente utilizados são os índices de vegetação, que permitem monitorar a condição de cobertura da Terra em escala global ou local. O mais difundido é o *Normalized Difference Vegetation Index* (NDVI), que deve ser avaliado em diferentes datas para que seja notada a resposta da vegetação a variadas condições de regimes pluviométricos (ZANZARINI et al., 2013). O monitoramento contínuo do NDVI e sua relação com a presença de chuvas é ainda mais necessário em regiões semiáridas, considerando que esse índice, indiretamente, fornece informações sobre as condições de umidade do solo (BEZERRA et al., 2014).

Assim como ocorreu na avaliação do TRMM em conjunto com o CHIRPS, as resoluções nativas dos produtos TRMM e NDVI foram mantidas

para permitir melhor visualização dos padrões espaciais. O produto de NDVI utilizado foi obtido a partir do *Moderate-Resolution Imaging Spectroradiometer* (MODIS - Terra), da NASA, com resolução espacial de ~5 km (MOD13C2). Os produtos referem-se à composição média de um mês, que foram agregadas para obtenção de um valor médio anual, em cada pixel. Após isso, as anomalias foram calculadas. Como o MODIS só passou a fornecer dados a partir de fevereiro de 2000, as anomalias do NDVI foram obtidas para esse período (Figura 31).

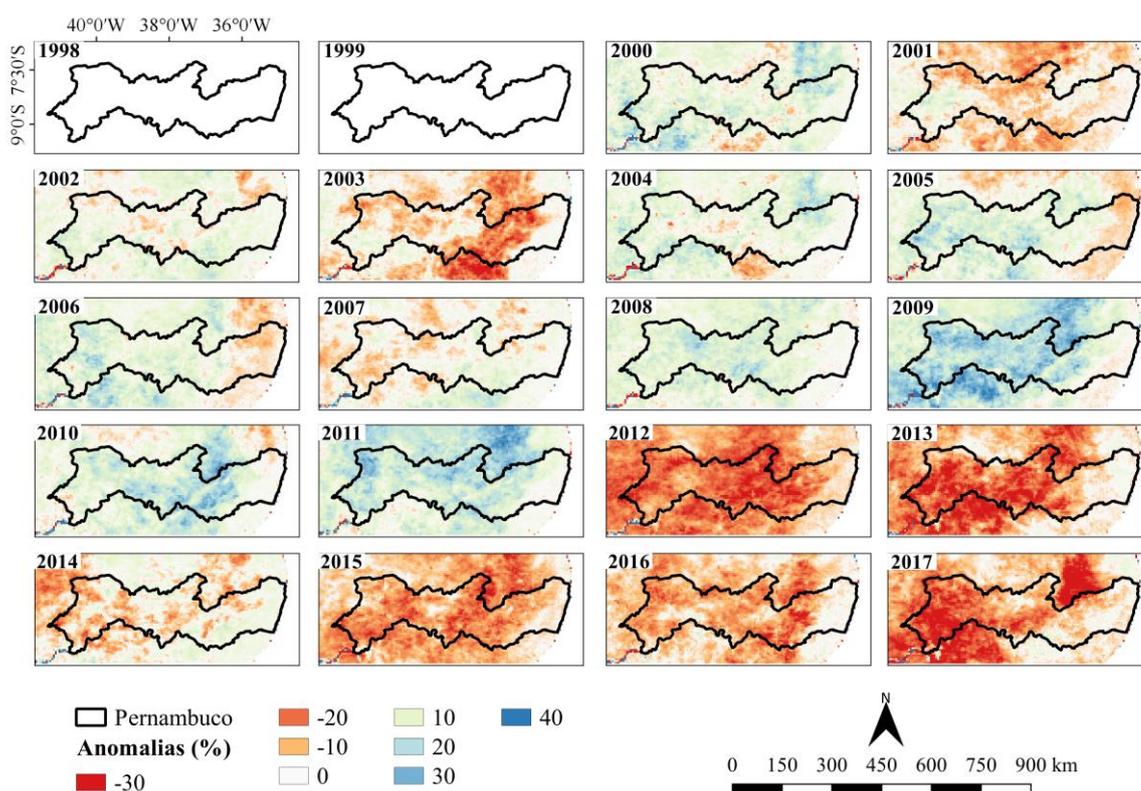


Figura 31. Anomalias de NDVI obtidas pelo produto MOD13C2 para o período de fevereiro de 2000 a dezembro de 2017.

Devido à limitação da série de NDVI, não é possível perceber os impactos que a seca de 1998 trouxe sobre a vegetação e o processo regenerativo do ano seguinte. No entanto, fica claro que as anomalias do NDVI são tidas como ‘espelhos’ das anomalias de precipitação, indicando a forte similaridade entre as duas séries. Isso indica que o vigor vegetal responde de forma direta à presença ou ausência de chuvas, e esse padrão pode ser visualizado ainda com mais clareza por se tratar de anomalia anual. Se menores intervalos fossem selecionados (ex.: 7 dias), talvez não fosse possível visualizar essa dinâmica com tanta clareza, visto que o NDVI responde de

forma levemente tardia à precipitação, já que a regeneração vegetal não é imediata, embora seja rápida, especialmente na Caatinga.

Além de indicar a forte relação entre a dinâmica vegetal e as chuvas, esse resultado também evidencia, novamente, o elevado potencial do TRMM para aplicação em estudos de seca, mesmo nas condições climáticas discrepantes do Estado de Pernambuco. É interessante notar, por exemplo, que no ano de 2012 houve forte redução nos valores de NDVI em relação à média histórica em decorrência dos menores valores de precipitação. Embora do ponto de vista pluviométrico a condição de seca tenha reduzido levemente em 2013, as chuvas ainda não foram suficientes para reverter o processo de seca da vegetação, o que causou uma leve acentuação da severidade do fenômeno do ponto de vista agrícola. Desse modo, o ano de 2013 reflete ainda de forma mais intensa, no Sertão e São Francisco, a severa seca registrada no ano anterior.

A correlação entre dados de precipitação e NDVI já foi amplamente estudada e comprovada, inclusive com o TRMM (LIU et al., 2017; SOFUE et al., 2018). Essa alta correlação é bastante explorada para realizar o “*downscaling*” dos dados do satélite para resoluções espaciais menores (ZHANG et al., 2017). O NDVI é um dos principais dados utilizados nesse processo. Para permitir melhor avaliação do TRMM em comparação ao produto de NDVI do MODIS, o segundo também foi reamostrado para a mesma resolução espacial do primeiro, assim como ocorreu com o CHIRPS (Figura 32).

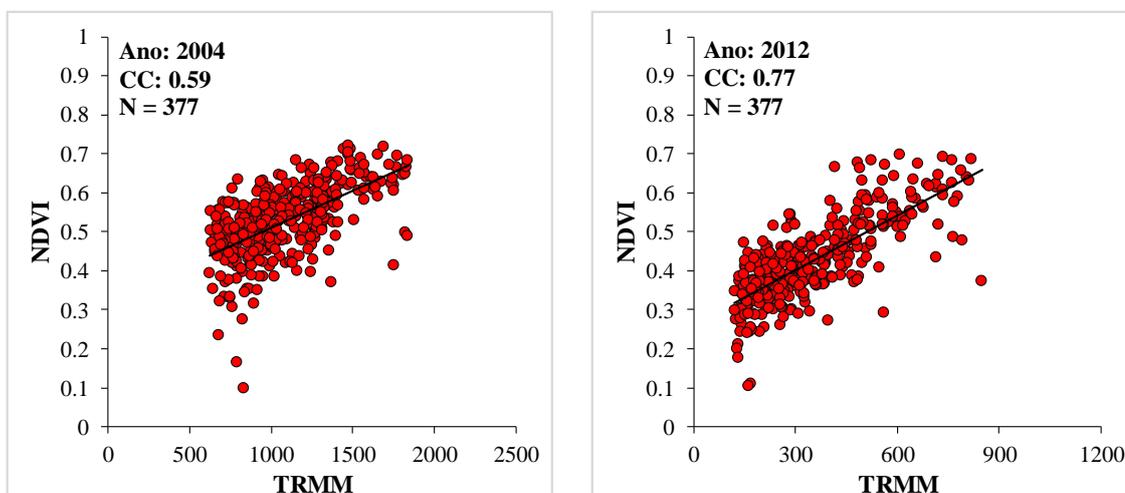


Figura 32. Comparação dos dados de precipitação do TRMM e NDVI, do MODIS, para os anos de 2004 e 2012.

Maior correlação foi registrada no ano de 2012, durante o período seco. Esse padrão pode ser justificado porque nesse período a precipitação foi baixa, atingindo volumes muito aquém da média histórica. Em consequência, a vegetação também não obteve aumento do vigor de forma expressiva. Isso levou a um padrão de variação temporal mais similar entre as duas séries. No ano chuvoso, o maior volume de chuvas pode ter ocasionado aumento de vigor vegetal de forma mais desigual, a depender do tipo de uso do solo, o que interferiu no valor do coeficiente de correlação, que passou de 0,59 em 2004 para 0,70 em 2012 ($p < 0,005$). Em alguns poucos pixels, o NDVI permanece baixo e parece não responder satisfatoriamente à precipitação. Vale ressaltar que esse índice tem está relacionado ao vigor vegetal, e o produto do MODIS possui alta resolução espacial. É possível que, nesses pixels, o uso do solo não seja caracterizado por condições marcantes de vegetação, por isso o volume precipitação não garantiu aumento do NDVI, como ocorreu no restante do estado. Isso fica ainda mais nítido porque os pixels que apresentaram esse comportamento estão localizados na região semiárida e foram os mesmos para os dois períodos.

4 CONCLUSÕES

O TRMM evidenciou grande potencial para representar a dinâmica espacial e temporal da precipitação no Estado de Pernambuco, além de detectar adequadamente eventos de seca, seja por meio do índice de precipitação padronizada (SPI), em diferentes escalas temporais, ou através de anomalias anuais.

Além da validação com dados registrados em superfície, o TRMM também teve sua eficiência confirmada quando confrontado com dados de precipitação do CHIRPS (com melhor resolução espacial) e de vigor vegetal, por meio do NDVI, que evidenciaram a sensibilidade do satélite em perceber mínimas variações espaciais e temporais no regime de chuvas. Essa característica permite que o TRMM seja utilizado em substituição aos dados de superfície quando estes não estiverem disponíveis. No entanto, a depender da aplicação, uma correção de tendências pode ser necessária, especialmente no Litoral, onde os eventos são subestimados pelo satélite.

É importante ressaltar que dentre as ações do Plano Nacional de Segurança Hídrica (PNSH), está o monitoramento contínuo de eventos extremos que possam afetar o acesso à água, especialmente na região Nordeste, que é a mais impactada pelo déficit hídrico. Sendo assim, ações que envolvam o monitoramento de eventos de seca são essenciais por favorecerem a gestão de riscos, contribuindo com o gerenciamento dos recursos hídricos. Por conta disso, estudos com TRMM ou outros satélites que monitoram a precipitação são essenciais no semiárido.

CAPÍTULO III

**VALIDAÇÃO DA PRECIPITAÇÃO ESTIMADA PELOS PRODUTOS
TRMM 3B43 E GPM 3IMERGM NO ESTADO DE PERNAMBUCO**

Validação dos dados de precipitação estimados pelos produtos TRMM 3B43V7 e GPM 3IMERGM no estado de Pernambuco

RESUMO: muitos satélites destinados a monitorar a precipitação têm sido lançados nos últimos anos. Esse estudo objetivou verificar o desempenho dos dados de precipitação estimados pelas missões TRMM (*Tropical Rainfall Measuring Mission*) e GPM (*Global Precipitation Measurement*). Foram utilizados os produtos mais recentes dos dois satélites e 144 pluviômetros como referência para validação. As avaliações ocorreram em escala mensal, em todo o estado de Pernambuco, durante o período de 2015 a 2017. Os resultados indicaram que: (1) tanto o TRMM quanto o GPM apresentam similaridade com os dados mensurados in situ, com coeficientes de correlação superiores a 0,84, embora tendam a superestimar a precipitação nas mesorregiões menos chuvosas e subestimar no litoral do Estado; (2) além do volume de chuvas, a topografia influenciou a qualidade das estimativas, com erros significativos no litoral, onde a altitude é próxima de zero; (3) os satélites possuem probabilidade de detecção (POD) de eventos de chuva acima de 96%, mas tendem a emitir falsos alarmes (FAR) no Sertão e São Francisco, especialmente o GPM. Os dois produtos são bastante similares em termos de desempenho e podem ser utilizados, isoladamente ou em conjunto, para preenchimento de falhas ou em aplicações hidrológicas, requerendo atenção na correção de tendências.

Palavras-chave: sensoriamento remoto, satélites, chuva, validação, semiárido.

Validation of rainfall data estimated by TRMM 3B43V7 and GPM 3IMERGM products over the state of Pernambuco

ABSTRACT: many satellites designed to monitor rainfall data have been launched in recent years. This study aimed to verify the performance of rainfall data estimated by TRMM (Tropical Rainfall Measuring Mission) and GPM (Global Precipitation Measurement) missions. The most recent products of the two satellites were used, as well as 144 rain gauges as reference for validation. The results showed that: (1) both TRMM and GPM showed similarity with in situ data, with correlation coefficients above 0.84, although they tend to overestimate rainfall in less rainy mesoregions and underestimate on the state's coastline; (2) in addition to the volume of rainfall, the topography influenced the quality of the estimates, with significant errors on the coast, where the altitude is close to zero; (3) the satellites have high probability of detection (POD) of rainfall events above 96%, although they tend to emit false alarms (FAR) in the Sertão and São Francisco mesoregions, especially GPM. The two products are quite similar in performance and can be used either alone or in combination to fill gaps in rainfall data or in hydrological applications, requiring attention in correcting trends.

Keywords: remote sensing, satellites, rain, validation, semiarid.

1 INTRODUÇÃO

A precipitação é uma componente essencial nos ciclos da água e energia e exerce papel importante em muitos campos de pesquisa, como hidrologia, meteorologia e climatologia (CHEN et al., 2018; PRAKASH et al., 2017). Por ser um dos principais atributos hidrológicos, a precipitação é utilizada em diversas aplicações, como o monitoramento de secas (ROSSATO et al., 2017), simulação de diferentes cenários a partir de modelagem (REN et al., 2018; TUO et al., 2016) e estimativa de produção agrícola (RAMESH e VISHNU, 2015).

Em regiões situadas em áreas de risco, como é o caso do Nordeste Brasileiro, a compreensão espacial e temporal da dinâmica da precipitação é ainda mais necessária. Desde 2012, o Nordeste enfrenta uma grave crise hídrica, com taxas de precipitação pluviométrica e água armazenada no solo inferiores aos registrados nos últimos 30 anos. De fato, a região Nordeste é caracterizada pela alta vulnerabilidade à seca, com um longo histórico de fome, migração e problemas sociais (MARENGO et al., 2013; ROSSATO et al., 2017).

Medições precisas e confiáveis de dados de precipitação representam um grande desafio, considerando as recentes ou escassas redes de monitoramento em campo aliadas à alta variabilidade espacial e temporal desse tipo de evento, especialmente sobre oceanos e regiões com variações topográficas significantes (LU et al., 2018). Além disso, a precipitação obtida em campo, a partir de uma estação, em geral representa uma área de aproximadamente 10-100 km², principalmente em regiões remotas (Chao et al., 2018), o que pode levar a grandes incertezas, ao passo que dados obtidos por outras fontes, como sensores orbitais, podem representar uma área uniforme de até 5 km² com cobertura global (AADHAR e MISHRA, 2017). Outro aspecto negativo das redes de monitoramento em campo é que, em muitos casos, há irregularidade e falha na coleta de dados, tornando-os pouco aplicáveis ou representativos (GITHUNGO et al., 2016).

Em um esforço global para minimizar problemas decorrentes da escassez de redes de monitoramento, nos últimos anos diversos satélites e missões dedicadas a monitorar a precipitação, com variadas resoluções

espacial e temporal, foram lançadas e fornecem dados de acesso livre ao público. Dentre eles, podem ser citados o *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks* (PERSIANN) (NGUYEN et al., 2018); o *Climate Prediction Center* (CPC) morphing technique (CMORPH) (XIE et al., 2017); o *Climate Hazard Group InfraRed Precipitation Satellite* (CHIRPS) (BAI et al., 2018b); o *Tropical Rainfall Measuring Mission* (TRMM) *Multi-satellite Precipitation Analysis* (TMPA) (ANJOS et al., 2017) e o *Integrated Multi-Satellite Retrievals* (IMERG), da missão *Global Precipitation Measurement* (GPM) (CHEN et al., 2018).

O GPM IMERG é um dos satélites mais recentes destinados a monitorar a precipitação, com altíssima resolução espacial ($0,1^\circ \times 0,1^\circ$) e temporal (30 minutos). Lançado em fevereiro de 2014, é resultado de uma sólida parceria entre a Administração Nacional da Aeronáutica e Espaço (NASA) e a Agência Japonesa de Exploração Aeroespacial (JAXA), mantida desde o lançamento da primeira missão com a mesma finalidade, em 1997, porém concentrada no satélite TRMM (XU et al., 2017). O grande sucesso do TRMM, que apresenta resoluções espacial e temporal de $0,25^\circ \times 0,25^\circ$ e 3 horas, respectivamente, levou ao lançamento do GPM antes mesmo ser encerrada a missão anterior, garantindo continuidade dos dados. Ambos os satélites possuem produtos com diferentes resoluções temporais, formados a partir de composições dos dados originalmente coletados (REN et al., 2018).

Tanto o TRMM quanto o GPM já foram validados com bons resultados em áreas com diferentes regimes pluviométricos e variadas condições climáticas (SOARES et al., 2016; TAN e DUAN, 2017), embora a melhor performance do GPM não seja sempre percebida em relação ao TRMM. Wang et al. (2017), avaliando o desempenho dos dois satélites, na China, notaram que o GPM, em geral, apresentou menores erros e melhor poder de detecção de eventos devido à maior resolução temporal, especialmente no período mais seco. No entanto, em termos de correlação, tende a ser um pouco inferior ao TRMM. Xu et al. (2017), em estudo realizado dentro de uma área densamente equipada com pluviômetros no Planalto do Tibete, constataram que o GPM responde melhor que o TRMM em regiões bastante elevadas, sendo o inverso verdadeiro para áreas menos elevadas. Tan & Duan (2017), utilizando uma série de métricas para avaliação dos satélites na Singapura, categoricamente

concluíram que os produtos de diferentes resoluções temporais do GPM não apresentam melhorias significativas quando comparados com os mesmos produtos do TRMM.

Considerando se tratar de um satélite relativamente recente e com tendência a apresentar variações de desempenho em diferentes regiões quando comparado ao TRMM, o objetivo desse estudo foi realizar uma avaliação conjunta dos produtos dos dois instrumentos por meio de validação, utilizando uma extensa rede de monitoramento em campo, pelo período de três anos, no Estado de Pernambuco. Para isso, diferentes índices estatísticos e categóricos foram utilizados em associação com dados topográficos.

2 MATERIAL E MÉTODOS

2.1 Área de estudo

O estudo foi desenvolvido no estado de Pernambuco, localizado na região Nordeste do Brasil e ocupando uma área de aproximadamente 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.

De acordo com Possas et al., (2012), os menores índices pluviométricos ocorrem nas mesorregiões do Sertão Pernambucano e São Francisco, com médias anuais variando de 400 a 800 mm, principalmente no São Francisco, onde as chuvas são ainda mais escassas. A região Agreste já possui um incremento na média, de 600 a 1000 mm, ao passo que na Zona da Mata e RMR, os valores variam de 1000 a 2265 mm. Devido à similaridade climática e proximidade do litoral, neste estudo, as mesorregiões da Zona da Mata e RMR foram avaliadas em conjunto. As mesorregiões do estado e a localização dos postos pluviométricos utilizados no estudo estão representados na Figura 33.

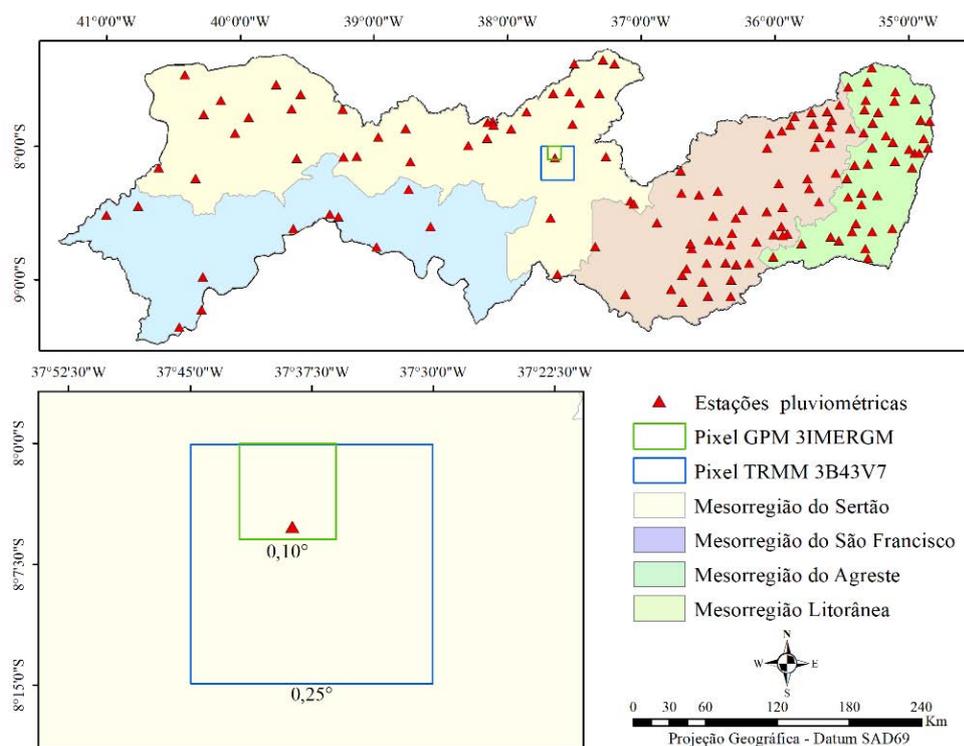


Figura 33. Área de estudo com localização dos postos pluviométricos utilizados para validação dos dados orbitais e representação dos pixels TRMM e GPM.

O relevo do Estado é bastante variável, com a tendência de redução de altitude em direção ao litoral. A variação fica em torno de 4 m no ponto mais baixo e 1200 m no ponto mais alto.

2.2 Fontes de dados

Os dados utilizados como referencial para validação dos produtos remotos foram obtidos a partir de 144 pluviômetros automáticos geridos pela Agência Pernambucana de Águas e Clima (APAC), entre o período de janeiro de 2015 a dezembro de 2017. Essa faixa de tempo foi selecionada para coincidir com as séries dos satélites, considerando que o GPM só passou a fornecer dados em meados de 2014. Os dados de precipitação dos pluviômetros, baixados em escala temporal diária, foram reorganizados em acumulados mensais antes das validações.

A rede de monitoramento de precipitação no estado é bem mais extensa. No entanto, somente os postos com total ausência de falhas em dados diários foram considerados nesse estudo.

O *Tropical Rainfall Measuring Mission* (TRMM), resultado de parceria entre a Administração Nacional da Aeronáutica e Espaço (NASA) e a Agência

Japonesa de Exploração Aeroespacial (JAXA) foi lançado em 1997 com o intuito de estimar a precipitação tropical. O *TRMM Multi-satellite Precipitation Analysis* (TMPA) combina os dados obtidos com a precipitação estimada por outros satélites, além de calibrar os dados com base em pluviômetros de controle instalados em pontos específicos, o que aumenta a exatidão das leituras. Contando com resolução espacial de $0,25^\circ$ e temporal e 3 horas, o sucesso da missão levou ao lançamento do seu sucessor, o *Global Precipitation Measurement (GPM) Core Observatory*. Ao contrário do TRMM, o GPM estima a precipitação em escala global, com resoluções espacial e temporal aprimoradas, de $0,1^\circ$ e 30 minutos, respectivamente.

A missão GPM, iniciada em 2014, é mais ambiciosa, formada por uma constelação de vários satélites que conta um instrumento principal que funciona como um 'núcleo'. Além de estimar a precipitação, o satélite principal recebe e processa dados dos demais. O *GPM Integrated Multi-satellitE Retrievals* (IMERG) combina dados dos sensores de microondas que compõem a constelação e passa por calibração com base em registros de pluviômetros de referência usados na missão.

Neste estudo, foram utilizados os produtos mais recentes dos dois satélites. Para o TRMM, foram obtidos dados relativos ao produto TMPA 3B43V7 e, para o GPM, ao produto 3IMERGM, ambos formados por dados acumulados mensais de precipitação, totalizando 36 observações para cada pixel durante o período considerado. É importante ressaltar que o produto 3B43V7 é formado por acumulados mensais com base em dados coletados a cada 3 horas, já o 3IMERGM trabalha com dados acumulados de resolução de 30 minutos. As imagens em formato NetCDF, contendo os dados dos dois satélites, podem ser obtidas através do portal Mirador, da NASA (<https://mirador.gsfc.nasa.gov/>).

2.3 Comparação dos dados

Estudos de validação de atributos estimados por satélites devem ser realizados com bastante cuidado, considerando as discrepantes resoluções espaciais dos dados mensurados em campo em relação àqueles estimados remotamente. Diversas técnicas são sugeridas, embora cada uma delas apresente vantagens e desvantagens.

Dentre as principais metodologias utilizadas, destacam-se as comparações ponto a pixel, em que o valor registrado pelo pluviômetro é diretamente comparado com aquele estimado pelo pixel (GAO, ZHANG, CHEN, et al., 2018); ponto a ponto, em que as leituras mensuradas pelos pluviômetros são interpoladas para a área do centroide do pixel (AMITAI et al., 2012); pixel a pixel, em que as leituras dos centroides dos pixels são interpoladas para a área do pluviômetro (CHEN et al., 2013). Visando reduzir erros decorrentes da interpolação dos dados dos pluviômetros ou dos satélites, as comparações foram realizadas diretamente pelo método ponto a pixel, conforme sugerido por Wang et al. (2017) e Tan et al. (2017).

Diversos estudos comprovam que o GPM e TRMM tendem a incrementar o desempenho quando se aumenta a escala temporal dos dados. Validações a partir de dados horários ou diários são significativamente inferiores quando comparadas com validações de dados acumulados mensais e anuais (MANTAS et al., 2015; SOARES et al., 2016; CHEN et al., 2017). Apenas dados mensais foram considerados nesse estudo devido à sua grande aplicação em modelagem hidrológica, previsão de secas e preenchimento de falhas em dados de precipitação (GITHUNGO et al., 2016; JESUS et al., 2016; VIANA et al., 2018).

2.4 Análise de desempenho

Para quantificar os erros de precipitação estimada pelos satélites em comparação com os pluviômetros, que representam o dado de referência neste estudo, foram utilizados os seguintes índices estatísticos: coeficiente de correlação de Pearson (CC), erro médio absoluto (EMA), bias relativo (Bias %), e Raiz do Erro Quadrático Médio (REQM), obtidos pelas equações abaixo:

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

$$EMA = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad 9$$

$$Bias (\%) = \frac{\sum(x_i - y_i)}{\sum y_i} 100 \quad 10$$

$$REQM = \sqrt{\sum \frac{(x_i - y_i)^2}{N}} \quad 11$$

em que x e y correspondem à precipitação estimada pelo satélite e mensurada pelo pluviômetro, respectivamente, \bar{x} e \bar{y} representam a média dessas variáveis e n é o número total de observações mensais para o período.

O coeficiente de correlação indica o grau de similaridade entre as duas séries, variando de -1 (perfeita correlação negativa) a 1 (perfeita correlação positiva); o EMA dá uma ideia da magnitude dos erros de precipitação estimados pelo satélite, em mm; Bias, expresso em porcentagem, indica a direção dos erros em relação ao valor registrado pelos pluviômetros. Valores negativos indicam que o satélite subestimou o evento e valores positivos indicam superestimativa; o REQM reflete o grau de precisão, sendo mais sensível, já que eleva ao quadrado a diferença entre os valores estimados e observados. Produtos de boa performance devem apresentar valores de EMA, Bias (%) e REQM próximos de zero (TAN et al., 2015).

Além disso, quatro indicadores estatísticos baseados em tabela de contingência foram calculados para a estatística categórica: Probabilidade de Detecção (POD – *Probability of Detection*), que indica a fração de eventos que foram corretamente estimados pelos satélites; Razão de Falso Alarme (FAR – *False Alarm Ratio*), que expressa a fração de eventos estimados, mas que não ocorreram na realidade (sem registro no pluviômetro); Taxa de Perda de Detecção (MDR – *Missing Detection Rate*), que indica eventos que foram ignorados pelos satélites, mas registrados pelos pluviômetros; e o Índice de Sucesso Crítico (CSI – *Critical Success Index*), relativo à taxa de acertos nas estimativas, descontando as vezes em que a não ocorrência do evento foi corretamente prevista (PRAKASH et al., 2017; WEHBE et al., 2017).

Os índices supracitados variam de 0 a 1, com um valor ideal para POD e CSI sendo o maior possível e, para o FAR e MDR, o menor possível. As equações de cada índice são descritas abaixo:

$$POD = \frac{H}{H + M} \quad 12$$

$$FAR = \frac{F}{H + F} \quad 13$$

$$MDR = \frac{M}{H + M} \quad 14$$

$$CSI = \frac{H}{H + F + M} \quad 15$$

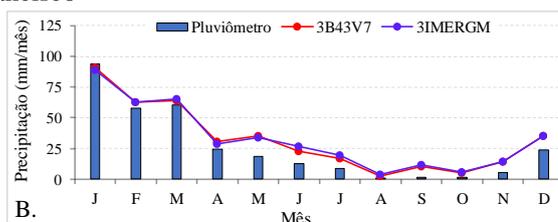
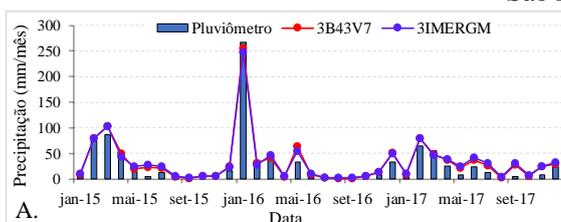
em que H representa o número de eventos que foram registrados tanto pelo satélite quanto pelo pluviômetro (≥ 1 mm); F é o número de eventos mensurados pelo satélite, mas não detectados pelo pluviômetro e M é o número de eventos registrados pelo pluviômetro, mas ignorados pelo satélite.

3 RESULTADOS E DISCUSSÃO

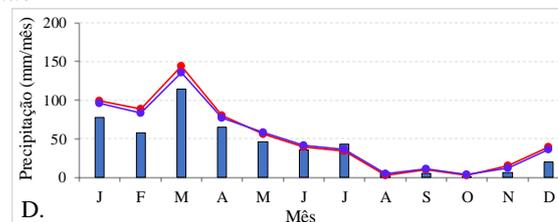
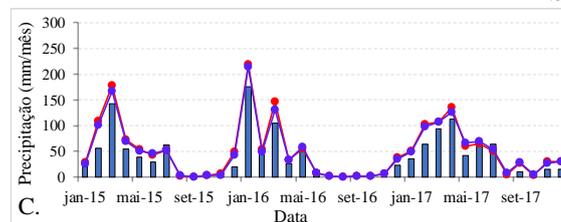
Nesse estudo, a validação dos dados estimados pelos satélites foi realizada pela técnica conhecida como ponto a pixel, recomendada por não agregar erros gerados durante o processo de interpolação (TAN et al., 2017; WANG et al., 2017). Devido ao grande número de postos pluviométricos utilizados, cada um foi usado na validação individualmente e, em seguida, agrupados por mesorregião, adotando-se uma média aritmética de todos os postos.

Com base nas validações realizadas nas quatro mesorregiões, nota-se a similaridade nas estimativas dos dois satélites, que tendem a seguir a mesma flutuação dos dados registrados pelos pluviômetros, tanto na distribuição da precipitação mensal (Figura 34A, C, E e G), ao longo do período, quanto sazonal (Figura 34, D, F, H). É interessante notar que a distribuição sazonal da precipitação registrada pelo GPM possui o mesmo padrão do que foi detectado pelo TRMM na série histórica de 20 anos, evidenciando que os períodos secos e chuvosos no Estado tendem a sofrer alteração em direção ao litoral, conforme detectado por Silva et al. (2010), que também notaram que nas mesorregiões do Agreste e Litoral as chuvas concentram-se em maior quantidade no meio do ano.

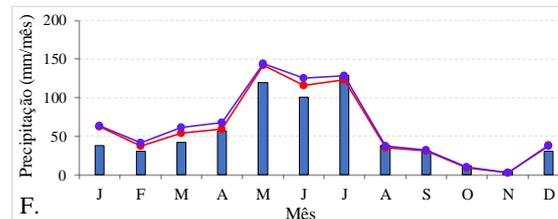
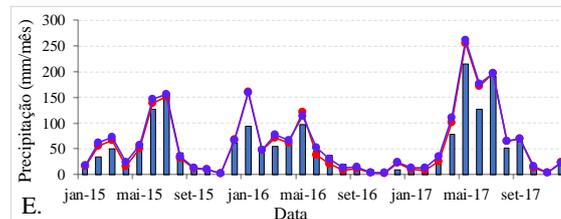
São Francisco



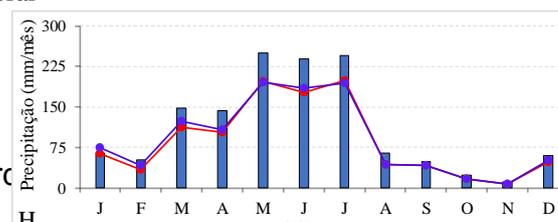
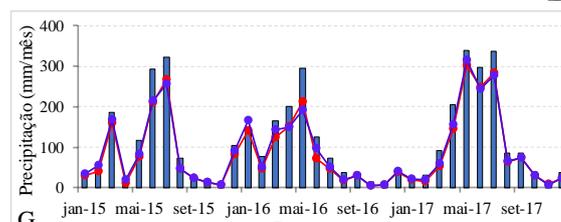
Sertão



Agreste



Litoral



de Pernambuco.

A similaridade dos dados do TRMM 3B43V7 e GPM 3IMERGM é nítida. Ambos os satélites subestimam ou superestimam os registros dos pluviômetros na mesma magnitude. Esse padrão, percebido em vários outros estudos, é comum entre os dois instrumentos (CHEN et al., 2017; TAN & DUAN, 2017; WANG et al., 2017). A acentuada tendência de subestimativa dos dados no Litoral (Figura 35), também percebida por Rozante et al. (2010) para o TRMM, deve-se à deficiência do satélite em estimar a precipitação associada às nuvens “quentes”, comuns na região. Essa limitação não foi devidamente corrigida no GPM, ao menos para o litoral do Nordeste, que concentra maior quantidade de nuvens do que o semiárido durante todo o ano.

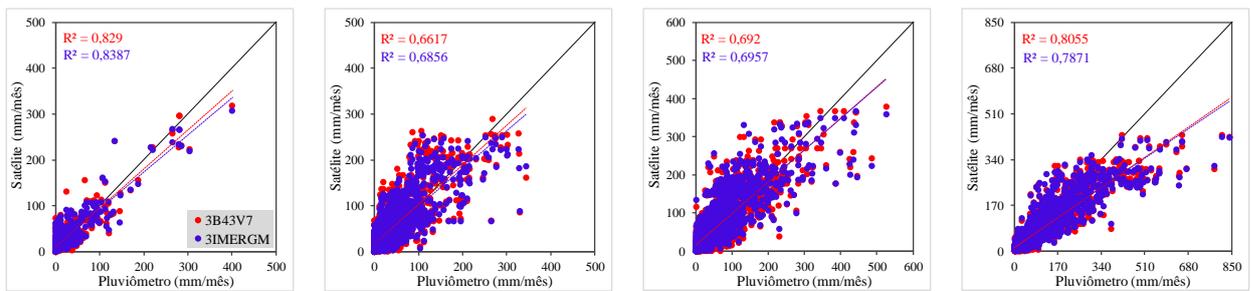


Figura 35. Diagramas de dispersão entre a precipitação mensurada e estimada pelo TRMM 3B43V7 e GPM 3IMERGM.

No caso do coeficiente de determinação (R^2), seu uso é feito para indicar, de maneira descritiva, a qualidade dos dados coletados pelo TRMM e GPM 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 . Na mesorregião do Sertão, que apresentou valores menores de R^2 , os registros mais baixos do índice foram encontrados na porção norte, onde o relevo apresenta variações de altitude que vão de ~250 m até mais de 1000 m na fronteira entre os estados de Pernambuco e Paraíba.

É importante ressaltar que os postos pluviométricos coletam um dado puramente pontual. Por isso, a depender da sua localização na região, esses valores podem ser muito discrepantes em relação aos estimados pelo TRMM e GPM. Considerando a 'microrregião' de Triunfo (no Agreste), que também apresentou valores de R^2 mais baixos, caso a estação esteja em um local de baixa altitude, que tende a apresentar menor precipitação, naturalmente os valores de R^2 serão mais baixos quando comparados aos dos satélites, que geram um dado médio para toda a área, caracterizada por elevadas altitudes. Esse padrão pode demonstrar a importância de avaliar corretamente a localização dos postos pluviométricos antes das validações, levando em conta se a sua localização é maior ou menor representativa do volume precipitado na área. Vale destacar que outras estações próximas apresentaram R^2 elevados, o que pode ter sido favorecido pela sua localização mais representativa da precipitação média.

A mesorregião do Agreste também apresenta grande variação topográfica que, naturalmente, pode induzir a menores valores de R^2 , sendo caracterizada, ainda, pela variação climática, já que está inserida na faixa de transição entre os climas Semiárido e a Zona da Mata. Essa característica

confere à mesorregião grande variabilidade no regime de precipitação, que vai de 600 mm a até 1000 mm ao ano. Nessas condições, a capacidade de adequada detecção do TRMM e GPM pode acabar sendo prejudicada. Esse mesmo padrão foi detectado por Soares et al. (2016), avaliando o desempenho do TRMM na Paraíba. Os autores notaram que, no agreste paraibano, o TRMM apresentou algumas variações no R^2 e demais índices estatísticos, com maior destaque em determinadas épocas do ano. Para Pernambuco, tanto no Sertão quanto no Agreste, essa variação no R^2 em alguns postos acabou afetando a média das duas mesorregiões, deixando-as com valores levemente inferiores quando comparadas às demais.

Com relação ao incremento de erros em direção ao litoral, que tende a ganhar maior representatividade com baixas altitudes e maior incidência de precipitação (Figura 36C), nota-se que o TRMM 3B43V7 e o GPM 3IMERGM tendem a apresentar maior erro médio absoluto (Figura 36A) e raiz de erro quadrático médio (Figura 36B) quanto mais se aproxima do litoral do estado. Esses erros estão associados à subestimativa dos dados de precipitação, ao passo que, nas demais mesorregiões, os mesmos erros, com menor magnitude, estão relacionados à superestimava das precipitações estimadas em relação aos pluviômetros.

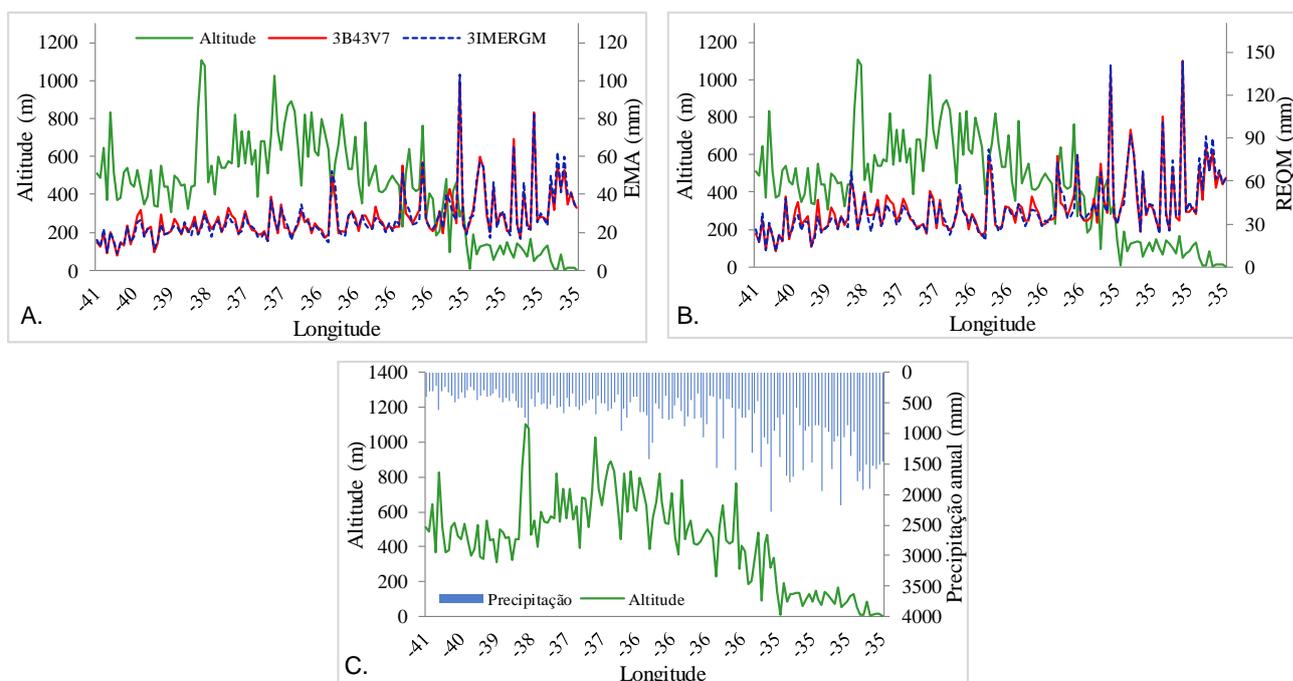


Figura 36. Relação entre altitude (perfil longitudinal) e incidência de erros de estimativas dos satélites TRMM 3B43V7 e GPM 3IMERGM. A – Erro médio

absoluto (EMA); B – Raiz do erro quadrático médio (REQM); C – Precipitação anual e altitude.

Soares et al. (2016), avaliando as estimativas do produto 3B42 do TRMM com base em 212 postos no Estado da Paraíba, em escalas diária e mensal e por um período de 14 anos, também verificaram com clareza a tendência de o satélite subestimar a precipitação litorânea em virtude dos maiores volumes precipitados e associação com nuvens. Esse fato foi confirmado tanto em dados diários quanto mensais e a subestimativa, inevitavelmente, acarretou maiores valores de EMA e REQM. De fato, não é incomum o TRMM superestimar menores valores de precipitação e subestimar maiores valores. Essa característica já foi percebida tanto no Brasil (OLIVEIRA et al., 2014; ANJOS et al., 2017) quanto na África (ADEYEWA e NAKAMURA, 2003) e China (WANG et al., 2017). Nesse sentido, Najja et al. (2018) ressaltam que as subestimativas estão relacionadas às fortes chuvas, que podem reduzir a emissão de sinais para obter informações apuradas sobre o evento. Por apresentar performance similar ao TRMM, é esperado que o GPM obtenha resultados parecidos.

Tanto o TRMM quanto o GPM apresentam padrões de estimativas que variam globalmente. Uma característica de acurácia percebida no litoral brasileiro, por exemplo, caracterizado por baixas altitudes e altos índices pluviométricos, não necessariamente se repetirá em outros locais com topografia e climatologia diferentes. Por isso, estudos com validação de precipitação estimada por satélite em grandes áreas costumam considerar a altitude como fator crucial da detecção do sinal. Najja et al. (2018), validando o TRMM em uma bacia no litoral da Malásia, também notaram que os erros são menores em altitudes médias a altas, tornando-se expressivos em baixas altitudes. Esse é o caso do semiárido pernambucano em comparação com o litoral do Estado, onde há gradativa redução da elevação.

Lu et al. (2018), validando o TRMM e GPM em região montanhosa da China, encontraram menores erros em áreas mais baixas. A área de estudo, no entanto, além de não ser litorânea, apresentou precipitação inferior a 600 mm na faixa montanhosa durante o ano validado. No litoral pernambucano, esse valor facilmente ultrapassa 2000 mm. Esses fatores podem ter contribuído para

as diferenças nos padrões percebidos, indicando, mais uma vez, que o TRMM e GPM são bastante sensíveis à topografia e climatologia.

Os erros de estimativa (bias) dos satélites não apenas tendem a ser negativos no Litoral, indicando subestimativa, como também são mais expressivos em alguns períodos (Figura 37). A magnitude dos erros tende a crescer conforme aumentam os índices pluviométricos. No caso do Litoral, altos valores foram detectados em junho de 2015 e maio de 2016, em que os satélites superestimaram a precipitação mensal em mais de 80 mm. Nos dois casos, esses foram os meses mais chuvosos do ano, de acordo com a média dos postos pluviométricos na mesorregião. Esse fato reforça a dificuldade do TRMM e GPM em estimar, com maior precisão, chuvas caracterizadas por grande volume precipitado. Em junho de 2015, a precipitação observada foi de 293,88 mm e as estimadas pelo TRMM 3B43V7 e GPM 3IMERGM foram de 210,09 e 213,15, respectivamente. No ano seguinte, em maio, esses valores foram de 296,00 (pluviômetro), 212,28 (TRMM) e 191,85 (GPM) para a precipitação observada e estimada pelos satélites.

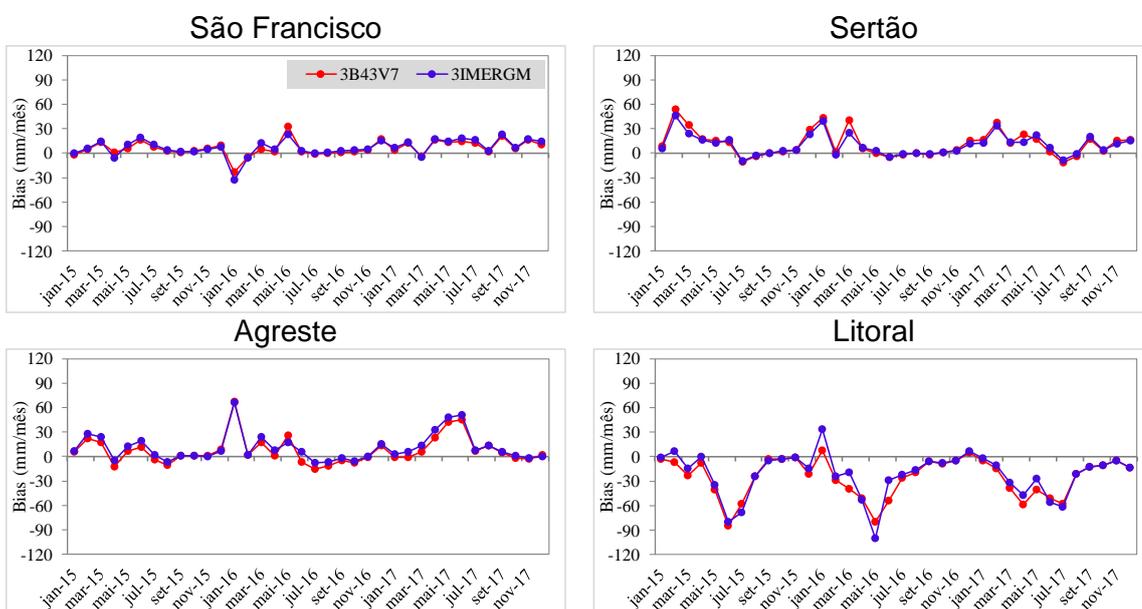


Figura 37. Distribuição temporal de tendências para os dados de precipitação estimados pelos produtos TRMM 3B43V7 e GPM 3IMERGM nas mesorregiões do Estado de Pernambuco.

De acordo com Liu (2016), no continente, as diferenças sistemáticas entre os dados estimados do TRMM e GPM são muito menores em comparação com aquelas percebidas sobre os oceanos, isso porque a mesma

rede de estações em solo é usada para calibrar os dois satélites, agregando-lhes parâmetros semelhantes. Por isso a similaridade entre os dois produtos sobre regiões continentais é esperada e, embora as resoluções espacial e temporal sejam distintas, isso nem sempre trará mudanças significativas, já que se tratam de características de variação espaço-temporal da própria precipitação.

Na Tabela 4 estão expressos os índices estatísticos utilizados para validação. Percebe-se que as variações entre os dois satélites são pouco expressivas. Os menores e maiores valores de coeficiente de correlação (CC) para o TRMM 3B43V7 foram de 0,839 e 0,931. Para o GPM 3IMERGM, esses valores foram de 0,851 e 0,925. No Litoral, a flutuação temporal dos dados registrados pelos satélites acompanha os dados mensurados pelos pluviômetros, o que levou a maiores valores de CC, embora os produtos tenham subestimado os dados de precipitação em razão da maior amplitude, especialmente o TRMM 3B43V7 (bias de -16,41%) que, nesse aspecto, apresentou desempenho inferior ao GPM 3IMERGM (bias de -11,72%). Esse padrão, no entanto, não se repetiu em todas as mesorregiões. No Agreste, por exemplo, houve uma inversão, com o TRMM 3B43V7 apresentando desempenho superior ao GPM 3IMERGM em relação ao bias, nesse caso, os dois produtos tenderam a superestimar o total precipitado. Quanto aos valores de EMA e REQM, praticamente não houve variação. Considerando o número de postos utilizados no estudo, admite-se que os dois satélites são iguais em termos de desempenho para esses índices.

Tabela 4. Índices estatísticos utilizados para validação dos produtos TRMM 3B43V7 e GPM 3IMERGM.

Mesorregião	N	CC		R ²		EMA		Bias (%)		REQM	
		TRMM	GPM	TRMM	GPM	TRMM	GPM	TRMM	GPM	TRMM	GPM
São Francisco	11	0,909	0,918	0,832	0,848	15,69	15,16	30,57	28,57	21,58	21,34
Sertão	37	0,839	0,851	0,708	0,923	23,48	23,11	33,76	30,49	36,16	33,47
Agreste	56	0,885	0,890	0,785	0,795	25,96	25,76	21,19	27,66	37,92	38,07
Litoral	40	0,931	0,925	0,870	0,857	37,78	37,49	-16,41	-11,72	58,00	57,01

O melhor desempenho do GPM sobre o TRMM é notado na maioria dos estudos, mas isso não é regra. Xu et al. (2017) obtiveram resultados variados em relação aos índices estatísticos para uma bacia na China. Embora o GPM

tenha apresentado maiores valores de CC em dados de precipitação acumulada mensais e anuais, também obteve valores de bias relativo muito maior, quase o dobro do TRMM. Silva Lelis et al. (2018), comparando a performance do TRMM e GPM sobre a região leste do Estado de São Paulo, perceberam poucas variações entre os dois produtos, concluindo que há forte similaridade entre os erros gerados pelos satélites e alertando à necessidade de novos estudos para melhor compreensão dos fatores que intervêm nesse processo.

Especialmente, ao longo do Estado, os erros tendem a aumentar no Litoral, assim como o coeficiente de correlação. Esse padrão, já discutido anteriormente, pode ser visualizado para cada pluviômetro, com destaque para o CC (Figura 38A e B), EMA (Figura 38B e C) e Bias relativo (Figura 38E e F), com valores negativos, indicando subestimativa. É nítida a alta similaridade entre os dois produtos em detrimento das diferenças de resolução espacial e temporal.

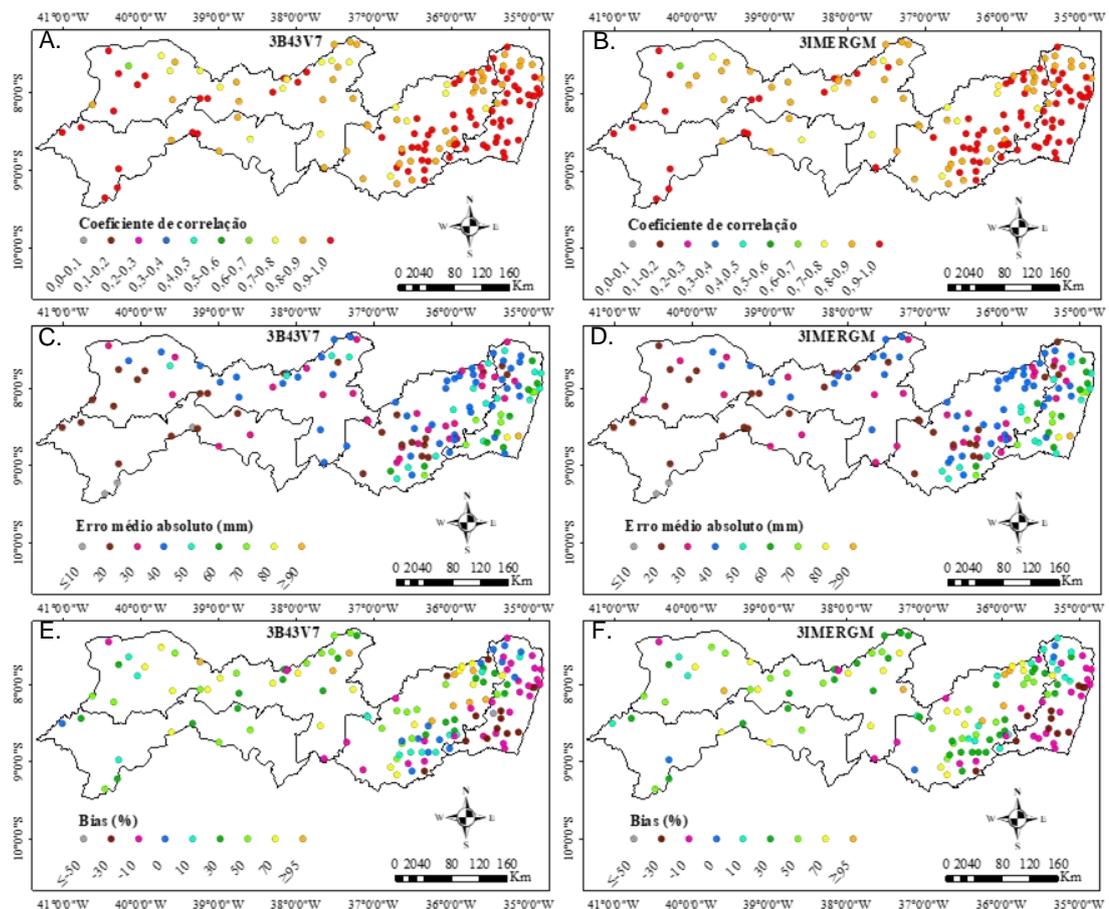


Figura 38. Distribuição espacial do coeficiente de correlação (CC), erro médio absoluto (EMA) e bias relativo (Bias %) por mesorregião do Estado de Pernambuco.

Além dos índices de desempenho estatísticos, uma das formas de comprovar a eficiência de sensores remotos que monitoram eventos esporádicos passíveis de ocorrência a qualquer momento, como a precipitação, é por meio de indicadores baseados em tabela de contingência. Dessa forma, é possível detectar quando o sensor registra (ou não) um evento de forma equivocada (PRAKASH et al., 2017).

Com base nos resultados obtidos, nota-se que tanto o TRMM quanto o GPM possuem alta probabilidade de detecção de eventos (POD), de quase 100%. Isso indica que um evento que é registrado pelos sensores, acima de 1 mm/mês, também é mensurado nos pluviômetros (Tabela 5). Já nas mesorregiões do Sertão e São Francisco, onde os volumes precipitados são os mais baixos do Estado, os satélites tendem a emitir falsos alarmes (FAR). Nesse caso, os sensores registram precipitações acumuladas mensais que não foram detectadas pelos pluviômetros, especialmente o GPM. A taxa de perda de detecção (MDR), que expressa eventos registrados pelos pluviômetros, mas ignorados pelos satélites, também é baixa, corroborando com o POD. Esses fatores levaram a um índice de sucesso crítico (CSI) superior a 0,6 em todos os casos, com a tendência de aumentar em direção ao litoral, indicando que os sensores possuem maior sensibilidade a estimar eventos de forma correta em áreas mais chuvosas. Já a adequada detecção dos volumes precipitados, conforme discutido anteriormente, tende a ser mais problemática nessas regiões.

Tabela 5. Capacidade geral de detecção de eventos de chuva pelos produtos TRMM 3B43V7 e GPM 3IMERGM no Estado de Pernambuco.

Mesorregião	N	POD		FAR		MDR		CSI	
		TRMM	GPM	TRMM	GPM	TRMM	GPM	TRMM	GPM
São Francisco	36	0,986	0,990	0,351	0,392	0,014	0,010	0,644	0,605
Sertão	36	0,985	0,993	0,245	0,276	0,015	0,007	0,744	0,719
Agreste	36	0,965	0,997	0,079	0,087	0,035	0,003	0,890	0,910
Litoral	36	0,979	0,999	0,014	0,015	0,021	0,001	0,966	0,984

Os dados obtidos são similares aos percebidos em outros estudos que comprovaram a alta capacidade do TRMM e GPM na detecção de eventos de

chuva, seja em escala diária ou mensal, embora a característica de emitir falsos alarmes também tenha sido notada (DEMBÉLÉ e ZWART, 2016; TAN et al., 2015; TAN & DUAN, 2017).

4 CONCLUSÕES

O desempenho do TRMM 3B43V7 e GPM 3IMERGM é bastante similar no estado de Pernambuco, embora o sucessor tenda a ser levemente superior em virtude das melhorias nas resoluções espacial e temporal. Os dois satélites apresentam a característica de superestimar a precipitação no semiárido e subestimar os eventos no litoral do Estado. 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. Dessa forma, é possível utilizar os dados de ambos os satélites com maior segurança, isoladamente ou em conjunto.

Por ser um satélite recente, não é possível afirmar que esse mesmo padrão de estimativas do GPM será mantido nos próximos anos, de modo que novos estudos, inclusive de comparação com outros instrumentos orbitais, são recomendados para continuar acompanhando o desempenho do GPM e checar a sua aplicabilidade em estudos relacionados à gestão e gerenciamento de recursos hídricos.

CAPÍTULO IV

**VALIDAÇÃO E APLICAÇÃO DE DADOS DE UMIDADE DO SOLO
ESTIMADOS POR SENSORIAMENTO REMOTO NA DETECÇÃO DE
SECAS NO SEMIÁRIDO**

Validação e aplicação de dados de umidade do solo estimados por sensoriamento remoto na detecção de secas no semiárido

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 objetivou validar produtos de dois satélites globais que monitoram a umidade do solo, o *Soil Moisture Active Passive* (SMAP) e o *Soil Moisture and Ocean Salinity* (SMOS), para em seguida utilizá-los na estimativa de seca agrícola. Para isso, um produto do SMAP com resolução espacial de 36 km² e dois produtos do SMOS com resolução espacial de 25 km² foram utilizados. Para as validações, foram consideradas 120 estações em todo o semiárido, com 61 delas localizadas em Pernambuco. Devido à elevada densidade da rede de monitoramento, o Estado foi também avaliado separadamente. A seca foi estimada com base no índice *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 validar o SWDI, o índice *Atmospheric Water Deficit* (AWD) foi calculado com dados de 49 estações do INMET. O SMAP foi o satélite que apresentou melhor desempenho, tanto em Pernambuco quanto em todo o semiárido, ainda que tenha resolução espacial inferior aos demais produtos avaliados. Além disso, o índice SWDI, gerado com dados orbitais, apresentou boa correlação com o AWD calculado com dados *in situ*, com coeficiente de correlação médio igual a 0,79 nas 49 estações avaliadas, indicando o potencial do SMAP para o monitoramento da seca agrícola. Os resultados apontam que o SWDI pode ser monitorado continuamente para suporte ao manejo agrícola, 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.

Palavras-chave: satélites, conteúdo de água, agricultura, recursos hídricos.

Validation and application of soil moisture data estimated by remote sensing for drought monitoring in the semiarid

ABSTRACT: soil moisture is a key variable in water and energy cycles on a global scale. However, due to the scarcity of ground data, several satellites have been used as an alternative source in recent years. This study aimed to validate products from two global satellites that monitor soil moisture, Soil Moisture Active Passive (SMAP) and Soil Moisture and Ocean Salinity (SMOS), and then use them to estimate agricultural drought. For this, one SMAP product with spatial resolution of 36 km² and two SMOS products with spatial resolution of 25 km² were used. For validations, 120 stations were considered throughout the semiarid, with 61 of them located in Pernambuco. Due to the high density of the monitoring network, the State was also evaluated separately. Drought was estimated based on the Soil Water Deficit Index (SWDI), which uses physical soil properties to indicate when plants are under water deficit. In order to validate the SWDI, the Atmospheric Water Deficit (AWD) index was calculated using 49 INMET station data. SMAP was the satellite that presented the best performance, both in Pernambuco and throughout the semiarid, although it has lower spatial resolution than the other products evaluated. In addition, the SWDI index, generated with orbital data, showed a good correlation with the AWD calculated with in situ data, with an average correlation coefficient of 0.79 in the 49 evaluated stations, indicating the potential of SMAP to monitor agricultural drought. The results indicate that SWDI can be continuously monitored to support agricultural management, assisting in the more rational use of water resources and issuing alerts that may favor the mitigation of impacts resulting from extreme drought events, highlighting conditions in which water demand is high.

Keywords: satellites, water content, agriculture, water resources.

1 INTRODUÇÃO

A umidade do solo é uma variável chave nos ciclos de água e energia em escala global. Seu conhecimento, com medições de alta qualidade, é necessário para um grande número de aplicações, incluindo previsão meteorológica de curto prazo, modelagem hidrológica, estimativa de produção agrícola, monitoramento de secas e estudos de mudanças climáticas (BROCCA et al., 2017).

Nas últimas duas décadas, vários estudos mostraram que a umidade do solo pode ser obtida por uma grande variedade de sensores orbitais, incluindo os ópticos, termais e instrumentos baseados em microondas ativos e/ou passivos (UMAR et al., 2016). A grande vantagem dos sensores de microondas 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).

A temperatura de brilho (TB) é uma das formas de estimar a umidade do solo utilizando sensoriamento remoto. A TB é adquirida através de sensores de microondas passivos e essa estimativa é possível devido à relação direta entre o conteúdo de água e a emissividade do solo (GARNAUD et al., 2016; SOUZA et al., 2018). Alguns satélites, como o *Soil Moisture and Ocean Salinity* (SMOS) e o *Soil Moisture Active Passive* (SMAP) utilizam a TB como referência para estimar o conteúdo de água na superfície por meio da banda L, que é sensível à detecção na camada inicial do solo, de até 5 cm (BAI et al., 2018a; KOSTER et al., 2016).

Qualquer aplicação com dados de umidade do solo oriundos 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 obtidos 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., 2018a; MARTÍNEZ-FERNÁNDEZ et al., 2016).

O objetivo desse estudo será validar dados de sensoriamento remoto obtidos por diferentes produtos baseados em microondas e verificar a sua aplicabilidade para a modelagem de seca agrícola no semiárido.

2 MATERIAL E MÉTODOS

2.1 Área de Estudo

O estudo foi desenvolvido para todo o semiárido brasileiro. No entanto, o Estado de Pernambuco também foi avaliado separadamente por possuir uma rede mais densa de plataformas de coleta de dados de umidade do solo. Foram utilizadas, em todo o semiárido, 120 estações de monitoramento de umidade do solo geridas pelo Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN). Desse total, 59 estão inseridas apenas no Estado de Pernambuco, que também conta com 10 estações da Agência Pernambucana de Águas e Climas, totalizando 69 pontos de monitoramento em superfície. Essas estações foram utilizadas para a validação dos dados obtidos pelos diferentes sensores remotos. A validação é requerida antes de que os dados orbitais sejam utilizados para outras finalidades, como a modelagem de secas.

2.1.2 Semiárido Brasileiro

O semiárido brasileiro se estende por uma área que abrange 86,84% dos estados da região Nordeste, incluindo mais de 80% do Estado de Pernambuco, somando uma área total de aproximadamente 974.752 km². Os índices pluviométricos registrados nessa região são bastante baixos, podendo chegar a menos de 400 mm ano⁻¹. No entanto, no semiárido brasileiro como um todo, os valores médios são de 750 mm ano⁻¹, com período chuvoso

raramente ultrapassando 4 meses ao ano. A insolação é bastante elevada e a temperatura varia de 23 a 27 °C; o solo é rochoso, arenoso e raso, o que, aliado às características climáticas, expõe severamente a região a processos de desertificação (TEIXEIRA, 2016).

Dentro do semiárido, foram utilizadas 120 estações do CEMADEN (e mais 10 da APAC em Pernambuco). O órgão possui outras estações, no entanto, após seleção prévia daquelas consideradas mais consistentes, esse foi o valor final obtido.

2.1.3. Estado de Pernambuco

O Estado de Pernambuco está localizado na região Nordeste do Brasil e ocupa uma área de aproximadamente 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.

De acordo com Possas et al., (2012), os menores índices pluviométricos ocorrem nas mesorregiões do Sertão Pernambucano e São Francisco, com médias anuais variando de 400 a 800 mm, principalmente no São Francisco, onde as chuvas são ainda mais escassas. A região Agreste já possui um incremento na média, de 600 a 1000 mm, ao passo que na Zona da Mata e RMR, os valores variam de 1000 a 2265 mm.

Silva et al. (2010) enfatizam ainda que, no que concerne ao regime pluvial, o estado de Pernambuco possui ao menos três mesorregiões distintas: Sertão, Agreste e Zona da Mata/Litoral. No Sertão, as chuvas concentram-se de janeiro a abril; o Agreste está em zona intermediária de transição entre os climas úmidos e secos, tendo o período chuvoso principal de fevereiro a junho (setor ocidental) e março a julho (setor oriental). Já a Zona da Mata/Litoral apresenta regime chuvoso mais longo, de seis meses (março a agosto).

Considerando a grande irregularidade na precipitação ao longo do estado que ocasiona diversidade climática e, levando em conta que a precipitação é a principal variável hidrológica que regula a distribuição espacial e temporal da umidade do solo, o estudo foi realizado para quatro

mesorregiões separadamente: Sertão Pernambucano, Sertão do São Francisco, Agreste e Zona da Mata/RMR, sendo que as duas últimas foram avaliadas em conjunto, dada a proximidade do litoral e maior homogeneidade climática em detrimento das demais. Ressalta-se que o estudo para todo o Estado, considerando-o como homogêneo, poderia levar a grandes erros de estimativa, aumentando o desvio-padrão, métricas de erro e, conseqüentemente, reduzindo o coeficiente de correlação e qualidade das análises. A distribuição dos pontos de monitoramento do CEMADEN e APAC no semiárido (com destaque para Pernambuco) podem ser visualizados na Figura 39.

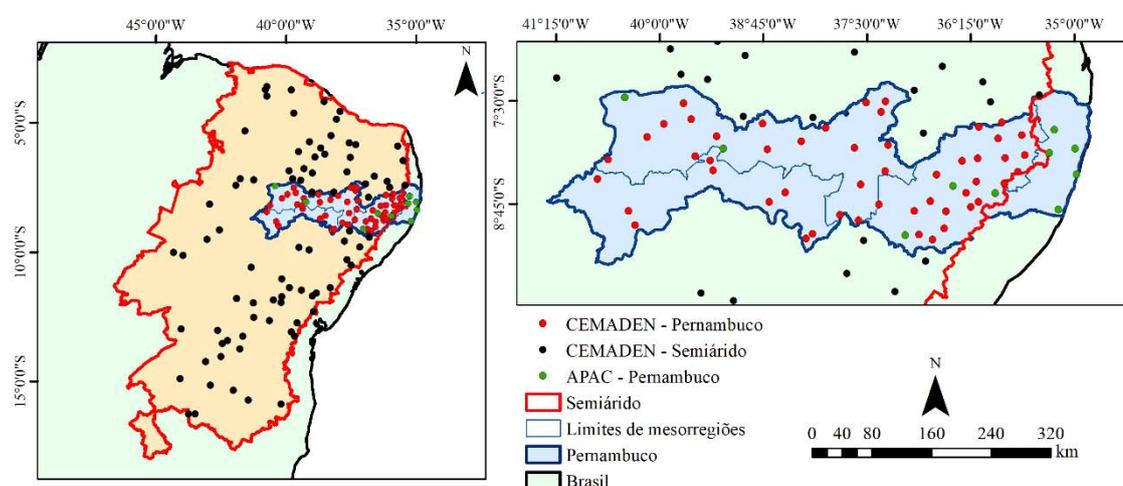


Figura 39. Estações de monitoramento da umidade do solo no semiárido.

2.2 Séries de dados

Os dados de umidade do solo e precipitação utilizados foram obtidos a partir de redes de monitoramento em campo que cobrem todo o semiárido, para o período de três anos, compreendido entre os meses de julho de 2015 a julho de 2018. Devido à limitação no período de coleta de dados, optou-se por usar essa escala temporal para o trabalho em virtude do menor número de falhas e maior consistência das informações.

Para avaliação da umidade do solo por sensoriamento remoto, foram utilizados dados provenientes de duas redes de satélites: *Soil Moisture and Ocean Salinity* (SMOS), da ESA, que utiliza o sensor *Microwave Imaging Radiometer using Aperture Synthesis* (MIRAS) e o *Soil Moisture Active Passive* (SMAP), da NASA. Ambos operam na frequência de microondas e na banda L.

2.2.1 Estações do CEMADEN

No semiárido, a rede de monitoramento do CEMADEN é composta por mais 595 plataformas de coleta de dados (PCD), que tiveram a instalação finalizada em janeiro de 2016. Por se tratar de uma rede recente, algumas PCD apresentam falhas de operação ou fornecem dados ainda inconsistentes em virtude da ausência de manutenções e controle de qualidade. Desse total, 120 estações foram cedidas pelo CEMADEN em todo o semiárido, possivelmente por apresentarem dados mais consistentes.

Na faixa semiárida do Estado de Pernambuco, o CEMADEN conta com um total de 76 estações. No entanto, conforme mencionado, muitas ainda possuem falhas ou não operam corretamente. Aproximadamente 51 estações possuem uma série anual mais consistente. Dentre estas, a maioria possui dados completos, mas outras apresentam algumas falhas em intervalos de alguns dias. Por esse motivo, foram utilizadas nas análises comparativas de umidade do solo com produtos oriundos de sensores remotos.

Todos os estados do semiárido possuem uma rede adensada. No entanto, o CEMADEN forneceu a maior quantidade de dados para Pernambuco, já que o foco maior da validação e dos estudos de seca se concentram nesse Estado.

Os sensores utilizados são do modelo EC-5, da Decagon Devices[®], que possuem precisão de $0,03 \text{ m}^3 \text{ m}^{-3}$ e fornecem dados de umidade do solo à profundidade de até 40 cm.

2.2.2 Estações da APAC

As PCD meteorológicas da APAC iniciaram as operações em meados de abril de 2013. A rede conta com 13 estações espalhadas pelo Estado. Para igualar o intervalo de tempo com as estações do CEMADEN, foi considerado apenas o período de julho de 2015 a julho de 2018 (três anos). Após triagem inicial, três estações foram descartadas das validações. Somadas às estações do CEMADEN, a rede considerada neste estudo possui, no total, 61 estações.

Os sensores de umidade do solo da APAC são do modelo PR2, da Decagon Devices®, que trabalham com precisão de $0,04 \text{ m}^3 \text{ m}^{-3}$, registrando dados a até 30 cm de profundidade.

2.2.3 SMOS (MIRAS)

O satélite SMOS foi lançado pela Agência Espacial Europeia (ESA) em novembro de 2009 com o objetivo de monitorar a umidade do solo à profundidade de até 5 cm, com acurácia de $0,04 \text{ m}^3 \text{ m}^{-3}$, em escala global e com tempo de revisita de 1 a 3 dias. O SMOS foi o primeiro satélite dedicado especificamente a monitorar a umidade do solo, operando na banda L (1.4 GHz), com passagem de órbita ascendente às 06:00h e descendente às 18:00h, em horário local, e resolução espacial de $\sim 25 \text{ km}$ (Kerr *et al.*, 2010; Leroux *et al.*, 2014).

Foram utilizados dois produtos: 1) SMOSL3 (SMOS Level 3), fornecido publicamente pelo *Centre Aval de Traitement des Données* (CATDS; <https://www.catds.fr/sipad/>), que integram dados globais de umidade do solo com resoluções temporais de 1, 3 e 10 dias ou mensais e resolução espacial de 25 km (AL-YAARI *et al.*, 2014; LEROUX *et al.*, 2014; WAGNER *et al.*, 2014). Os dados são fornecidos no formato NetCDF com grid EASE (*Equal Area Scalable Earth grid*) (AL-YAARI *et al.*, 2014); 2) SMOS-IC (SMOS-INRA-CESBIO), uma versão alternativa do SMOSL3 desenvolvida pelo INRA (*Institut National de la Recherche Agronomique*) e CESBIO (*Centre d'Etudes Spatiales de la BIOSphère*). O SMOS-IC, quando cedido para estas avaliações, era de acesso ainda restrito, pois estava em fase de avaliação e validação em escala global. Os dados foram cedidos pela equipe desenvolvedora do INRA/CESBIO. Atualmente, o SMOS-IC já está disponível para toda a comunidade científica também na plataforma do CATDS.

O SMOS-IC diferencia-se do SMOSL3 por possuir um algoritmo mais simples, sendo o mais independente possível de dados auxiliares, considerando os pixels como homogêneos, além de possuir melhorias nos parâmetros de rugosidade do solo e relacionados à vegetação. Fernandez-Moran *et al.* (2017), comparando os produtos SMOSL3 e SMOS-IC entre os anos de 2010 a 2015 em escala global, constataram que o segundo possui

melhorias acentuadas no coeficiente de correlação, bem como menores erros de estimativa, tanto para a umidade do solo quanto para a profundidade óptica da vegetação.

O princípio do algoritmo da versão L3 (v300) do SMOS é similar ao da versão L2, em que observações multiangulares são usadas para obter, simultaneamente, a umidade do solo (quantificada diretamente em $\text{m}^3 \text{m}^{-3}$) e a profundidade óptica da vegetação no nadir (τ -NAD), que está relacionada à biomassa (AL-YAARI et al., 2014; NICLOS et al., 2016).

Devido ao fato de o sensor MIRAS trabalhar na banda L, possui algumas vantagens sobre outros sensores. Isso ocorre porque os demais sensores trabalham com altas frequências de microondas, que são mais susceptíveis à presença de nuvens, densidade de dossel vegetal e topografia da superfície. Ao contrário deles, o MIRAS está menos propenso a ruídos relacionados ao conteúdo de água na atmosfera, já que as nuvens têm efeito relativamente insignificante na banda L (ANAM et al., 2017).

Para este estudo, foram utilizadas imagens para todo o período de julho de 2015 a julho de 2018, em intervalos diários. No entanto, devido à resolução temporal do SMOS (1 a 3 dias), nem todos os pixels da imagem fornecerão dados de umidade do solo diariamente.

2.2.4 SMAP

O *Soil Moisture Active Passive* (SMAP), lançado pela NASA em janeiro de 2015, foi projetado para estimar a umidade do solo por meio de sensores passivos e ativos. Infelizmente, o sensor ativo (radar) parou de transmitir dados após alguns meses em operação. Atualmente, o SMAP produz dados somente através do sensor passivo (radiômetro) e, assim como o SMOS, também opera na banda L (CHEN et al., 2017). O radar, que foi totalmente revolucionário para a época, possuía resolução espacial de ~ 3 km. Problemas de hardware levaram à sua inoperância.

O SMAP tem uma órbita quase polar, com passagens de órbita às 6:00h (ascendente) e 18:00h (descendente), horário local. Neste estudo, o produto SMAP Level 3 estimado pelo radiômetro com escala de tempo diária foi

avaliado. O produto SMAPL3 é fornecido pela NASA (<https://smap.jpl.nasa.gov/data/>) e originalmente tem resolução espacial de ~36 km com EASE-2 (*Equal Area Scalable Earth grid, Version 2.0*), com resolução espacial de 1 a 3 dias e profundidade de amostragem de até 5 cm de camada de solo (ZHANG et al., 2017). No entanto, a fim de fazer comparações justas e reduzir erros sistemáticos, a resolução do SMAP foi reamostrada para coincidir com a mesma resolução espacial do SMOS (~25 km), usando uma técnica de interpolação bilinear, conforme realizada por (CUI et al., 2018).

2.3 Validação dos dados

Quando se trata de dados de sensoriamento remoto obtidos em diferentes horários, pode haver maior ou menor impacto de radiofrequência (RFI) em função do momento da aquisição da imagem (DENTE et al., 2012), o que pode afetar as estatísticas de erro levadas em conta nas comparações com os dados do sensor remoto e aqueles obtidos em campo. Embora saiba-se que os dados de órbita ascendente são os mais indicados a serem utilizados, devido à sua menor probabilidade de serem afetados por ruídos (USOWICZ et al., 2014), muitos autores optaram por realizar as análises utilizando as duas órbitas combinadas (BROCCA et al., 2011; DENTE et al., 2012; DJAMAI et al., 2015; KANG et al., 2016; SOUZA et al., 2018).

A utilização das duas órbitas em conjunto permite ampliar a resolução temporal dos sensores, já que é comum que o dado de uma órbita seja registrado em um dia diferente da outra. Ao calcular a média das duas órbitas, a resolução temporal do satélite torna-se maior, reduzindo a quantidade de dias sem dado. Nesse estudo, as órbitas foram utilizadas em conjunto, por meio de média diária. Além disso, as validações foram realizadas em escala diária e mensal, considerando que diversas aplicações, incluindo modelagem de seca e hidrológica, podem necessitar de dados mensais de umidade do solo.

Antes das validações, os dados adquiridos pelos satélites passaram por uma triagem inicial que removeu aquelas leituras consideradas inconsistentes ou inapropriadas, segundo os critérios dos desenvolvedores. Cada 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), este trabalho comparou os dados de umidade do solo de órbitas ascendente e descendente (em conjunto) dos sensores SMOS e SMAP com os dados obtidos pelas redes de monitoramento em campo. Quando mais de uma estação esteve dentro de uma mesma célula (pixel) da grade dos satélites, foram calculados os valores médios visando obter o dado de umidade do solo de forma mais representativa, reduzindo tendências.

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.

Albergel et al. (2013) estudando especificamente a performance de diferentes métricas de erro para avaliar o desempenho da validação de dados obtidos por sensoriamento remoto versus *in situ*, apresentaram as estatísticas comumente utilizadas pela comunidade científica, mais precisamente quando se deseja validar dados espaciais de umidade do solo. Essas mesmas métricas foram adotadas no estudo aqui proposto, dada a sua consistência e difusão em vários trabalhos, em diferentes escalas, variando de local a global (AL-YAARI et al., 2014; WAGNER et al., 2014; AMPAGNE et al., 2016; CHEN et al., 2017; KANG et al., 2016). São elas: o coeficiente de correlação (R), desvio da raiz quadrada média (RMSD), tendenciosidade ou viés (*Bias*), desvio da raiz quadrada média não-tendenciosa (ubRMSD).

A estatística mais utilizada para quantificar o padrão de similaridade é o coeficiente de correlação R , expresso por (Eq. 16):

$$R = \frac{1}{N} \sum_{n=1}^N (\text{satélite}_n - \overline{\text{satélite}}) (\text{in situ}_n - \overline{\text{in situ}}) \quad 16$$

$$\sigma_{\text{satélite}} \sigma_{\text{in situ}}$$

onde $\sigma_{\text{satélite}}$ e $\sigma_{\text{in situ}}$ são os desvios-padrão dos dados de satélite e de campo, respectivamente. N é o total de dados de uma determinada estação; $\overline{\text{satélite}}$ e $\overline{\text{in situ}}$ representam as médias de umidade do solo para os dados de satélite e de campo. O R varia de -1 a 1, correspondendo à perfeita correlação negativa e positiva entre as duas séries de dados, respectivamente. Vale ressaltar que um R bastante elevado não implica dizer que os dados de satélite e campo sejam iguais (exceto quando $R=1$), mas sim que eles possuem os mesmos padrões de flutuação (Albergel *et al.*, 2013). O coeficiente de correlação será classificado como muito fraco ($\pm 0,0$ a $\pm 0,19$), fraco ($\pm 0,20$ a $\pm 0,39$), moderado ($\pm 0,40$ a $\pm 0,59$), forte ($\pm 0,60$ a $\pm 0,79$) e muito forte ($\pm 0,80$ a $\pm 1,0$).

Para quantificar diferenças entre as séries (satélite e campo), a estatística mais utilizada é baseada no RMSD (Eq. 17), que dá a magnitude média dos erros, sendo ponderada de acordo com o quadrado do erro:

$$\text{RMSD} = \sqrt{\frac{1}{N} \sum_{n=1}^N (\text{in situ}_n - \text{satélite}_n)^2} \quad 17$$

Aconselha-se utilizar o RMSD em lugar do erro quadrático médio porque, assim como ocorre com os satélites, dados de umidade do solo obtidos em campo podem conter erros (instrumentais e de representatividade), de modo que eles não podem ser considerados “verdadeiros” valores de umidade do solo. O RMSD levará isso em conta ao comparar o desvio dos sensores em relação aos dados de campo. Tendências na média e/ou diferenças na amplitude das flutuações dos dados fornecidos pelos satélites levarão a altos valores de RMSD (ALBERGEL *et al.*, 2013).

O viés (*bias*), que indica a direção média dos desvios em relação aos valores observados, também é bastante útil (Eq. 18). Valores positivos de viés indicam que os satélites subestimaram os dados de campo; valores negativos dão uma ideia da superestimativa.

$$\text{Bias} = \frac{1}{N} \sum_{n=1}^N (\text{in situ}_n - \text{satélite}_n) \quad 18$$

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 (Eq. 19):

$$\text{ubRMSD} = \sqrt{\frac{1}{N} \sum_{n=1}^N \{[(\text{satélite}_n - \overline{\text{satélite}_n}) - (\text{in situ}_n - \overline{\text{in situ}_n})]^2\}} \quad 19$$

As equações 18 e 19 estão relacionadas através de:

$$\text{ubRMSD}^2 = \text{RMSD}^2 - \text{Bias}^2 \quad 20$$

De modo que ubRMSD também pode ser representado como (Eq. 21):

$$\text{ubRMSD} = \sqrt{\text{RMSD}^2 - \text{Bias}^2} \quad 21$$

2.4 Índice de seca

Vários métodos que utilizam dados de umidade do solo obtidos por sensoriamento remoto, especialmente baseados em microondas, vêm sendo utilizados para estudos de seca. Alguns se baseiam nas variações relativas da umidade do solo (SM), incluindo anomalias de SM (SOUZA et al., 2018), em outros, a SM é combinada com outros dados também obtidos por sensoriamento remoto, como temperatura e índices de vegetação (SÁNCHEZ et al., 2016). Há, ainda, índices que têm maior foco agrícola e, além de dados de SM, levam em consideração as características físicas do solo para indicar se o conteúdo de água, em determinado período (dia), está aquém ou em conformidade com o requerido pelas culturas; um exemplo relativamente recente é o SWDI (BAI et al., 2018a).

Por possuírem séries relativamente curtas e, considerando as grandes secas que assolaram o semiárido desde 2012, incluindo os anos de 2015 a 2018, avaliados nesse estudo, foi utilizado o índice SWDI. O SWDI tem sido

considerado uma abordagem promissora ao incorporar as características físicas do solo para medir a disponibilidade de SM na zona radicular, uma vez que possui um maior significado do que outros índices de vegetação, variáveis climáticas e até mesmo alguns métodos baseados em SM. Mais importante que isso, o índice pode ser aplicado para monitoramento de secas de curto prazo (MARTÍNEZ-FERNÁNDEZ et al., 2016).

2.4.1 Propriedades físicas do solo

Para o cálculo do SWDI, são necessários dados de propriedades físicas do solo, incluindo capacidade de campo (CC), ponto de murcha permanente (PMP) e capacidade de água disponível (CAD). Em escala pontual, a obtenção desses dados é relativamente simples. No entanto, tratando-se de uma avaliação espacial, como é o caso do semiárido, a escassez dessas informações pode ser bastante limitante às análises.

O CEMADEN, durante a instalação de suas 595 PCD, 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. Uma alternativa encontrada foi utilizar 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, hidráulicas e químicas dos solos. O SoilsGrid possui resolução espacial de 250 m ou de 1 km. 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 250 m de resolução espacial.

Realizar uma validação dos dados seria impraticável, considerando a discrepante profundidade de amostragem entre as duas séries, visto que o CEMADEN obteve esses dados para a camada de 0 a 40 cm e o SoilsGrid foi estimado para até 5 cm. No entanto, os dois produtos foram visualmente

comparados para verificar se existe alguma convergência entre eles. Para isso, os dados das 595 PCD do CEMADEN (Figura 40) foram interpolados através do inverso do quadrado da distância (IQD).

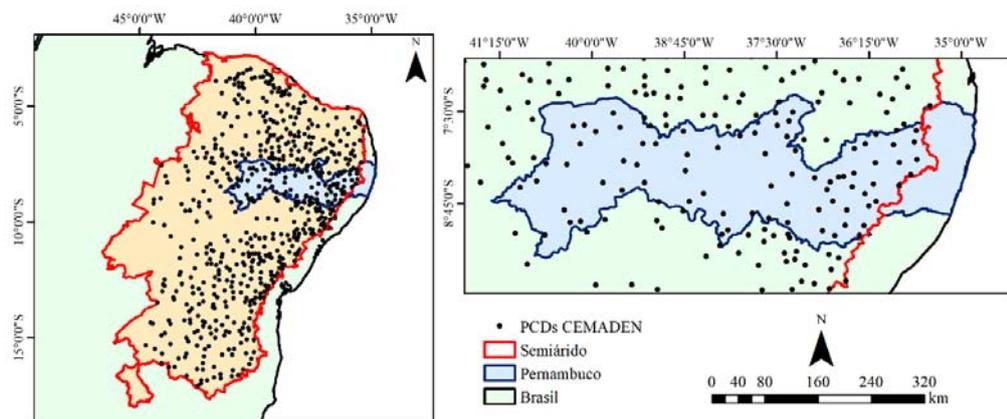


Figura 40. Rede de PCD do CEMADEN utilizadas para a interpolação de dados de propriedades físicas e frações granulométricas do solo, com destaque para o Estado de Pernambuco.

Os dados do CEMADEN, para a profundidade de 0-40 cm, podem ser visualizados na Figura 41. As Figuras 41A, B e C representam as frações granulométricas do solo e as Figuras 41C, D e E as propriedades físicas utilizadas para o cálculo do SWDI. Conforme esperado, maiores valores de areia tendem a estar relacionados a menores valores de CC. O inverso ocorre para a argila e silte, que tende a ter boa convergência com maiores valores de CC e CAD. Além disso, áreas com maior concentração de argila apresentam maiores valores de PMP, variação também esperada devido à capacidade dessa fração reter a água a maiores tensões.

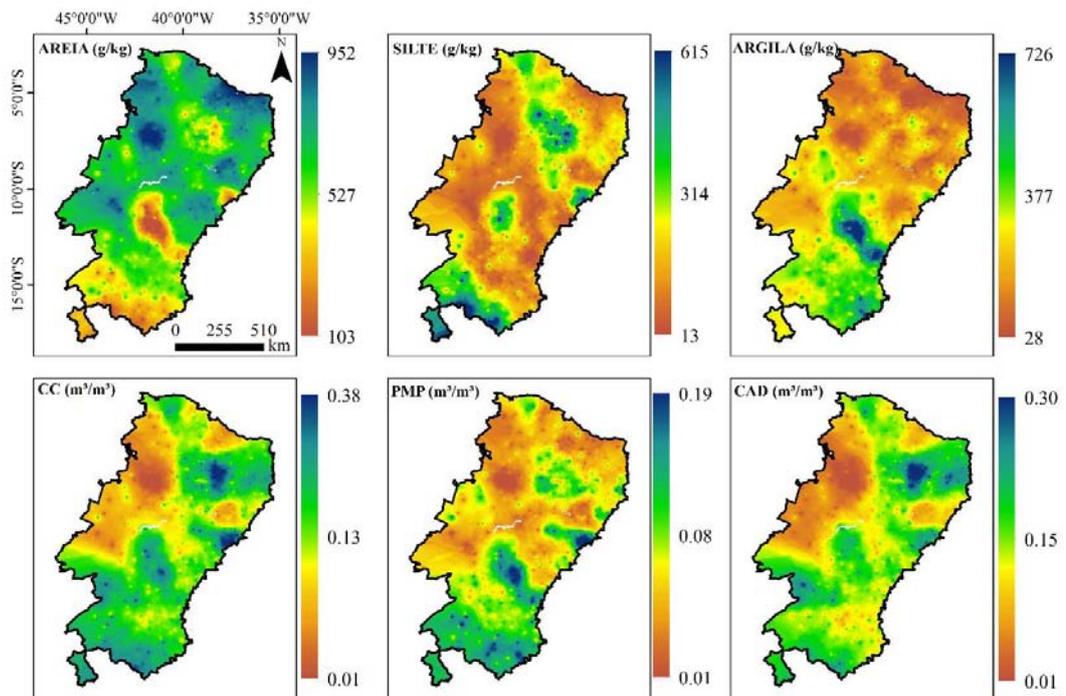


Figura 41. Frações granulométricas e propriedades físicas do solo para o semiárido brasileiro com base nos dados de PCD do CEMADEN, para a camada de 0 a 40 cm.

As estimativas feitas pelo SoilsGrid apresentam variação mais clara devido à resolução espacial adotada, que é de apenas 250 m e uniforme em todo o semiárido. Apesar de possuir alguma variação, o que já é esperado devido às diferentes técnicas de amostragem, representatividade e obtenção das propriedades físicas e granulométricas, nota-se que os dados tendem a apresentar padrão similar, principalmente para as frações areia e argila, que espacialmente variam de forma muito semelhante. Para fins de comparação, deve-se considerar que as rampas de cores das duas imagens não estão na mesma escala numérica. Em ambos os casos, nota-se que CC, PMP e CAD apresentam maiores valores no sul de semiárido, englobando parte do sul da Bahia e norte de Minas Gerais (Figura 42). As propriedades de solo tendem a mudar conforme se aproxima da região Sudeste do país.

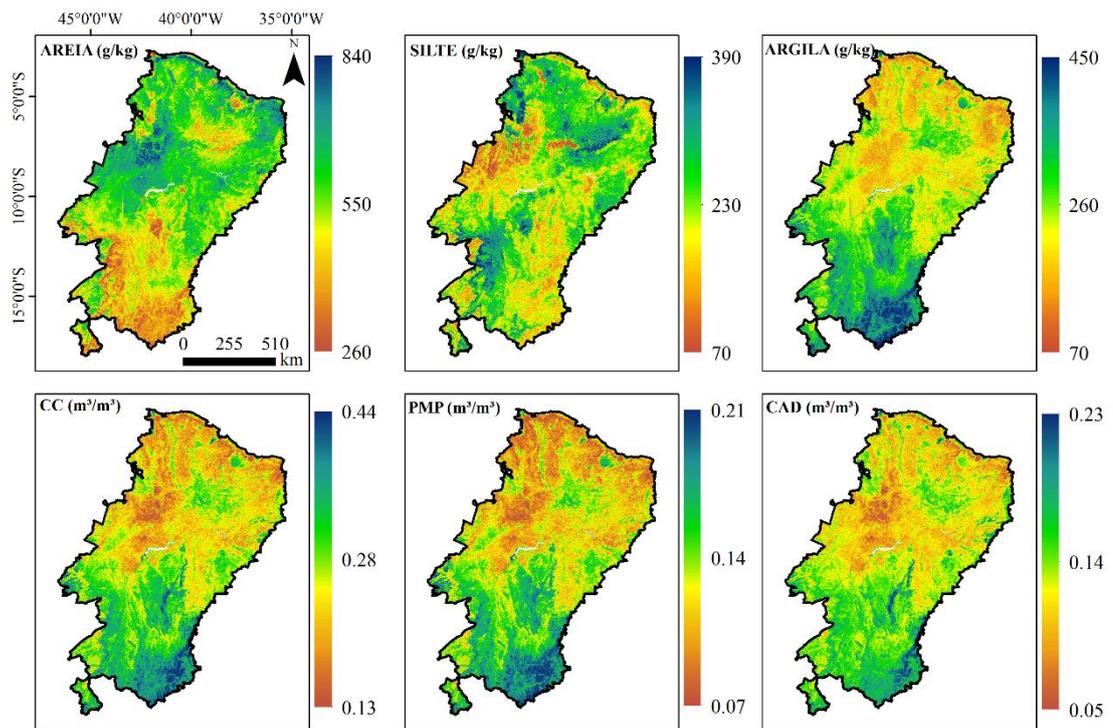


Figura 42. Frações granulométricas e propriedades físicas do solo para o semiárido brasileiro com base em estimativas do SoilsGrid, para a camada de 0 a 5 cm.

A partir de avaliação visual, percebe-se que os dados globais obtidos Zhang et al. (2018) utilizando como referência a base do SoilsGrid, na resolução de 250 m, possuem boa agregação com os dados obtidos em superfície pelo CEMADEN, mesmo considerando as diferentes profundidades de amostragem. Por conta disso, os dados do SoilsGrid foram adotados para as análises de seca. Para isso, sua resolução nativa de 250 m foi resmostrada para coincidir com a mesma resolução espacial do SMAP, satélite selecionado para o estudo, de acordo com os resultados de validação.

2.4.2 Soil Water Deficit Index (SWDI)

O SWDI, que é 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 (Eq. 22):

$$SWDI = \left(\frac{\theta - \theta_{CC}}{\theta_{CAD}} \right) \times 10 \quad 22$$

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 SWDI é positivo, o solo tem excesso de água; quando é igual a zero, o solo encontra-se na capacidade de campo em termos de conteúdo de água (sem déficit hídrico e sem seca). Os valores negativos indicam a seca agrícola e seu impacto dependerá do tipo de 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 três anos de avaliação (2015 a 2018). Após isso, as imagens diárias foram agrupadas em composições médias de três dias, referentes à resolução espacial dos produtos.

2.4.3 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 SM na camada superficial. 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 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 ETo a partir de 49 estações em superfície do Instituto Nacional de Meteorologia (INMET), com base na equação de Penman-Monteith, bem como dados de precipitação da mesma estação. Os dados englobam os estados de Alagoas, Bahia, Ceará, Paraíba, Pernambuco e Rio Grande do Norte. Infelizmente, a porção semiárida dos estados de Piauí e Minas Gerais não foi considerada devido a limitações de dados. A distribuição espacial das estações no semiárido está representada na Figura 43.

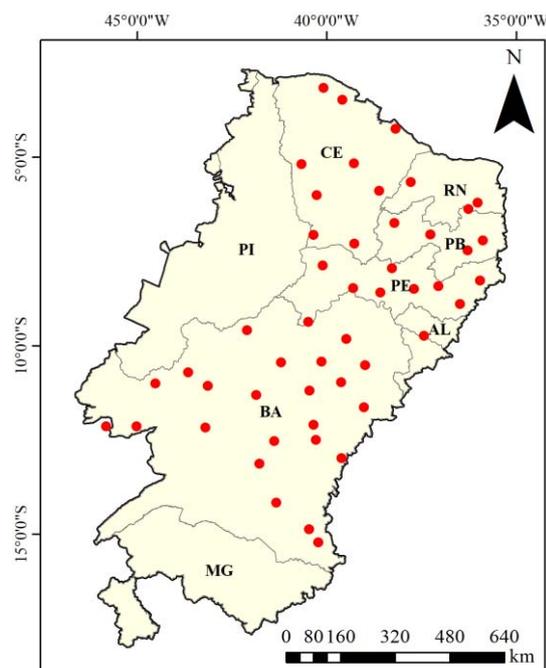


Figura 43. Localização das estações do INMET utilizadas para cálculo do índice AWD no semiárido.

O índice AWD é obtido somando a ETo de sete dias e a precipitação acumulada também de 7 dias. Após isso, a ETo é subtraída da precipitação (Eq. 23).

$$AWD_i = P_i - ET_i$$

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

3 RESULTADOS E DISCUSSÃO

3.1 Avaliação dos dados orbitais de umidade do solo em Pernambuco

A avaliação dos diferentes produtos orbitais de umidade do solo foi realizada utilizando estratégias distintas, tanto de escalas espaciais quanto temporais. Espacialmente, os produtos foram a princípio avaliados apenas no Estado de Pernambuco, que possui uma rede mais densa de estações e, em seguida, no semiárido, com uma rede menos densa. Temporalmente, adotou-se passo de tempo diário e mensal em Pernambuco, considerando a maior densidade de postos; para o semiárido, o passo de tempo foi apenas diário, levando em consideração a menor densidade de postos e a finalidade de utilização dos dados, que é o cálculo do índice SWDI, obtido diariamente.

No Estado de Pernambuco, os índices estatísticos foram considerados individualmente (em cada ponto) e também 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) relativamente elevados, nas quatro mesorregiões consideradas (Figura 44). Para o SMAP e SMOS-IC, os índices foram superiores a 0,6, classificando a correlação como 'forte' (entre 0,61 e 0,80). Para o SMOS-CATDS, apenas na mesorregião do Agreste o CC foi igual a 0,6, sendo os demais classificados como 'moderados' (entre 0,41 e 0,6). Todas as correlações foram significativas a $p < 0,005$.

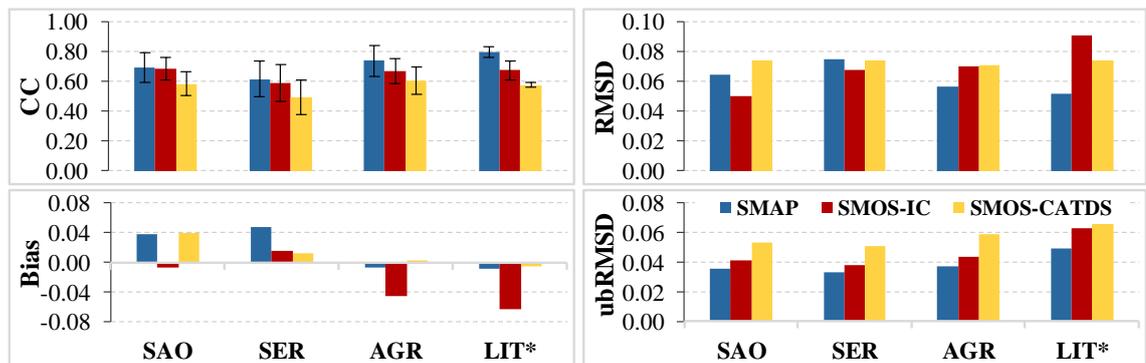


Figura 44. Índices estatísticos diários para os três produtos orbitais de umidade do solo sobre o Estado de Pernambuco. Barras verticais em CC indicam o desvio-padrão em torno da média; * Indica que apenas os pixels com dado no Litoral foram considerados.

Na mesorregião do Litoral/RMR, os valores de CC foram maiores, no entanto, não se pode inferir com precisão sobre esse padrão, considerando que nessa mesorregião a quantidade de estações é bastante limitada e, ainda, foram considerados nas estatísticas apenas os pixels que apresentavam dados em todos os produtos. Devido à proximidade do oceano, alguns satélites não geram dado, visto que a grande quantidade de água na faixa costeira presente na área do pixel leva a incertezas na estimativa, superestimando bastante a ‘umidade do solo’. Apenas os pixels dos produtos do SMOS (IC e CATDS) não possuem dado nessa região (pixels assinados como NaN – *Not a Number*).

Souza et al. (2018) também validaram o SMOS em Pernambuco utilizando a rede do CEMADEN como referência, no entanto, os autores utilizaram um outro produto, o SMOS-BEC, processado pelo *Barcelona Expert Center* (BEC). Essa necessidade de criar um dado reprocessado surgiu em virtude dos altos picos positivos e negativos da versão operacional, fornecida pelo CATDS, que levam a erros de estimativas. O SMOS-BEC também apresentou altos valores de CC em escala diária, superiores a 0,66 em todas as mesorregiões, de forma similar ao SMAP e SMOS-IC. Os valores inferiores do SMOS-CATDS, de fato, são resultado dos elevados picos do produto, que é mais susceptível a interferência de radiofrequência (RFI), especialmente em áreas bastante urbanizadas (HAJJ et al., 2018). Versões alternativas desse produto, como o SMOS-IC e SMOS-BEC, trazem melhorias ao algoritmo na tentativa de reduzir essas inconsistências (FERNANDEZ-MORAN et al., 2017; SOUZA et al., 2018).

Os valores de bias no SMOS-CATDS foram menores, novamente em virtude dos picos positivos e negativos do produto, que levam a um valor médio de erro mais próximo de zero, o que não indica que o SMOS-CATDS seja o mais preciso sobre Pernambuco. Esse padrão indica a necessidade de índices adicionais, como o Erro Médio Absoluto (EMA), que não é interferido por essa variação nos picos. No Sertão e São Francisco, o SMAP apresenta leve tendência de superestimativa, indicando que esse satélite possui maior limitação para mensurar valores de umidade do solo muito baixos, próximos do ponto murcha permanente. Já no Agreste e Litoral, o satélite mensura o conteúdo de água com erros próximos de zero. Nesse caso, há subestimativas registradas pelo SMOS-IC, que apresenta padrão inverso ao SMAP, sendo menos sensível nas respostas ao regime pluviométrico dessa região. Os erros do SMAP são mais reduzidos e admissíveis, já que se enquadram na faixa de precisão do satélite, de $\pm 0,04 \text{ m}^3 \text{ m}^{-3}$. Esse é o limiar para os três produtos utilizados.

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, que é o RMSD não enviesado (sem tendência). O SMAP é o satélite que apresenta menor ubRMSD. Aliado ao elevado valor de CC e bias dentro do limite admissível, é possível concluir que esse é, ao lado do SMOS-IC, o produto mais indicado para estimativa de umidade do solo em Pernambuco, mesmo com a sua resolução espacial inferior (36 km^2) quando comparado aos demais produtos (25 km^2).

Xiong et al. (2018), avaliando dados orbitais de umidade do solo e seu potencial hidrológico para aplicação em modelagem, em uma bacia da China, identificaram que o SMAP apresentou bom desempenho e o SMOS não gerou resultados satisfatórios, justificando esse padrão devido à alta sensibilidade do sensor à radiofrequência. Chen et al. (2017), comparando alguns produtos de umidade do solo, incluindo o SMAP e SMOS, também perceberam que o SMAP é mais preciso, especialmente porque captura bem a amplitude e variação temporal da umidade do solo, com boa resposta a eventos de chuva.

Por ser um satélite mais recente (lançado em 2015) e com algoritmo e sensores mais refinados, melhores resultados com o SMAP são esperados,

mesmo com a sua limitante resolução espacial. Ainda assim, é importante considerar que os produtos alternativos do SMOS, como o próprio SMOS-IC e o SMOS-BEC também representam ótimas opções de estudo. Esse último, inclusive, foi validado e aplicado em todo o território de Pernambuco (SOUZA et al., 2018). O SMOS-IC já foi previamente avaliado apenas na mesorregião do São Francisco, apresentando resultados muito consistentes em condições de seca, com escassez de precipitação (ARAÚJO et al., 2018).

Em escala temporal mensal, os resultados são similares, já que caracterizam a média dos dados diários para aquele mês. Embora os valores de CC tendam a se aproximar, é notável que o SMAP, novamente, apresenta maior correlação e menor ubRMSD (Figura 45). O menor valor de bias do SMOS-CATDS não é considerado porque é resultante do equilíbrio dos picos máximos e mínimos do produto, que fogem bastante dos valores mensurados em superfície. Para melhor compreensão, basta visualizar o ubRMSD desse produto para perceber que ele é o que apresenta maior problema nas estimativas. Esse padrão será melhor discutido na análise da validação pontual.

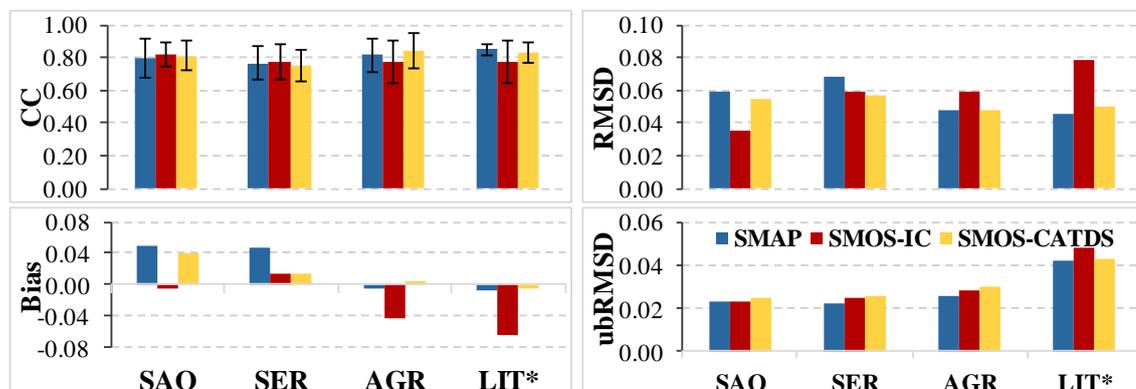


Figura 45. Índices estatísticos mensais para os três produtos orbitais de umidade do solo sobre o Estado de Pernambuco. Barras verticais em CC indicam o desvio-padrão em torno da média; * Indica que apenas os pixels com dado no Litoral foram considerados.

O resumo estatístico da validação diária e mensal pode ser visualizado na Tabela 6. Os maiores valores de CC do SMAP em escala diária são perceptíveis, bem como os menores valores de ubRMSD. Em escala mensal, o SMOS-IC é levemente superior ao SMAP nas mesorregiões mais secas (Sertão e São Francisco) em termos de CC, no entanto, o segundo produto

continua apresentando valores de ubRMSD menores, favorecendo os seus dados.

Tabela 6. Resumo estatístico da avaliação dos dados estimados pelo SMAP, SMOS-IC e SMOS-CATDS em Pernambuco, em base diária e mensal.

	DIÁRIO											
	SMAP				SMOS-IC				SMOS-CATDS			
	CC	Bias	RMSD	ubRMSD	CC	Bias	RMSD	ubRMSD	CC	Bias	RMSD	ubRMSD
SAO	0,695	0,038	0,065	0,036	0,68	-0,007	0,050	0,041	0,587	0,039	0,074	0,053
SER	0,617	0,048	0,075	0,033	0,59	0,015	0,068	0,038	0,493	0,012	0,074	0,051
AGR	0,741	-0,007	0,057	0,037	0,67	-0,045	0,070	0,044	0,604	0,003	0,071	0,059
LIT	0,796	-0,009	0,052	0,049	0,68	-0,064	0,091	0,063	0,578	-0,005	0,074	0,069
	MENSAL											
SAO	0,798	0,049	0,059	0,023	0,82	-0,004	0,035	0,023	0,810	0,040	0,055	0,025
SER	0,767	0,047	0,068	0,022	0,77	0,015	0,059	0,025	0,754	0,013	0,057	0,026
AGR	0,819	-0,005	0,048	0,026	0,78	-0,043	0,059	0,028	0,839	0,005	0,048	0,030
LIT	0,849	-0,008	0,046	0,042	0,77	-0,063	0,079	0,048	0,832	-0,006	0,050	0,043

SÃO = São Francisco; SER = Sertão; AGR = Agreste; LIT = Litoral.

Nas mesorregiões do Sertão e São Francisco, o SMAP superestimou os dados diários de umidade do solo em 76,51% das estações, ao passo que o SMOS-IC superestimou em apenas 43,69%. Para dados mensais, os valores superestimados foram de 81,06% e 48,23%, respectivamente, o que evidencia a tendência de superestimativa do SMAP. Devido aos elevados picos, o SMOS-CATDS apresentou valores diários e mensais iguais, de 73,24%.

Em termos de CC, tanto o SMAP quanto o SMOS-IC apresentaram desempenho igual nessas mesorregiões quando se considera o percentual de correlações classificadas como fortes ($> 0,60$). Os dois produtos obtiveram um percentual de correlações fortes de 82,07% e 87,63% em dados diários e mensais, respectivamente. Já para o SMOS-CATDS, o percentual foi de apenas 29,29% em dados diários, aumentando para o intervalo mensal, com 92,17%, o que chega a ser interessante, visto que o produto se mostrou até mesmo superior aos demais em escala mensal.

Em direção ao litoral, conforme aumentam os valores de precipitação, a situação tende a alterar. Na mesorregião do Agreste, o SMAP apresentou 92,00% das estações com correlação acima de 0,60 (forte) em dados diários. Para dados médios mensais, esse valor foi de 100%. Já o SMOS-IC obteve valores de 80,00% e 92,00%, respectivamente. O SMOS-CATDS, novamente, tende a ser inferior em dados diários com percentual de CC acima de forte de

56,00%. No entanto, esse produto se iguala ao SMOS-IC em dados mensais, com 92,00% de valores de CC acima de 0,61. A mesorregião do Litoral não foi avaliada devido à limitação de estações, no entanto, o SMAP novamente se sobressai em relação aos demais.

Como forma de ilustrar melhor o desempenho de cada produto nas diferentes mesorregiões do Estado, foram selecionadas aleatoriamente duas estações de cada uma delas (Figura 46). É nítido que os três produtos representam bem a variação temporal diária da umidade do solo, sendo sensíveis a eventos de chuva. No entanto, percebe-se os picos aleatórios do SMOS-CATDS anteriormente citados. Picos ainda maiores existiam nos dados originais, mas grande parte deles foi filtrado e removido, conforme critérios baseados em interferência de radiofrequência e índice de qualidade dos dados, sugeridos pelo desenvolvedor. Em todas as estações destacadas, o SMAP tende a apresentar leituras com valores mais elevados que o SMOS-IC, o que evidencia a dificuldade desse satélite em mensurar valores de umidade do solo muito baixos. O SMOS-IC, inclusive, representa uma modificação do SMOS-CATDS, com bom potencial de detecção de valores mínimos de umidade do solo, o que pode ser de grande vantagem em regiões semiáridas (FERNANDEZ-MORAN et al., 2017).

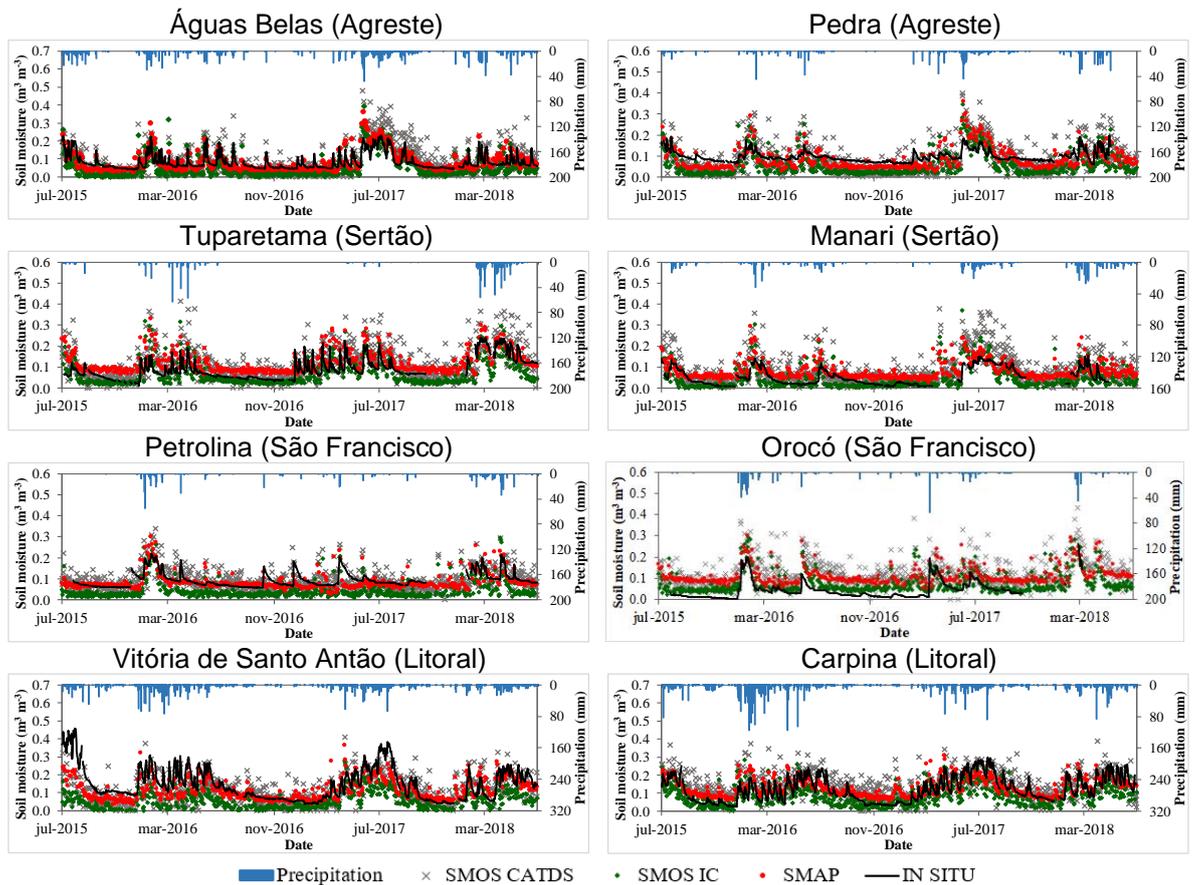


Figura 46. Comparação dos dados diários de umidade do solo medidos *in situ* e estimados por sensoriamento remoto (SMAP, SMOS-IC e SMOS-CATDS) para o período de julho de 2015 a junho de 2018; Soil moisture: umidade do solo.

Os diagramas de dispersão ou correlação, 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. No caso de Pernambuco, percebe-se que o SMAP é o satélite que mensura os dados de umidade do solo de forma mais precisa (Figura 47), considerado que os pontos tendem a estar sempre mais próximos da linha de ajuste (linha 1:1). Os diagramas também permitem detectar que o SMAP tende a emitir valores sempre superiores ao SMOS-IC. No Agreste e Litoral, essa característica acaba favorecendo o SMAP, que estima valores mais próximos ao observados em superfície. Esse padrão, aliado aos maiores valores de CC, indica que o satélite é mais sensível a variações no regime pluviométrico, conseguindo detectar com maior precisão e de forma mais rápida os eventos de chuva.

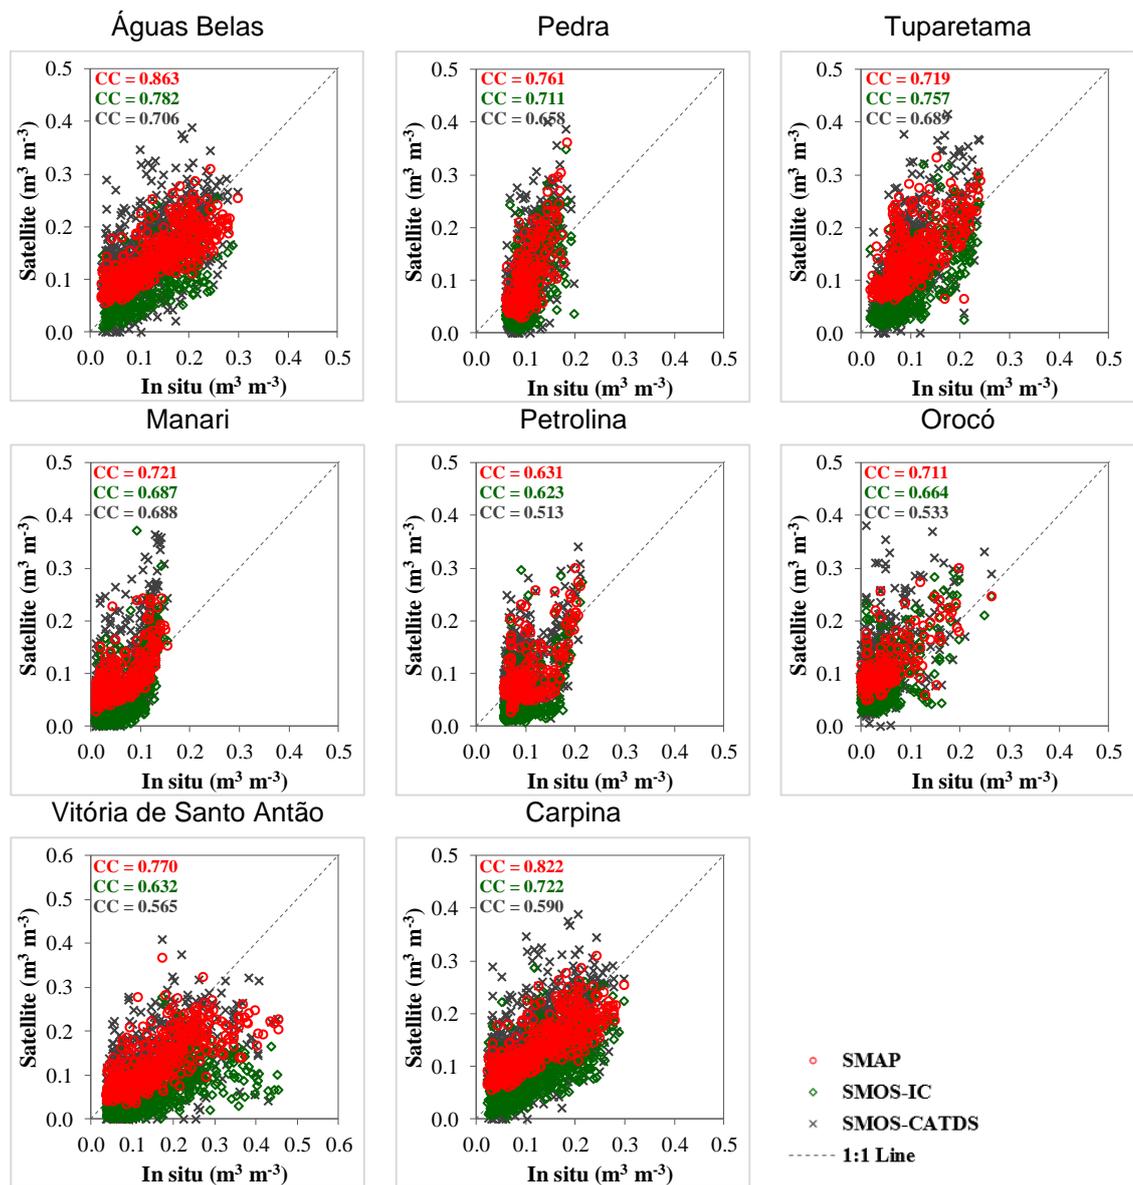


Figura 47. Diagramas de dispersão dos dados diários de umidade do solo, obtidos in situ e estimados por produtos de sensoriamento remoto, para o período de julho de 2015 a junho de 2018.

A análise pontual, considerando os resultados dos índices estatísticos obtidos quando o pixel é comparado a cada estação, pode ser mais apropriada quando se deseja utilizar os dados do satélite de forma localizada, especialmente para fins de modelagem hidrológica. Além disso, esse tipo de avaliação permite perceber mais claramente as variações de precisão dos produtos em pequena escala, facilitando a seleção daquele que melhor representa os padrões espaciais e temporais da área de estudo.

A distribuição espacial do CC diário e mensal para as diferentes mesorregiões do Estado pode ser visualizado na Figura 48. Conforme

anteriormente discutido, nota-se que o SMAP tende a se sobressair em relação aos demais produtos em escala temporal diária. O SMOS-CATDS é o produto com pior desempenho, apresentando maior parte das correlações com classificação ‘moderada’, sendo levemente mais consistente no Agreste. Para valores médios mensais de umidade do solo, os dois satélites (e os três produtos) incrementam bastante a eficácia das estimativas em termos de CC, indicando que a flutuação temporal dos dados é muito similar à mensurada *in situ*. Vale destacar que o SMOS não apresenta valores de umidade do solo nos pixels conectados à faixa costeira, dada a presença de água. Já o SMAP, mesmo nessas condições, consegue gerar dados, embora muito superestimados e inconsistentes, com CC variando de 0,41 a 0,60 (moderado).

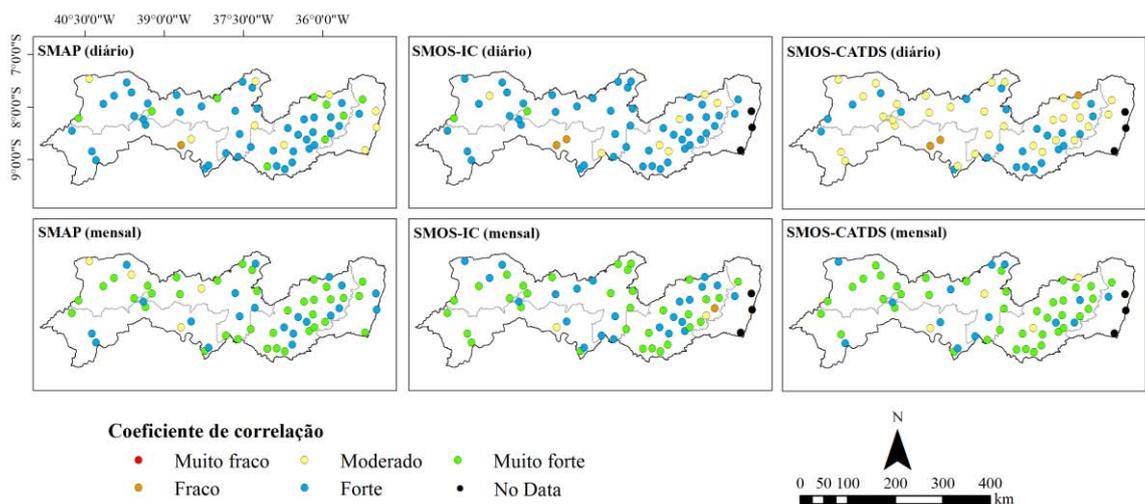


Figura 48. Coeficiente de correlação (CC) para dados diários e mensais de umidade do solo obtidos por sensoriamento remoto sobre o Estado de Pernambuco; valores médios para o período de jul/2015 a jun/2018.

Os dados estatísticos espaço-temporais de bias indicam o padrão de subestimativa ou superestimativa dos produtos e confirmam os resultados obtidos por média nas diferentes mesorregiões (Figura 49). O SMAP, de modo geral, superestima a umidade do solo nas mesorregiões mais secas, indicando as limitações do sensor na detecção adequada do conteúdo de água residual, próximo ou dentro do ponto de murcha permanente. Já o SMOS-IC tende a subestimar, embora em menor magnitude. No Agreste, o SMAP apresenta valores de bias mais próximos de zero, ao passo que o SMOS-IC estima dados com valores bem menores que os mensurados em superfície, evidenciando subestimativas do produto e sua maior dificuldade em responder a eventos de chuva e consequente aumento do armazenamento de água nessa região. No

caso do SMOS-CATDS, a variabilidade dos dados de bias é alta, com muitos valores de erro próximos de zero, outros subestimados ou superestimados. Isso ocorre em virtude dos picos nas leituras do sensor. O mesmo padrão é percebido em dados diários e mensais para os dois satélites.

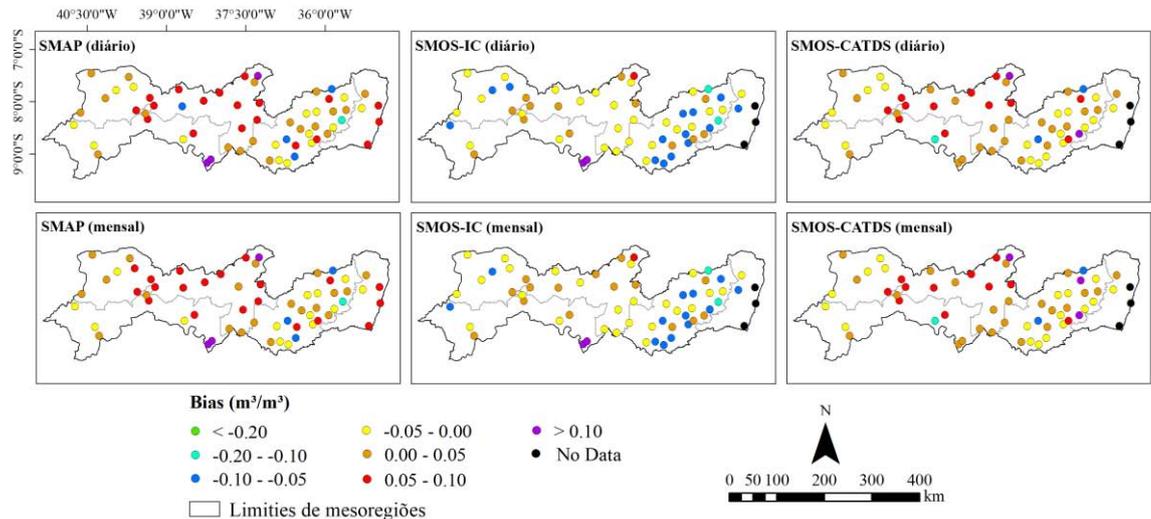


Figura 49. Valores de tendência (bias) para dados diários e mensais de umidade do solo obtidos por sensoriamento remoto sobre o Estado de Pernambuco; valores médios para o período de jul/2015 a jun/2018.

Dependendo da localização na área de estudo no globo, a variação dos dados de bias e CC pode ser muito grande. Hajj et al. (2018), por exemplo, validando produtos de quatro satélites na França, incluindo o SMAP e SMOS (produtos IC e CATDS), detectaram, para o SMAP, valores de bias de $-0,054 \text{ m}^3 \text{ m}^{-3}$ ao contrário do que foi percebido em Pernambuco. Para o SMOS-IC e SMOS-CATDS, a subestimativa foi ainda mais expressiva, de $-0,109$ e $-0,112 \text{ m}^3 \text{ m}^{-3}$, muito maior do que o limiar de precisão dos produtos, que é de $\pm 0,04 \text{ m}^3 \text{ m}^{-3}$. Para o CC, os valores foram de 0,69, 0,57 e 0,42 para o SMAP, SMOS-IC e SMOS-CATDS, respectivamente, indicando também que o satélite da NASA foi mais preciso, mesmo com sua menor resolução espacial.

O desvio da raiz quadrada média (RMSD) tem distribuição similar no SMAP e SMOS-IC, embora o primeiro apresente valores médios maiores no Sertão e São Francisco e, o segundo, no Agreste (Figura 50). Essa distribuição do RMSD é similar à de bias, evidenciando alteração no padrão de estimativa dos dois produtos nessas duas mesorregiões. Na faixa costeira do Litoral, é perceptível que o SMAP, apesar de conseguir estimar dados de umidade do solo, registra informações muito inconsistentes. É nesse local onde os erros

são mais expressivos ($> 0,12 \text{ m}^3 \text{ m}^{-3}$), inviabilizando a possibilidade de uso do satélite. Em passo de tempo diário, o SMOS-CATDS apresenta os maiores valores de RMSD, embora eles reduzam quando se considera dados mensais.

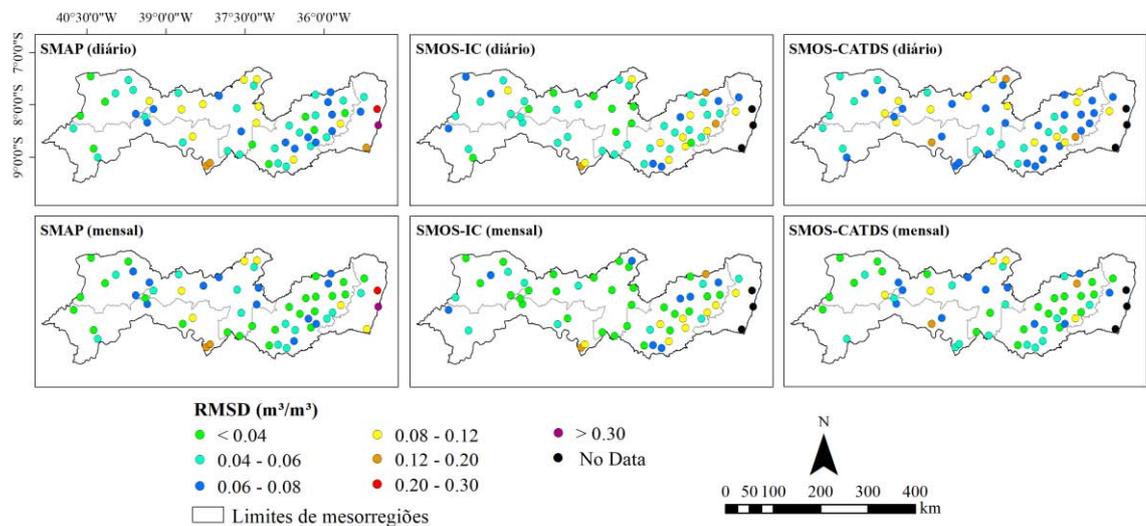


Figura 50. Valores de RMSD para dados diários e mensais de umidade do solo obtidos por sensoriamento remoto sobre o Estado de Pernambuco; valores médios para o período de jul/2015 a jun/2018.

Souza et al., (2018), avaliando o produto SMOS-BEC em Pernambuco, encontraram valores de RMSD variando de 0,02 a 0,06 $\text{m}^3 \text{ m}^{-3}$ em dados diários de umidade do solo. Esses valores foram um pouco inferiores ao encontrados com o SMOS-IC e SMOS-CATDS. No entanto, deve-se considerar a estratégia de validação utilizada. Além disso, é possível que o SMOS-BEC seja mais preciso sobre o Estado, o que justifica menores valores de RMSD. Já Zhang et al. (2017), validando o SMAP nos Estados Unidos, encontraram valores de RMSD para dados médios mensais entre 0,09 e 0,15 $\text{m}^3 \text{ m}^{-3}$, bem superiores aos registrados em Pernambuco nos produtos avaliados neste trabalho (SMAP, SMOS-IC e SMOS-CATDS) e no que foi utilizado por Souza et al., (2018).

Os dados de desvio da raiz quadrada média não-tendenciosa (ubRMSD), ao contrário dos de RMSD, tendem a apresentar maior alteração em escala temporal mensal, reduzindo os valores e enquadrando-os dentro do limiar de precisão dos produtos orbitais ($\pm 0,04 \text{ m}^3 \text{ m}^{-3}$). Esse índice, ao contrário do RMSD, faz um filtro e remoção das possíveis tendências resultantes de erros sistemáticos dos sensores, sendo um valor de erro mais 'real' e representativo, com maior impacto na seleção do produto mais

adequado sobre o Estado. Nesse sentido, o SMAP (da NASA), apresenta menores valores de ubRMSD, tanto para dados diários quanto mensais (Figura 51). Essa característica, aliada aos elevados valores de CC e bias reduzidos, tornam o satélite a melhor opção para monitoramento da umidade do solo em Pernambuco, seguido do SMOS-IC.

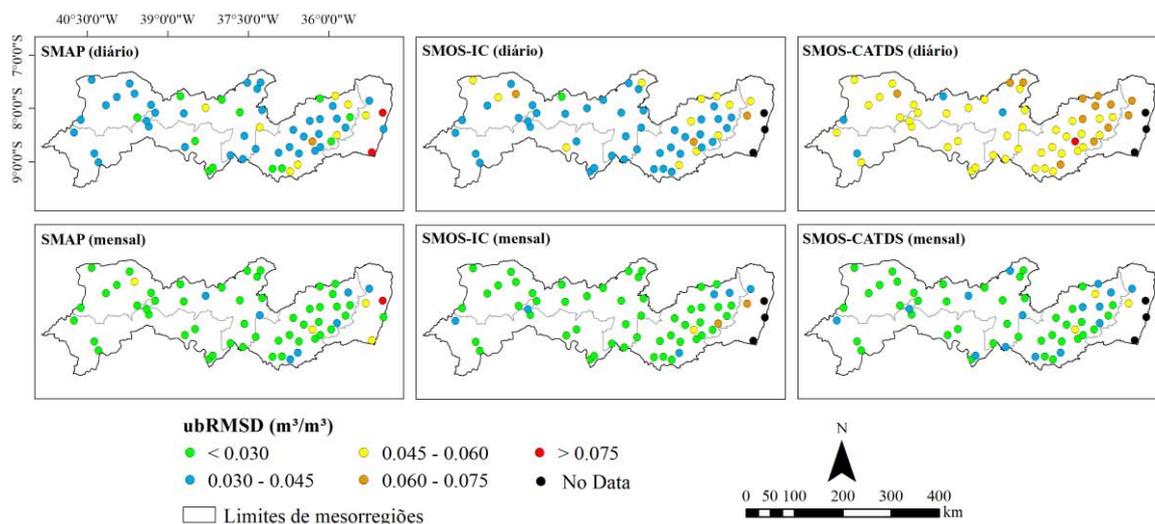


Figura 51. Valores de ubRMSD para dados diários e mensais de umidade do solo obtidos por sensoriamento remoto sobre o Estado de Pernambuco; valores médios para o período de jul/2015 a jun/2018.

3.2 Avaliação dos dados orbitais de umidade do solo no Semiárido

A validação no Estado de Pernambuco, que possui mais de 80% do seu território inserido na região semiárida, teoricamente já seria suficiente para afirmar que os produtos diários e mensais do SMAP e SMOS-IC são os que melhor estimam a umidade do solo nas condições avaliadas. No entanto, como forma de melhor representar a viabilidade dos produtos em todo o semiárido, uma avaliação mais simplificada, baseada apenas em dados diários e com validação 'pixel a ponto' (valor do pixel comparado diretamente ao da estação), sem considerar dados médios por área, foi realizada.

A utilização de dados apenas diários foi selecionada porque o intuito é calcular o índice de seca SWDI, que requer dados diários de umidade do solo. Já a avaliação por área não foi realizada porque o semiárido é caracterizado por possuir condições climáticas relativamente homogêneas, ao contrário do Estado de Pernambuco como um todo, que está inserido em duas zonas climáticas distintas. Além disso, para aumentar a consistência dos resultados,

as estações de Pernambuco inseridas na faixa semiárida também foram integradas, totalizando 130 pontos de validação. As estações da Zona da Mata Pernambucana, apesar de representadas nos mapas a seguir, não foram consideradas nas estatísticas.

Os valores médios CC para os três produtos foram de 0,70, 0,66 e 0,56 para o SMAP, SMOS-IC e SMOS-CATDS, respectivamente. A mesma tendência observada em Pernambuco foi percebida no semiárido, com o SMAP se sobressaindo em relação aos demais em escala temporal diária. Esses dados representam uma média para todo o semiárido, incluindo as estações inseridas em Pernambuco. Em dados percentuais, os valores de CC foram classificados como fortes (> 0,60) em 81,54%, 78,74% e 42,62% das estações nos três produtos.

A partir da distribuição espacial dos pontos, percebe-se que o SMAP e SMOS-IC são muito similares em termos de CC, o que justifica os valores muito próximos. Já o SMOS-CATDS tende a apresentar muitos pontos com CC classificada como fraca (0,21 a 0,40) e moderada (0,41 a 0,60). Além disso, esse produto, que representa a versão operacional (original) dos dados do satélite SMOS, gera dados inconsistentes ou muito falhos em alguns pixels a sudeste e sul do semiárido, que foram descartados para a validação (Figura 52).

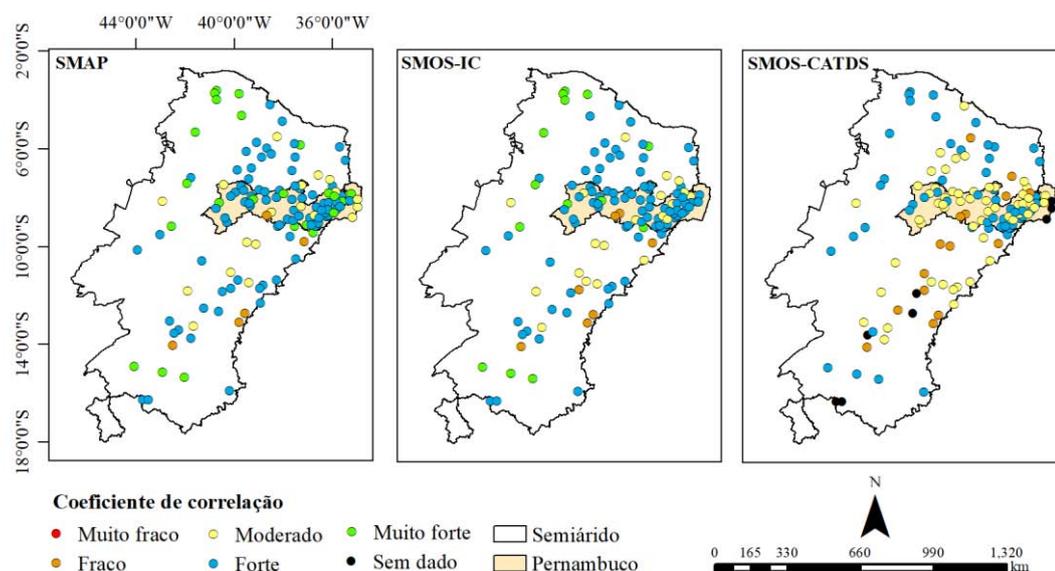


Figura 52. Valores de CC para dados diários de umidade do solo obtidos por sensoriamento remoto sobre o Semiárido Brasileiro; valores médios para o período de jul/2015 a jun/2018.

A mesma tendência de bias percebida em Pernambuco também foi notada em todo o semiárido, com o SMAP superestimando ($0,025 \text{ m}^3 \text{ m}^{-3}$) e o SMOS-IC subestimando ($-0,019 \text{ m}^3 \text{ m}^{-3}$) os dados de umidade do solo. O SMOS-CATDS apresentou bias de $0,018 \text{ m}^3 \text{ m}^{-3}$. Embora o valor de bias tenha sido menor que os demais, isso foi favorecido pela incidência de picos negativos e positivos, que levam a um maior equilíbrio da média, deixando-a mais próxima de zero. Apesar disso, o SMOS-CATDS é o produtor de pior desempenho. Tanto o SMAP quanto o SMOS (IC e CATDS) evidenciaram valor de bias dentro do limiar de precisão dos satélites, que é de $\pm 0,04 \text{ m}^3 \text{ m}^{-3}$.

A distribuição de bias em todos os pontos considerados na validação pode ser visualizada na Figura 53. Tanto na densa rede de Pernambuco quanto no restante do semiárido, é possível perceber que o SMAP superestima os dados em muitos pontos, enquanto o SMOS-IC subestima na mesma magnitude. Mais uma vez, esse padrão evidencia a dificuldade do SMAP em estimar dados de umidade muito baixos, próximos ou inferiores à capacidade de campo, enquanto o SMOS-IC 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.

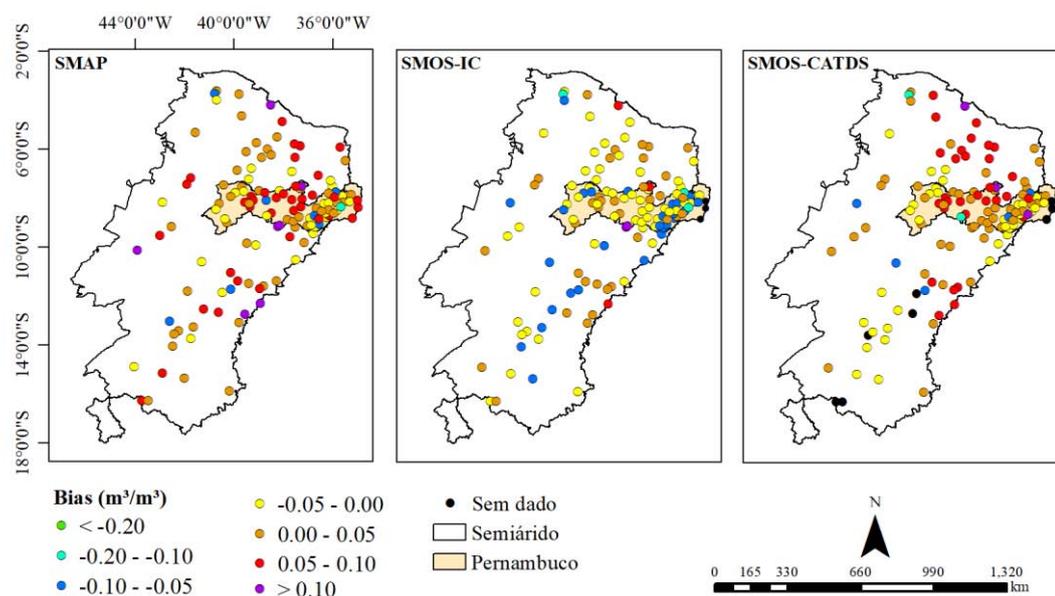


Figura 53. Valores de tendência (bias) para dados diários de umidade do solo obtidos por sensoriamento remoto sobre o Semiárido Brasileiro; valores médios para o período de jul/2015 a jun/2018.

Os valores de ubRMSD, que indicam o desvio da raiz quadrada média após a remoção de tendências e erros sistemáticos de cada sensor, foram de

0,043, 0,047 e 0,067 $\text{m}^3 \text{m}^{-3}$ para o SMAP, SMOS-IC e CATDS, respectivamente. Os resultados indicam, novamente, que o SMAP é o satélite que melhor representa os dados de umidade do solo sobre o semiárido, ainda que tenda levemente à superestimativa.

Os três produtos possuem valores de ubRMSD levemente superiores a $\pm 0,04 \text{ m}^3 \text{ m}^{-3}$ sobre o semiárido. Esse valor corresponde à precisão das estimativas dos satélites, indicando o desvio esperado nos dados registrados sem grande comprometimento na qualidade da informação obtida, por esse motivo, esse valor limiar é utilizado na maioria dos trabalhos de validação como um padrão para interpretação do bias, RMSD e ubRMSD. Ainda que levemente maiores, esses valores indicam o elevado potencial dos produtos, especialmente o SMAP e SMOS-IC. Globalmente, é bastante comum encontrar valores de ubRMSD bem maiores associados a menores coeficientes de correlação, mas ainda assim os autores indicarem a utilização dos dados estimados (CHEN et al., 2017; HAJJ et al., 2018; ZHANG et al., 2017).

A distribuição espacial do ubRMSD ao longo do semiárido, nas 130 estações utilizadas para validação, evidenciam o padrão similar dos produtos SMAP e SMOS-IC e a maior tendência de superestimativa do SMOS-CATDS, com grande quantidade de pontos apresentando valores acima de $0,060 \text{ m}^3 \text{ m}^{-3}$ (Figura 54).

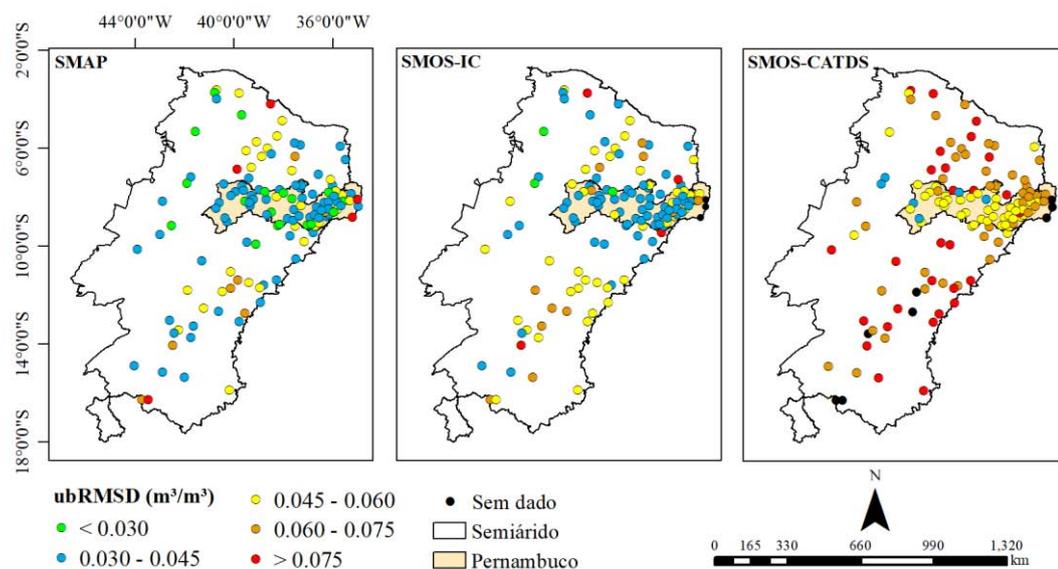


Figura 54. Valores de ubRMSD para dados diários de umidade do solo obtidos por sensoriamento remoto sobre o Semiárido Brasileiro; valores médios para o período de jul/2015 a jun/2018.

O resumo estatístico dos índices utilizados para avaliação dos três produtos pode ser observado na (Figura 55). Conforme supracitado, fica evidente a melhor performance do SMAP e SMOS-IC em detrimento do SMOS-CATDS, que é a versão operacional do satélite da ESA, fornecia logo após a passagem.

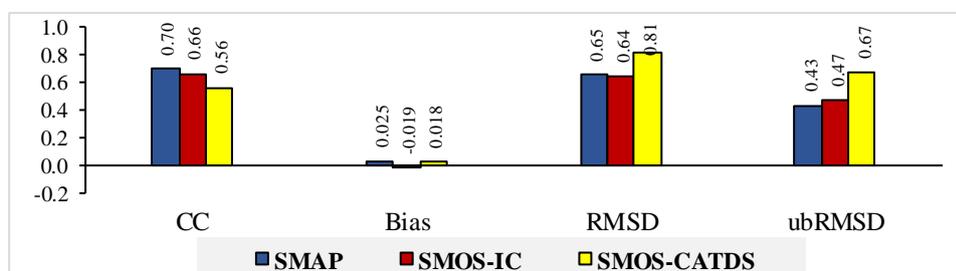


Figura 55. Índices estatísticos diários para os três produtos orbitais de umidade do solo sobre o semiárido.

Considerando as validações em Pernambuco e no Semiárido, o satélite selecionado para avaliação do índice de seca SWDI foi o SMAP. Primeiro porque os seus dados tendem a ser mais similares aos mensurados temporalmente (maior CC), além de apresentar menores tendências de estimativa e susceptibilidade a erros sistemáticos (ubRMSD). Além disso, trata-se de um dos instrumentos mais recentes destinados ao monitoramento da umidade do solo, lançado em 2015, com sensores e algoritmos bastante atualizados.

Embora possua menor resolução espacial (36 km²), o SMAP consegue mensurar com grande precisão a umidade do solo, destacando ainda mais a sensibilidade do seu sensor de microondas passivo. Essa resolução, por sinal, pode ser refinada com técnicas de *downscaling* e, inclusive, a própria NASA fornece um produto ‘melhorado’ com resolução espacial de 9 km². Esse último não foi validado porque o objetivo do trabalho é utilizar os produtos operacionais ou minimamente reprocessados de cada satélite, em sua resolução nativa.

Essas características tornam o SMAP o satélite mais utilizado globalmente para avaliação da seca agrícola utilizando o índice SWDI em conjunto com o AWD, já que ambos estão relacionados à demanda e armazenamento hídrico no solo e atmosfera (BAI et al., 2018a; MISHRA et al., 2017).

3.3 Índices de seca SWDI e AWD

Os dados de umidade do solo do SMAP, apesar de recentes e com série curta, já são utilizados para monitoramento e compreensão da extensão de fenômenos de seca agrícola. Através da plataforma Google Earth Engine (GEE), por exemplo, são cedidos diariamente dados de anomalias globais de umidade do solo obtidos através de produtos do SMAP. Os dados são adimensionais e representam as anomalias padronizadas de umidade do solo utilizando uma janela deslizante de 31 dias, com o dia referente à anomalia centrado no meio desse intervalo (SAZIB et al., 2018).

Como se tratam de 'anomalias', os dados do GEE acabam não sendo muito representativos, já que a série do SMAP é curta. Dessa forma, o índice apenas indica se o dia referente às anomalias apresentou conteúdo de água baixo ou alto quando comparado ao mesmo dia nos demais anos da série. Do ponto de vista agrícola, essa informação pode dificultar o planejamento e tomada de decisões. Pensando nisso, surge como alternativa o índice SWDI, que considera as próprias propriedades físicas do solo para indicar se o armazenamento de água, no dia da passagem do satélite, esteve abaixo ou dentro do requerido pelas culturas, com valores menores que -10,00 indicando condições de ponto de murcha permanente (MARTÍNEZ-FERNÁNDEZ et al., 2016). Por esse motivo, a dimensão da série de dados torna-se irrelevante, já que o SWDI pode ser obtido apenas com dados de um único dia.

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, uma validação para checar 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. 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.

Nas estações consideradas no semiárido, o valor médio de CC entre o SWDI e AWD foi 0,74, classificado como forte. O percentual de correlações acima de 0,60 foi de 88%, indicando a forte relação entre os dois índices e 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. Em apenas dois casos, que correspondem a 4,08%, as correlações foram inferiores a 0,40 (fracas a muito fracas); nos dois casos, as estações estão localizadas no Estado da Bahia, em locais de maior precipitação. O resumo estatístico apresentando os valores de CC, SWDI e AWD médios para cada estação considerada pode ser observado na Tabela 7.

Tabela 7. Resumo estatístico dos dados de SWDI e AWD nas estações do INMET consideradas para a validação. CC: coeficiente de correlação; PMP: ponto de murcha permanente (déficit hídrico absoluto).

MUNICÍPIO	UF	LON	LAT	CC	MÉDIA SWDI	MÉDIA AWD
PÃO DE ACUCAR	AL	-37.43	-9.75	0.82	-12.03	-28.48
LENÇÓIS	BA	-41.38	-12.55	0.17	-8.67	-37.48
BARREIRAS	BA	-45.02	-12.15	0.35	-13.79	-26.86
LUIZ EDUARDO MAGALHÃES	BA	-45.81	-12.15	0.83	-11.81	-28.58
ITABERABA	BA	-40.28	-12.52	0.70	-13.10	-23.25
MACAJUBA	BA	-40.35	-12.12	0.77	-12.82	-20.97
VITÓRIA DA CONQUITSTA	BA	-40.47	-14.88	0.75	-8.02	-19.47
SANTA RITA DE CÁSSIA	BA	-44.52	-11.02	0.80	-11.18	-22.03
REMANSO	BA	-42.10	-9.60	0.73	-5.88	-45.03
IRECÊ	BA	-41.85	-11.32	0.58	-15.80	-32.04
SENHOR DO BONFIM	BA	-40.13	-10.43	0.77	-10.10	-23.86
BARRA	BA	-43.13	-11.08	0.61	-12.92	-31.85
PIATÁ	BA	-41.77	-13.15	0.70	-6.19	-21.80
BURITIRAMA	BA	-43.65	-10.72	0.79	-9.10	-22.49
BRUMADO	BA	-41.33	-14.18	0.85	-15.69	-22.86
AMARGOSA	BA	-39.61	-13.00	0.76	-6.05	-13.42
UAUÁ	BA	-39.48	-9.83	0.81	-11.71	-36.98
QUEIMADAS	BA	-39.62	-10.98	0.82	-13.65	-35.23
IBOTIRAMA	BA	-43.20	-12.18	0.82	-9.50	-32.26
JACOBINA	BA	-40.45	-11.20	0.61	-11.35	-22.38
SERRINHA	BA	-39.02	-11.65	0.85	-11.70	-24.36
EUCLIDES DA CUNHA	BA	-38.98	-10.53	0.76	-13.42	-29.32
DELFINO	BA	-41.20	-10.45	0.80	-10.50	-31.59
ITAPETINGA	BA	-40.22	-15.23	0.77	-12.52	-22.17
JAGUARIBE	CE	-38.62	-5.90	0.84	-12.28	-37.48
GUARAMIRANGA	CE	-38.18	-4.25	0.74	-6.31	1.46

BARBALHA	CE	-39.27	-7.30	0.59	-12.63	-32.50
IGUATÚ	CE	-36.27	-6.38	0.44	-13.92	-28.84
TAUÁ	CE	-40.27	-6.02	0.82	-10.89	-31.56
QUIXERAMOBIM	CE	-39.28	-5.17	0.72	-10.38	-30.35
CRATEUS	CE	-40.67	-5.18	0.81	-9.56	-29.52
CAMPOS SALES	CE	-40.35	-7.07	0.76	-11.41	-24.46
ITAPIPOCA	CE	-39.58	-3.48	0.83	-8.17	-30.31
ACARAU	CE	-40.08	-3.17	0.89	-6.90	-27.85
PATOS	PB	-37.26	-7.06	0.79	-11.72	-43.79
CAMPINA GRANDE	PB	-35.88	-7.22	0.81	-8.94	-23.85
SÃO GONCALO	PB	-38.22	-6.75	0.83	-13.08	-29.15
CABACEIRAS	PB	-36.28	-7.48	0.75	-11.16	-36.41
PETROLINA	PE	-40.48	-9.38	0.77	-11.98	-42.43
ARCOVERDE	PE	-37.05	-8.43	0.77	-12.89	-34.20
GARANHUNS	PE	-36.48	-8.90	0.85	-8.95	-13.75
CABROBÓ	PE	-39.30	-8.48	0.80	-10.97	-35.99
CARUARU	PE	-35.95	-8.28	0.74	-11.59	-33.44
IBIMIRIM	PE	-37.70	-8.50	0.69	-10.82	-39.61
SERRA TALHADA	PE	-38.28	-7.95	0.77	-11.14	-33.94
FLORESTA	PE	-38.58	-8.60	0.66	-9.48	-40.19
OURICURI	PE	-40.10	-7.88	0.57	-14.40	-43.18
APODI	RN	-37.78	-5.66	0.80	-11.90	-34.90
SANTA CRUZ	RN	-36.02	-6.22	0.82	-10.41	-30.74
MÉDIA				0.74	-11.01	-29.52

Classificação do CC					SWDI
Muito fraca	Fraca	Moderada	Forte	Muito forte	PMP

Com base nos dados pontuais apresentados na Tabela 7, já é possível perceber a tendência de valores negativos de SWDI para o semiárido brasileiro no período de julho de 2015 a junho de 2018, com valor médio de -11,01, indicando que as culturas e/ou vegetação nativa, em maior parte do tempo, estiveram em condições de estresse hídrico devido ao baixo armazenamento de água no solo (ponto de murcha permanente). Essa condição já era esperada em virtude da severa seca que assolou o semiárido em 2012, sendo considerada a maior e mais crítica dos últimos anos. Embora tenha sido extrema no ano de 2012, a seca ainda perdurou pelos anos seguintes, mantendo-se presente inclusive no período considerado nesse estudo (ROSSATO et al., 2017; SOUZA et al., 2018). Ainda que não fossem registrados eventos de seca, valores negativos de SWDI seriam comuns, considerando as características climáticas do semiárido.

Temporalmente, a flutuação dos índices SWDI e AWD 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). Logo, quando chove, ambos os índices aumentam, visto que tanto o conteúdo de água no solo quanto na atmosfera incrementa, com precipitação superior à evapotranspiração. Quando cessa o período chuvoso, a evapotranspiração é o único fenômeno ativo, regulando a saída de água e aumentando a demanda hídrica do solo. Isso causa impacto direto nos índices, que ficam negativos. Esse padrão é sempre detectado em estudos que visam a comparação dos dois índices, desde que os dados do satélite de umidade do solo representem bem a variação *in situ* (BAI et al., 2018a; MARTÍNEZ-FERNÁNDEZ et al., 2016).

Na Figura 56 está a representação dos índices SWDI e AWD em algumas estações de cada um dos estados que foram considerados nas avaliações. Claramente percebe-se a grande similaridade de variação temporal entre os dois índices, embora sejam distintos (escalas de valores diferentes). Essa alta similaridade é justificada pelos elevados valores de CC e, de forma indireta, também confirma o grande potencial do SMAP para capturar adequadamente as variações de umidade do solo nas diferentes porções do semiárido brasileiro. Em maior parte do tempo, os valores de SWDI foram negativos. Deve-se considerar que esse índice atinge valor crítico, com seca extrema, quando se torna inferior a -10,00. Esse valor limite representa o déficit hídrico absoluto, que equivale, dentro da visão agrícola, ao ponto de murcha permanente.

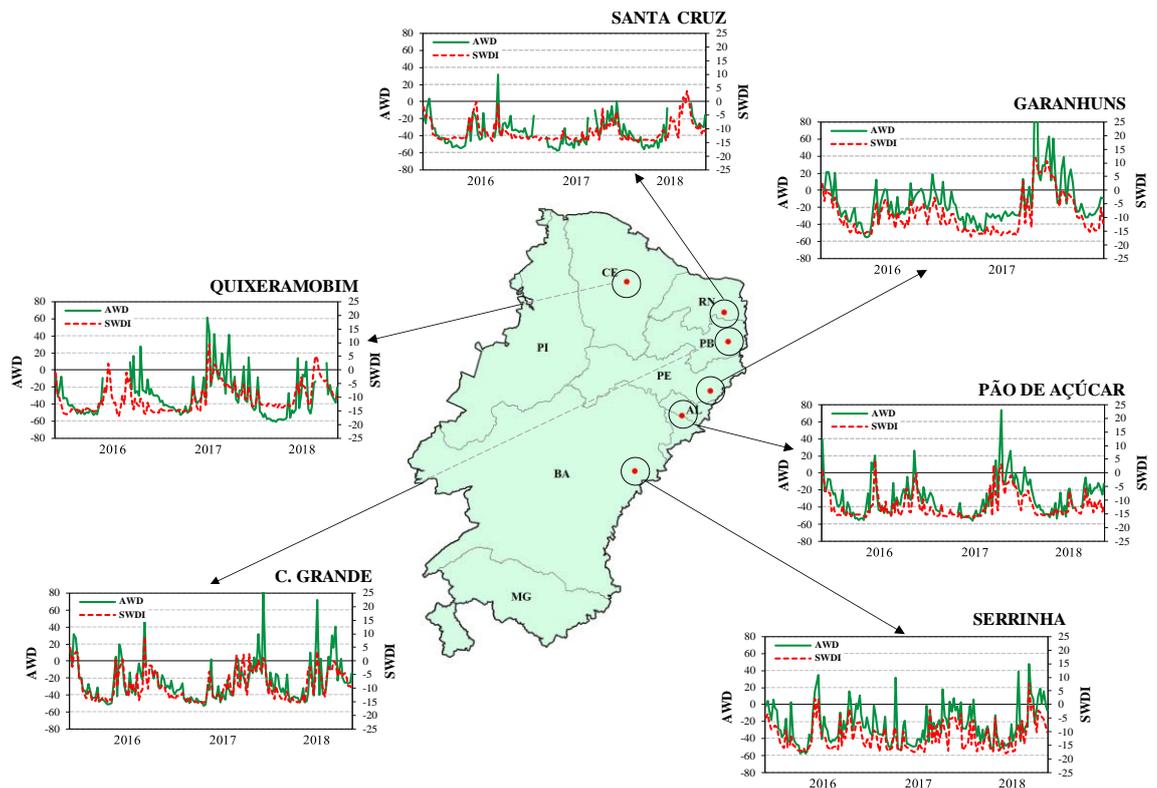


Figura 56. Variação semanal dos índices SWDI e AWD em algumas estações de cada um dos estados do semiárido que foram considerados nas avaliações.

Os diagramas de dispersão das estações anteriores, referentes ao SWDI-AWD semanais, podem ser visualizados na Figura 57. Novamente, é possível perceber a forte agregação 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, especialmente durante eventos de chuva, 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 (Figura 56). 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 (que é calculado para o solo) pode responder de forma mais lenta, nem sempre imediata.

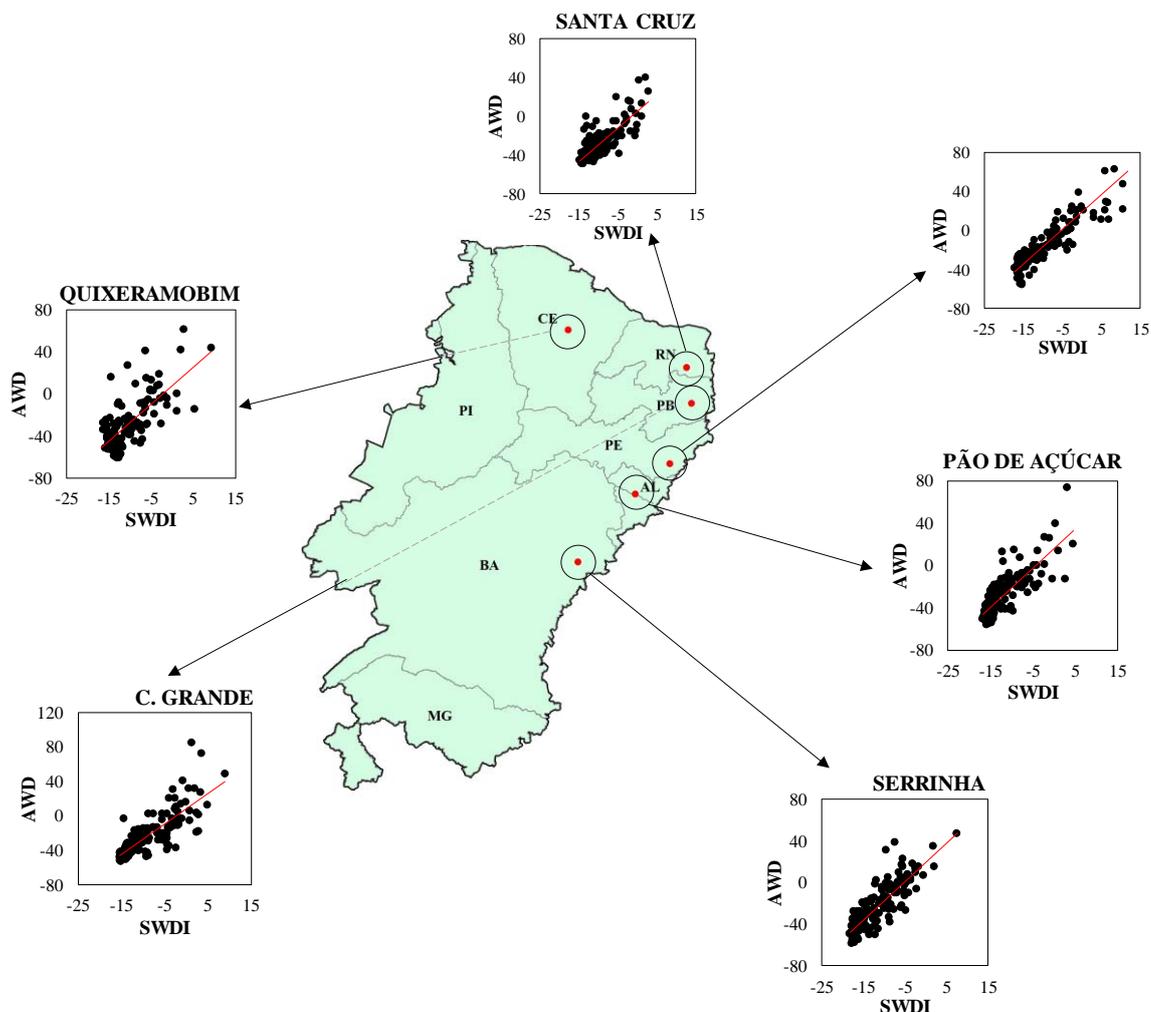


Figura 57. Coeficientes de correlação entre os índices SWDI e AWD em algumas estações de cada um dos estados do semiárido que foram considerados nas avaliações.

Pontualmente, é possível perceber que a variação do CC não é homogênea ao longo das estações avaliadas (Figura 58). No entanto, as estações que apresentaram menores valores CC (classificadas como fraca e muito fraca) estão localizadas na Bahia, em uma zona de transição caracterizada por um pequeno grau de variação de precipitação. Essa maior flutuação entre os índices SWDI e AWD pode ter ocorrido por causa da dimensão espacial do pixel do SMAP, que é de 36 km² e não acompanha de forma adequada a variação de precipitação e ETo, que foram obtidos de maneira pontual a partir dos dados da estação do INMET.

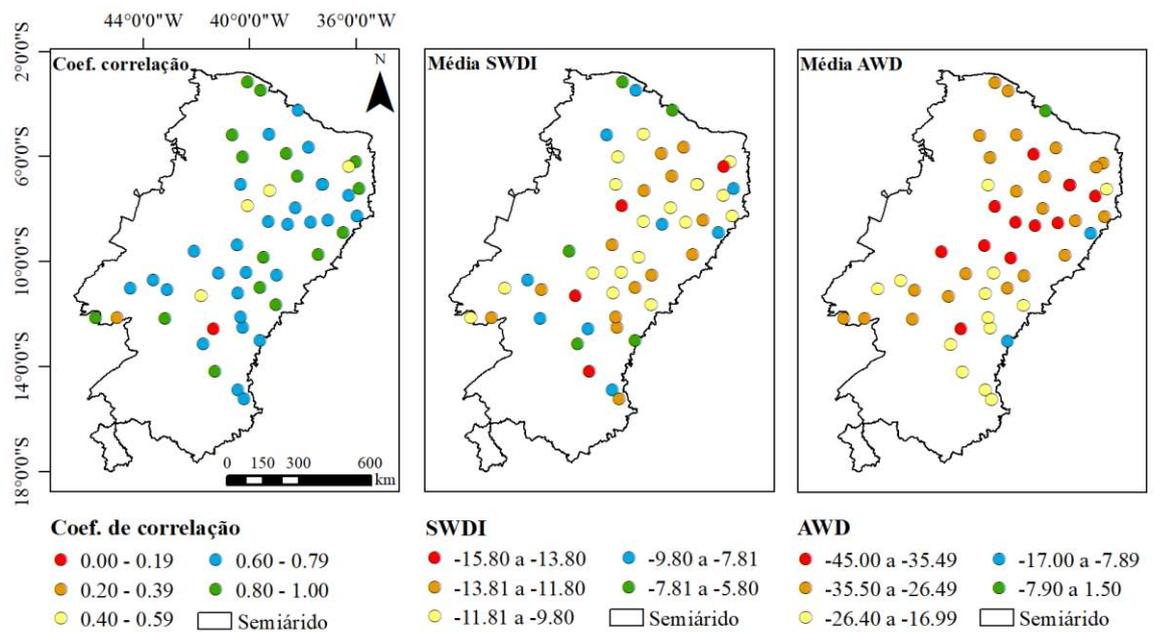


Figura 58. Resumo estatístico do coeficiente de correlação, SWDI e AWD no semiárido brasileiro durante o período de julho de 2015 a junho de 2018.

O SWDI médio, nos 49 pontos considerados para validação a partir da comparação com o AWD, foi negativo durante todo o período. No entanto, nem todos os locais apresentaram valores críticos de umidade no solo, que representam o ponto de murcha permanente, condição em que o déficit hídrico é absoluto ($SWDI < -10,00$) e a partir do qual o murchamento das folhas de espécies agrícolas torna-se irreversível, mesmo quando colocadas em atmosfera saturada com vapor de água (BAI et al., 2018a).

O AWD também esteve negativo em todos os locais. Esse resultado é esperado, já que o índice representa a ETo (evapotranspiração de referência) subtraída da precipitação, sendo expresso em valores médios de 7 dias. No semiárido, onde a precipitação é inferior à evapotranspiração média anual, a tendência é de que o AWD seja sempre negativo em virtude do desequilíbrio desse balanço (CIRILO, 2008; ROSSATO et al., 2017).

É importante considerar que, no ano de 2012, o Nordeste Brasileiro passou pela seca mais severa dos últimos 30 anos. Essa seca se estendeu com grande severidade até 2015, mas permaneceu nos anos de 2016 e 2017. A situação foi ainda mais crítica no Estado da Bahia, onde aproximadamente 230 municípios foram afetados. Municípios dos Estados de Alagoas e Piauí também foram severamente afetados pela ausência de chuvas. A seca trouxe

muitos prejuízos às principais fontes de renda da região: pecuária e cultivo de milho e feijão (ROSSATO et al., 2017).

Com base nisso, é possível perceber, a partir da distribuição espacial do SWDI trimestral, o grande impacto da ausência de chuvas em 2015 sobre o armazenamento de água no solo (Figura 59). No terceiro e quarto trimestres desse ano, quase todo o semiárido esteve 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 o solo como estando em ponto e murcha permanente.

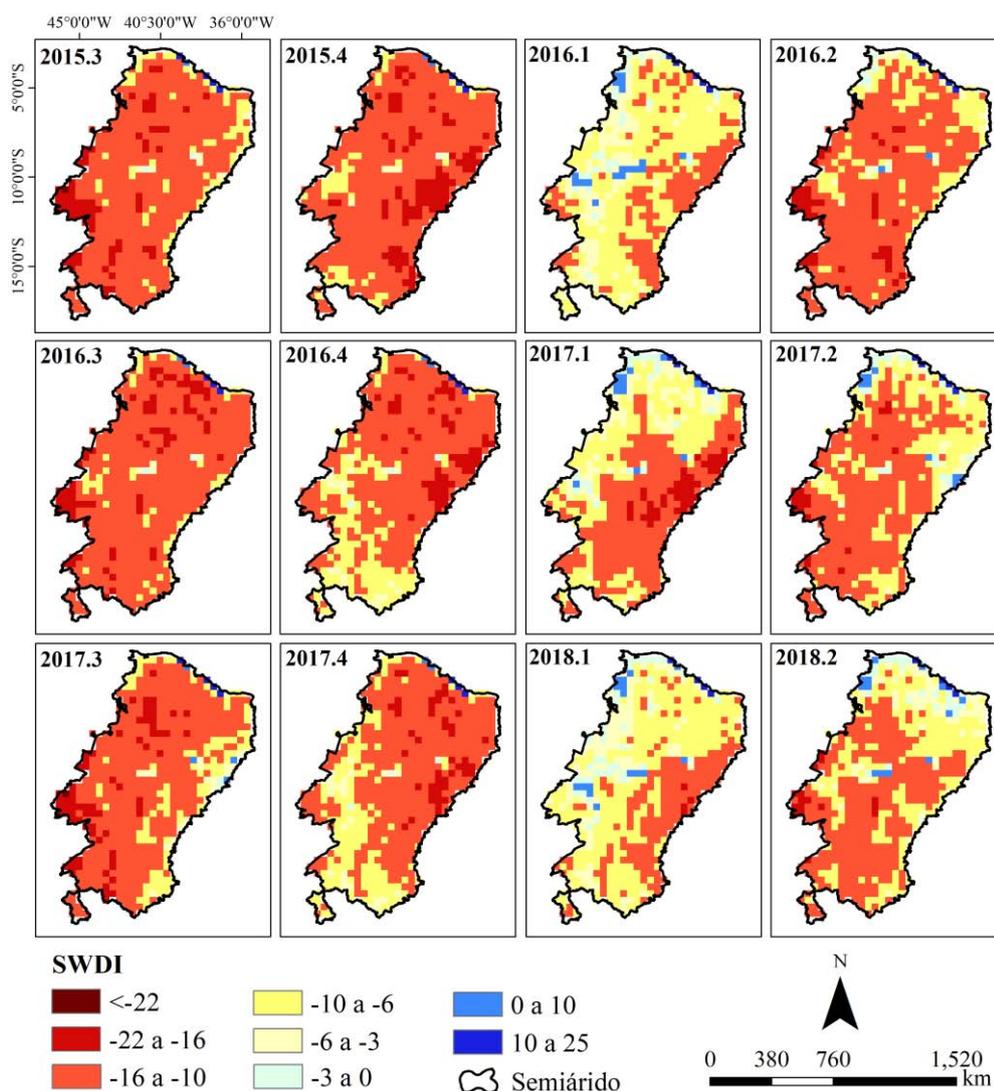


Figura 59. SWDI trimestral para o semiárido durante o período de julho de 2015 a junho de 2018. SWDI <-10,00 indica déficit hídrico absoluto.

É importante destacar que cada pixel do SMAP representa uma área de ~1296 km² e, dentro desse espaço, muitos usos de solo podem estar presentes, inclusive com áreas urbanas e lagos/reservatórios. No entanto,

como maior parte do semiárido é caracterizada por vegetação de caatinga, é correto supor que que essa é a vegetação dominante nos pixels. A vegetação de caatinga é naturalmente resiliente, adaptada às condições de déficit hídrico presentes no clima semiárido (CIRILO, 2008). No entanto, áreas agrícolas, especialmente de agricultura familiar, que são menos tecnificadas e expostas às ações do clima e deficiências nutricionais dos solos (ARAUJO et al., 2019), podem ser severamente afetadas com os valores de SWDI muito baixos, que indicam deficiência de água no solo para o suprimento vegetal.

Nos anos de 2016 e 2017, quando a seca persistiu e a série do SMAP registrou dados durante todo o ano, percebe-se que os valores de SWDI tendem a aumentar a partir do quarto trimestre (outubro, novembro, dezembro), apresentando os maiores valores no primeiro trimestre (janeiro, fevereiro e março) dos anos seguintes. Esse período coincide com a estação chuvosa no semiárido. De acordo com dados do *WorldClim – Global Climate Data* (FICK e HIJMANS, 2017), referentes à série de precipitação de 1970 a 2000, os meses de dezembro, janeiro, fevereiro, março e abril são os mais chuvosos em maior parte do semiárido, que possui precipitação média anual de 818,41 mm. Os dados da base *WorldClim*, que são fornecidos em grid global e possuem resolução espacial de 1 km², foram processados em Sistema de Informação Geográfica (SIG) para a obtenção das médias mensais para área do semiárido, com base em delimitação oficial proposta pela Superintendência de Desenvolvimento do Nordeste - SUDENE (Resolução n° 107, de 27/07/2017).

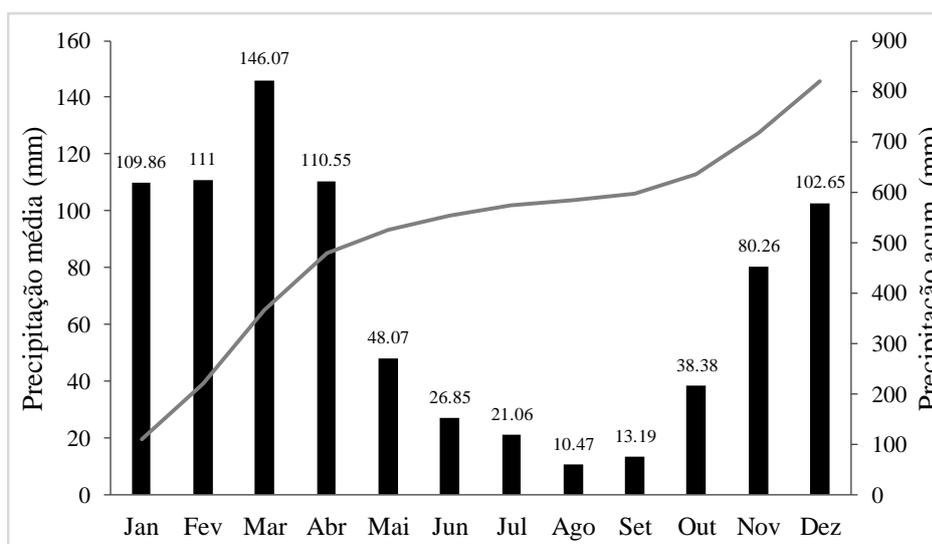


Figura 60. Precipitação média no semiárido de acordo com a série de dados espaciais do *WorldClim - Global Climate Data* (1970-2000).

Em escala temporal semestral, o padrão de o SWDI apresentar menores valores nos primeiros meses de cada ano da série fica evidente, confirmando a estreita relação entre a precipitação e umidade do solo, além de evidenciar o poder do SMAP na detecção da evolução temporal da umidade do solo, mesmo com sua limitada resolução espacial (Chen et al., 2017; Ma et al., 2017) (Figura 61). Especialmente no ano de 2018, o SWDI foi maior no primeiro semestre ($-8,67 \pm 4,30$), indicando que esse foi um ano mais chuvoso em relação aos demais, o que conseqüentemente favoreceu o armazenamento de água no solo e, conseqüentemente, aumento no valor do índice, principalmente nas porções norte e oeste do semiárido.

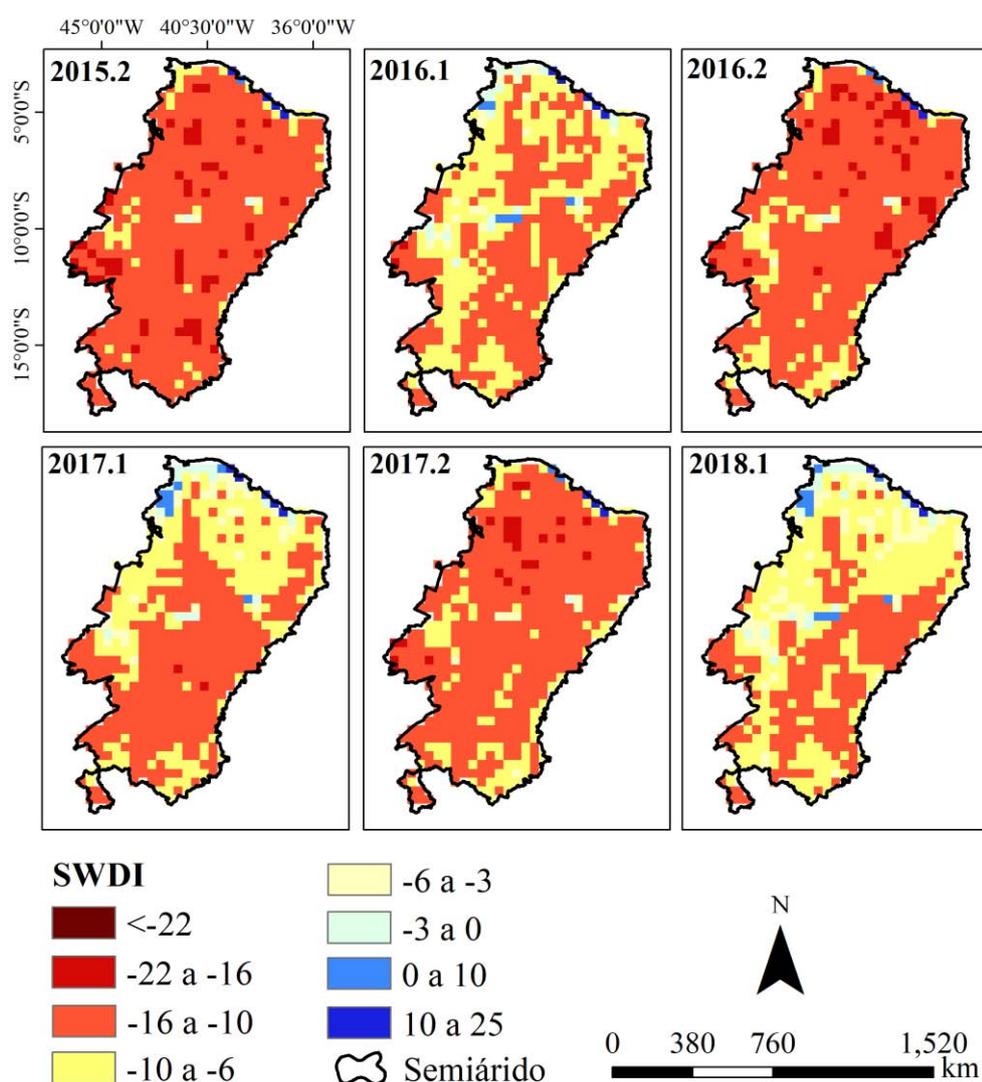


Figura 61. SWDI semestral para o semiárido durante o período de julho de 2015 a junho de 2018. SWDI $< -10,00$ indica déficit hídrico absoluto.

No primeiro semestre de 2016 a 2017, o SWDI médio foi de $-9,56 \pm 4,12$ e $-9,92 \pm 4,49$, respectivamente, demonstrando que a seca, que de forma espacial

foi levemente inferior em 2016, incrementou levemente em 2017. No entanto, nota-se que em 2016 a distribuição espacial dos valores críticos de SWDI foi mais aleatória ao longo do semiárido; já em 2017, houve a tendência de valores negativos nas porções central e sul, enquanto em 2018 foi percebida a redução de valores críticos ($<-10,00$) também no oeste do semiárido. É interessante continuar avaliando o índice durante o ano de 2019 para perceber como essa distribuição continuou em virtude da redução da seca.

O segundo semestre de 2015 foi o mais seco, já que dá continuidade à seca iniciada em 2012, que permaneceu bastante severa em todo o Nordeste até o final de 2015. Nesse período, o SWDI foi de $-13,01 \pm 3,83$, indicando déficit hídrico absoluto. No segundo semestre dos demais anos, o SWDI médio também esteve abaixo de $-10,00$, com média de $-12,51 \pm 3,84$ e $-11,99 \pm 3,73$ em 2016 e 2017, respectivamente. Esses dados indicam que o SWDI tende a alertar sobre a disponibilidade hídrica no solo extrema 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 armazenam água residual no solo para suprimento vegetal, embora retida a altas tensões.

Como forma de ilustrar a severidade da seca baseada no SWDI, que representa o armazenamento de água no solo, o índice médio foi calculado para toda a série de dados do SMAP disponível até junho de 2018 (Figura 62). Por não considerar a variação sazonal e integrar todas as estações (seca e chuvosa), a distribuição do índice alerta à necessidade de atenção quanto aos riscos que o déficit hídrico no solo pode trazer às culturas implementadas na região, principalmente do ponto de vista da agricultura familiar.

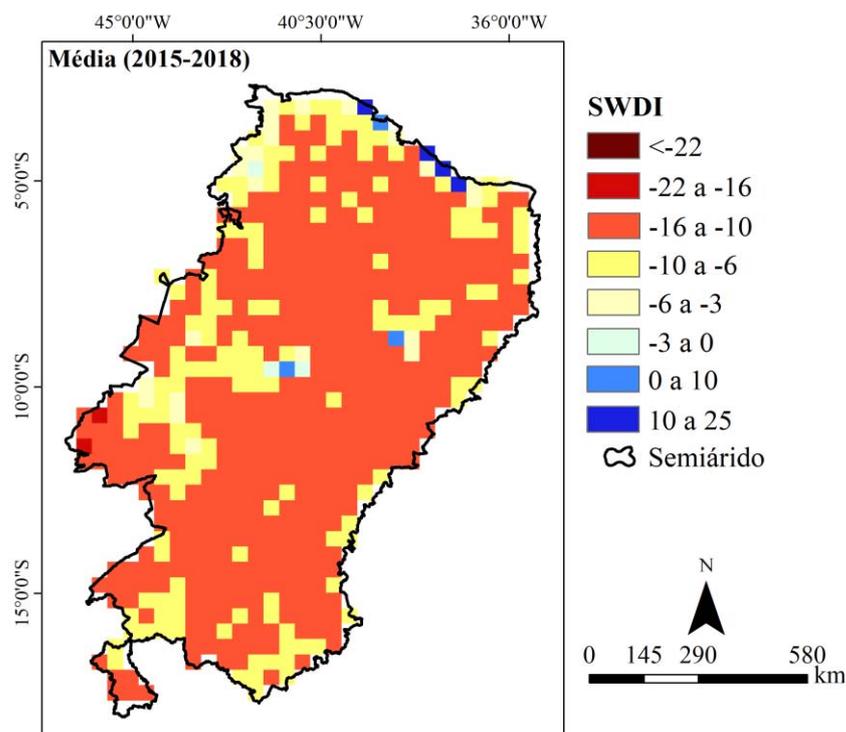


Figura 62. SWDI médio para o semiárido durante o período de julho de 2015 a junho de 2018. SWDI <-10,00 indica déficit hídrico absoluto.

No contexto da agricultura familiar, é importante destacar que, no Nordeste, essa modalidade possui destaque quando comparada ao restante do país, tanto no que se refere à área ocupada por agricultores familiares como no que diz respeito aos financiamentos. Por sinal, no Nordeste a agricultura familiar predomina e representa 88,3% dos agricultores da região, que ocupam 43,5% da área total explorada pela agropecuária. A principal dificuldade da prática da agricultura familiar reside nas limitações de solo (fertilidade) e clima da região, especialmente em virtude dos períodos cíclicos de seca (IBGE, 2010; GUANZIROLI et al., 2014). Por não possuírem tecnologias, com técnicos qualificados e recursos adequados, esses agricultores são severamente afetados pela sazonalidade e escassez de chuvas.

É importante considerar que a agricultura familiar está presente em 43,5% da área total explorada no Nordeste. De acordo com o mapa de SWDI médio, quase toda a área no semiárido foi afetada pelo déficit hídrico, com maior parte dela indicando solo em ponto de murcha permanente. Nesse contexto, esses pequenos agricultores são drasticamente afetados, demandando ainda mais ações de monitoramento e mitigação de riscos por parte dos órgãos responsáveis.

Índices de seca baseados na umidade do solo já foram estudados anteriormente no semiárido brasileiro, embora esse processo costume ocorrer em escalas espaciais mais reduzidas. Em toda a extensão territorial do semiárido, o Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN), já utilizou as suas 595 PCD para monitorar e avaliar a severidade da seca com base no índice Índice de Umidade do Solo (SMI) que, de forma similar ao SWDI, consiste na normalização dos valores da umidade do solo através da capacidade de campo e ponto de murcha permanente (ZERI et al., 2018).

As três principais desvantagens do SMI aplicado pelo CEMADEN são: a) foram utilizados dados das PCD espalhadas pelo semiárido, que tiveram a implementação finalizada em 2015. No entanto, maior parte delas apresenta falha nos dados ou registram informações inconsistentes, o que pode dificultar o seu uso para o cálculo do índice; b) como os dados não são contínuos (a informação é registrada pontualmente), não há uma espacialização no índice na área do semiárido, ao contrário do que ocorre com os dados do SMAP, por exemplo, que são fornecidos em *grid* global; c) o SMI não é validado a partir de um índice adicional. O SWDI, por exemplo, utiliza o AWD (precipitação e evapotranspiração de referência) para a validação. No entanto, o índice SMI proposto pelo CEMADEN foi analisado em conjunto com dados de precipitação.

Pensando nas limitações de índices de umidade do solo baseados apenas em anomalias e, verificando a necessidade de validar um índice criado com dados de umidade e propriedades do solo, Martínez-Fernández et al. (2015) desenvolveram o SWDI como um eficiente indicador de seca agrícola. A aplicação inicial foi desenvolvida na Espanha, de forma pontual, sem o uso dados orbitais. A partir de então, vários autores reconheceram a necessidade de ampliar as avaliações com o índice globalmente, de modo que diversas aplicações baseadas em dados de umidade do solo estimados por sensoriamento remoto vêm sendo desenvolvidas com grande sucesso na confirmação do potencial do índice.

Como a variação da qualidade dos dados estimados por satélites de umidade do solo altera globalmente, não somente o SMAP pode ser utilizado. Pablos et al. (2018), por exemplo, avaliaram o impacto da seca na umidade do

solo da zona radicular (5 cm de profundidade) utilizando dados de umidade do solo do SMOS na Espanha. O índice avaliado também foi o SWDI que, após comparado com o AWD, demonstrou grande potencial para o monitoramento desse tipo de evento nas diferentes estações do ano, que são bem distintas na Europa.

Nos Estados Unidos, Mishra et al. (2017) utilizaram o SMAP para avaliar o índice SWDI, que foi comparado com outros diferentes índices já amplamente utilizados e conhecidos, como o próprio AWD, além do Índice Padronizado de Evapotranspiração (SPEI) e Índice de Severidade de Seca de Palmer (PDSI). Embora tenham atingido resultados bastante satisfatórios, os autores mencionam que o grande desafio ainda é quantificar as características dos solos (capacidade de campo e ponto de murcha permanente) em escala espacial, já que essa informação é essencial para transformar o conteúdo de água em índices significativos de seca.

Bai et al. (2018a) também optaram por utilizar o SMAP para modelar o índice SWDI na China, com validação por meio do AWD. Primeiramente, os autores realizaram a validação dos dados do SMAP no país e, em seguida, calcularam o SWDI. Nos dois casos, foram encontrados bons resultados. Novamente, foi comentada a dificuldade de estimar as propriedades características de solo. Para o estudo, esses dados foram obtidos por meio da função de pedotransferência proposta por Saxton e Rawls (2006), utilizando dados de textura e umidade do solo.

As séries de dados de umidade do solo estimadas por satélites são relativamente curtas, já que se trata de uma forma de monitorar essa variável em escala global 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. No Brasil, país que possui economia bastante influenciada pela agricultura e sua produtividade, os dados de umidade do solo fornecidos por esses instrumentos ainda são pouco explorados, por isso é essencial que estudos nessa direção sejam estimulados para que a situação inverta nos próximos anos.

4 CONCLUSÕES

Em Pernambuco e no semiárido, o SMAP foi o satélite que melhor representou a variação da umidade do solo temporalmente 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 SMAP, 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, é correto inferir que 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. Esse tipo de ação é essencial e está inserida no novo Plano Nacional de Segurança Hídrica, que alerta à necessidade de ações que envolvem a gestão de riscos. No entanto, o monitoramento de eventos extremos é essencial antes que qualquer medida possa ser avaliada e/ou adotada.

É importante ressaltar que o índice SWDI, derivado do SMAP, já é utilizado até mesmo para detectar áreas agrícolas em que o uso da água está sendo realizado de forma inadequada, além da demanda hídrica requerida pelas culturas, o que causa excedentes e impacta diretamente nas práticas de uso racional dos recursos hídricos. Nesse sentido, o índice tem grande potencial na detecção de pontos em que o uso da água está sendo realizado de forma incorreta, evidenciando a sua relevância para a gestão adequada dos recursos hídricos. Em estudos futuros, uma aplicação similar pode ser realizada no semiárido com o objetivo de detectar regiões de polos agrícolas em que o conteúdo de água no solo está muito acima do nível requerido pelas culturas.

CAPÍTULO V

**CALIBRAÇÃO DO MODELO HIDROLÓGICO FEST-EWB UTILIZANDO
DADOS DE SENSORIAMENTO REMOTO EM UMA BACIA INSERIDA
EM REGIÃO DE TRANSIÇÃO CLIMÁTICA NO NORDESTE
BRASILEIRO**

Calibração do modelo hidrológico FEST-EWB utilizando dados de sensoriamento remoto em uma bacia inserida em região de transição climática no Nordeste Brasileiro

RESUMO: os modelos hidrológicos são ferramentas cruciais para o gerenciamento dos recursos hídricos, permitindo a estimativa de parâmetros que não podem ser facilmente medidos *in situ*, especialmente em regiões com redes de monitoramento escassas. No caso de modelos distribuídos, a principal limitação para sua aplicação é a quantidade de dados de entrada necessários para executar as simulações. Neste estudo, um modelo de balanço hídrico e energético distribuído (FEST-EWB) foi calibrado e validado em uma bacia inserida em uma zona de transição climática entre o semiárido (pouco afetado pela cobertura de nuvens) e a Mata Atlântica úmida (altamente afetada pela cobertura de nuvens) no Nordeste do Brasil. O estudo foi realizado durante os anos de 2016 e 2017 e dados de temperatura da superfície do solo (LST) do *Moderate Resolution Imaging Spectroradiometer* (MODIS) foram usados para calibrar o modelo, que resolve o sistema de equações do balanço de massa e energia em função da temperatura de equilíbrio representativa (RET). Essa RET foi confrontada com os dados de LST do MODIS durante o processo de calibração, e os parâmetros do solo e da vegetação foram ajustados a cada nova simulação, reduzindo as diferenças entre a RET e a LST. Para validação, foram utilizados dados de umidade do solo (US) e LST obtidos em diferentes estações da bacia. Os resultados indicaram que o modelo apresentou bom desempenho para a simulação da LST e US na bacia, principalmente no semiárido, onde os erros foram menores. Na Mata Atlântica, devido à alta incidência de nuvens, os erros foram mais pronunciados durante a comparação com os dados de LST do MODIS, mas reduzidos quando a validação pontual com dados *in situ* foi realizada. A presença de nuvens na Mata Atlântica limitou a quantidade de imagens do MODIS usadas para realizar a calibração na bacia, ainda assim, bons resultados foram gerados, principalmente na região semiárida. Esses resultados indicam que o modelo deve apresentar bons resultados quando aplicado nas demais bacias do Nordeste Brasileiro, que possui mais de 80% de seu território inserido na zona semiárida.

Palavras-chave: recursos hídricos, umidade do solo, temperatura de superfície do solo.

Calibration of FEST-EWB hydrological model using remote sensing data in a basin located in a climate transition region in Brazil

ABSTRACT: hydrological models are crucial tools for water resources management, allowing the estimation of parameters that cannot be easily measured in situ, especially in regions with poor monitoring networks. In the case of distributed models, the major limitation for their application is the amount of input data required to perform the simulations. In this paper, a distributed hydrological energy water balance model (FEST-EWB) was calibrated and validated in a basin inserted in a climate transition zone between the semiarid (little affected by cloud cover) and the humid Atlantic Forest (highly affected by cloud cover) in the Northeast Brazil. The study was conducted during 2016 and 2017 and land surface temperature (LST) data from the Moderate Resolution Imaging Spectroradiometer (MODIS) were used to calibrate the model, that solves the system of energy and mass balance equations as a function of the representative equilibrium temperature (RET). This RET was confronted with MODIS LST data during the calibration process, and the soil and vegetation parameters were adjusted in each new simulation, reducing the errors between RET and LST. For validation, soil moisture (SM) and LST data obtained at different stations over the basin were used. The results indicated that the model presented good performance for the simulation of LST and SM in the basin, especially in the semiarid, where the errors were smaller. In the Atlantic Forest, due to the high incidence of cloud cover, errors were more pronounced during calibration against MODIS LST data, but reduced when validation with in situ data was performed. The incidence of cloud cover in the Atlantic Forest reduced the amount of MODIS images used to perform the calibration in the basin, but still good results were generated, especially in the semiarid region. These results indicate that the model should present good results when applied in the other basins of the Brazilian Northeast, which has more than 80% of its territory inserted in the semiarid zone.

Keywords: water resources, soil moisture, land surface temperature.

1 INTRODUÇÃO

A modelagem de processos hidrológicos em escala de bacia hidrográfica é uma importante ferramenta para o monitoramento dos recursos hídricos, auxiliando na sua gestão. Nos últimos anos, os modelos vêm sendo bastante utilizados para auxiliar na compreensão de como ações antrópicas interferem na dinâmica da água em bacias hidrográficas, permitindo a estimativa de parâmetros que não podem ser diretamente mensurados *in situ* (ZHANG et al., 2008; WU et al. 2017; KUMARASAMY e BELMONT, 2018). Essa capacidade dos modelos hidrológicos é ainda mais necessária em regiões com escassez de redes de monitoramento, situação que é percebida em muitas bacias ao redor do mundo (LÓPEZ et al., 2017), especialmente em regiões áridas e semiáridas ou países em desenvolvimento (BRUNNER ET AL., 2007; LEKULA e LUBCZYNSKI, 2019).

Nesse contexto, a região Nordeste do Brasil (NEB), que engloba 30% da população, é a mais pobre e seca do país (CÁSSIA, 2015; FERREIRA et al., 2003). Uma das principais causas da pobreza nessa região são as condições climáticas extremas, marcadas por secas constantes e de longa duração (CIRILO, 2008). O NEB, especialmente o semiárido, que corresponde a 80% do território da região, ainda enfrenta as consequências da seca iniciada em 2012, uma das mais severas das últimas décadas, que afetou todos os setores produtivos e gerou grandes impactos sociais (ROSSATO et al., 2017; SOUZA et al., 2018). A persistência das secas leva à necessidade de monitorar e estudar os processos hidrológicos, objetivando a conservação e gestão dos recursos hídricos, mitigação de impactos e convivência produtiva com a seca (LOPES et al., 2019). Além disso, devido à escassez hídrica, o ambiente natural do semiárido brasileiro é frágil, de modo que compreender os processos hidrológicos que nele ocorrem é essencial para garantir a sua preservação (MONTENEGRO e RAGAB, 2010).

O NEB, tradicionalmente, possui redes de monitoramento falhas ou intermitentes. Essa situação está mudando nos últimos anos, no entanto, novas redes recém implementadas ainda não possuem uma série dados muito longa (ZERI et al., 2018). Como resultado da escassez de dados ou baixa qualidade das informações coletadas, diversos estudos têm focado em fontes alternativas, como dados de sensoriamento remoto e modelagem hidrológica

para entender a dinâmica espaço-temporal da água, balanço de energia e sua relação com eventos de seca e manejo agrícola (PAREDES-TREJO e BARBOSA, 2017; CUNHA et al., 2019; FONTES JÚNIOR e MONTENEGRO, 2019; MERCURE et al., 2019). Existem, ainda, estudos que integram a modelagem hidrológicas com produtos de sensoriamento remoto, beneficiando principalmente os modelos distribuídos ou semi-distribuídos (SOARES CRUZ et al., 2018).

No NEB, mais especificamente no Estado de Pernambuco, muitos modelos vêm sendo amplamente avaliados, principalmente o *Surface Energy Balance Algorithm for Land* (SEBAL) (OLIVEIRA et al., 2014) e o *Soil and Water Assessment Tool* (SWAT) (MAGALHÃES et al., 2018). No entanto, enquanto o SEBAL enfrenta limitações no processo de validação dos dados devido à reduzida disponibilidade de estações *in situ* que mensuram a evapotranspiração, o SWAT tem a desvantagem de não gerar dados geoespaciais, já que é um modelo semi-distribuído (LI et al., 2010; YU et al., 2017). Atualmente, o processo para gerar dados geoespaciais (em escala de pixels) no SWAT requer grande quantidade de tempo e repetitivas etapas de processamento (GIULIANI et al., 2013). Como esse tipo de dado é necessário para diversas aplicações, uma possível alternativa é o uso de modelos distribuídos, como o *Flash-flood Event-based Spatially distributed rainfall-runoff Transformation - Energy Water Balance* (FEST-EWB) (CORBARI et al., 2011).

O FEST-EWB computa os principais processos do ciclo hidrológico: evapotranspiração, escoamento superficial, infiltração, fluxo subterrâneo, vazão, umidade do solo etc. (CORBARI et al., 2009). O modelo tem seu algoritmo baseado no sistema do balanço de água e energia como função da temperatura de superfície do solo (LST), e resolve o sistema de equações do balanço de massa e energia buscando pela temperatura de equilíbrio representativa (RET) ou seja, a LST que fecha a equação do balanço de energia. Essa RET, que é uma variável interna do modelo, é comparada com a LST obtida por sensoriamento remoto durante o processo de calibração. O domínio computacional do FEST-EWB é discretizado em uma malha regular de pixels em que cada parâmetro é definido ou calculado em passo de tempo horário (CORBARI e MANCINI, 2014; CORBARI et al., 2015b). A resolução espacial do FEST-EWB pode ser adaptada às necessidades do pesquisador,

de modo que o modelo pode gerar dados com alta resolução espacial e temporal. Essa característica é importante em diversas aplicações, favorecendo principalmente o manejo agrícola (RAVAZZANI et al., 2017).

A calibração tradicional de modelos hidrológicos é baseada em um único valor multiplicativo dos parâmetros de sensibilidade, definido a partir da comparação entre dados observados e simulados. No modelo distribuído FEST-EWB, imagens de LST derivadas de sensoriamento remoto podem auxiliar na calibração desses parâmetros em cada pixel do domínio analisado, permitindo uma melhor compreensão do processo hidrológico e a análise de modelos em escala de pixels (CORBARI et al., 2015a).

Como o procedimento de calibração dos parâmetros hidráulicos do solo e da vegetação se dá através da comparação da RET estimada pelo FEST-EWB (utilizando diferentes configurações nas simulações) e os dados de LST obtidos por satélite, os produtos diários do MODIS são geralmente utilizados como referência. No entanto, esse satélite é severamente afetado pela cobertura de nuvens, que pode limitar as suas estimativas e aplicações em algumas regiões (KANG et al., 2018).

É importante enfatizar que, para comprovar a robustez do FEST-EWB e da metodologia de calibração baseada na LST, é necessário testar o modelo em diferentes regiões do mundo, com diferentes condições climáticas e de uso e ocupação do solo. Esse procedimento assegura que o FEST-EWB pode ser utilizado em diferentes cenários, de modo que esse tipo de aplicação deve ser sempre encorajada. O SWAT, por exemplo, que atualmente é o modelo hidrológico mais utilizado em Pernambuco, já foi calibrado e validado em diferentes regiões do mundo, conforme reportado por Abbaspour et al. (2018).

Nesse sentido, o objetivo desse estudo foi realizar a calibração do modelo FEST-EWB em uma bacia inserida em duas condições climáticas distintas: (1) semiárido (pouco afetado pela cobertura de nuvens) e (2) Mata Atlântica úmida (muito afetada pela presença de nuvens), considerando que a calibração utiliza imagens do MODIS. Além disso, o modelo foi validado utilizando dados de LST e umidade do solo mensurados por estações em superfície, durante o período de dois anos. Antes da calibração, foi realizado um breve teste para verificar a quantidade mínima de imagens de LST do MODIS necessária para executar o

procedimento, uma vez que a disponibilidade de imagens sem nuvens nessa região é muito limitada.

2 MATERIAL E MÉTODOS

2.1 Área de estudo

O estudo foi realizado na Bacia do Rio Una (BRU), no NEB. A bacia está localizada no litoral sul do Estado de Pernambuco, entre as coordenadas 08°17'31.5" e 09°0'0.77" S, e 36°42'24.03" e 35°5'54.68" W (Figura 63), com parte do seu território no Estado de Alagoas. O Rio Una é considerado um dos mais importantes de Pernambuco, com uma extensão de 270 km. Sua bacia (BRU) cobre uma área de 6740 km² (TAVARES et al., 2018).

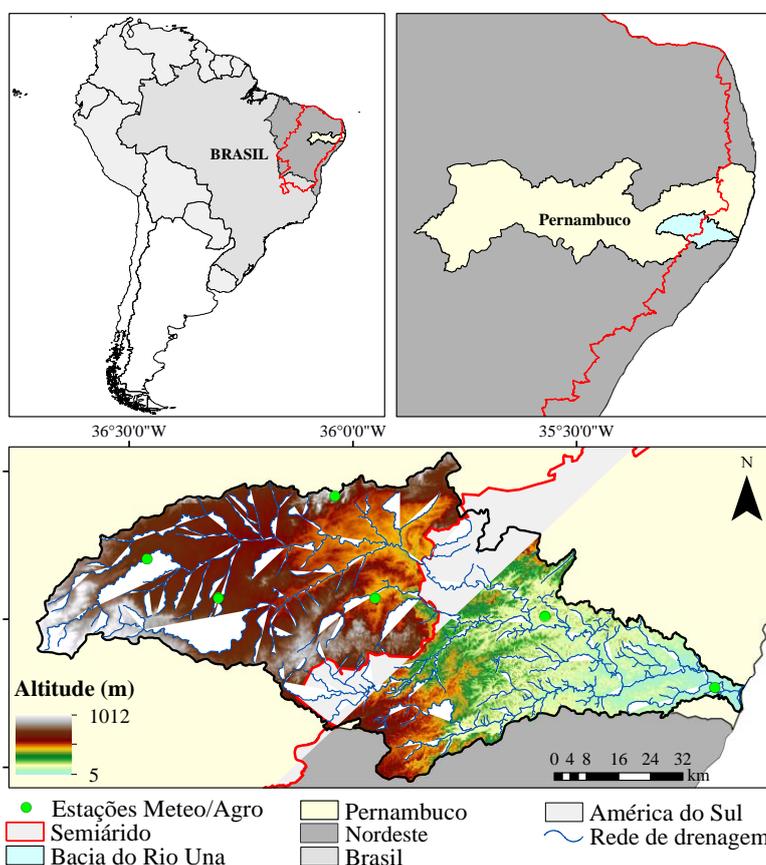


Figura 63. Localização da Bacia do Rio Una (BRU), com destaque para as estações meteorológicas e agrometeorológicas utilizadas no estudo.

Os principais usos da bacia são para suprimento público, dessedentação animal, uso industrial, irrigação com ênfase na cultura da cana-de-açúcar e atividades de lazer e pesca (CAMPELLO DE MELO et al., 2018). A BRU é parte de duas mesorregiões, o Agreste pernambucano e a Zona da Mata

pernambucana, situada em uma zona de transição entre dois tipos climáticos distintos, o semiárido (na porção oeste da bacia) e o clima de Mata Atlântica úmida (porção leste da bacia), por isso foi selecionada para esse estudo, que tem o objetivo de verificar o potencial do modelo em condições climáticas distintas.

No semiárido, a precipitação total anual varia de 500 a 800 mm. Para o período considerado nesse estudo (2016-2017), inserido na grande seca que afetou severamente a região nos últimos anos, a precipitação foi inferior à média histórica. Na Mata Atlântica úmida, a precipitação anual é elevada, excedendo 1000 mm e atingindo valores de até 2250 mm no litoral (SANTOS et al., 2014).

O semiárido é o tipo climático predominante no NEB, ocupando uma área de 80%. Toda a porção litorânea localizada fora dos limites do semiárido é caracterizada pelo clima quente e úmido (Mata Atlântica) (Figura 63).

2.2 Dados de superfície

Os dados meteorológicos com resolução temporal horária, necessários para executar o modelo (precipitação, radiação solar, umidade relativa do ar, temperatura do ar e velocidade do vento) foram obtidos a partir de seis estações distribuídas ao longo da bacia, para o período de janeiro de 2016 a dezembro de 2017. Os anos de 2016 e 2017 foram considerados secos no semiárido, no entanto, o FEST-EWB possui algoritmo que favorece a adequada estimativa de variáveis do balanço de água e energia para curtos períodos e condições climáticas distintas, não sendo necessárias grandes séries (CORBARI e MANCINI, 2014).

Os dados observados foram interpolados pelo FEST-EWB para uma grade regular de 62.500 m², utilizando a técnica do inverso do quadrado da distância. Mais precisamente, a temperatura do ar foi interpolada considerando também a elevação do solo, enquanto a radiação considerou as possíveis áreas sombreadas (CORBARI et al., 2009).

Entre as seis estações, três delas também fornecem dados consistentes de umidade do solo (US) e duas fazem leituras da temperatura de superfície do solo (LST), nos dois tipos climáticos presentes na bacia. Os dados têm

resolução temporal horária e são coletados em profundidades de 0 a 40 cm (em intervalos de 10 cm). Tanto a US quanto a LST foram utilizadas para a validação do modelo.

Os dados foram fornecidos pela Agência Pernambucana de Águas e Clima (APAC), o Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN) e pelo Instituto Nacional de Meteorologia (INMET).

2.3 Modelo digital de elevação e propriedades hidráulicas do solo

O modelo digital de elevação (DEM), utilizado para caracterização morfométrica da bacia, foi obtido através do banco de dados geomorfométricos do Brasil (TOPODATA), fornecido pelo Instituto Nacional de Pesquisas Espaciais (INPE). O DEM provém da missão SRTM (*Shuttle Radar Topography Mission*), com resolução espacial de 90 m.

O mapa de uso e ocupação do solo foi fornecido pelo Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil (MapBiomas). Esses dados são atualizados anualmente. O mapa mais recente, disponível para o ano de 2017, foi utilizado. Os dados de uso e cobertura do solo foram necessários para gerar mapas de altura da vegetação e resistência estomática mínima, essenciais para as simulações com o modelo.

O FEST-EWB requer muitos parâmetros hidráulicos do solo, já que é um modelo distribuído. Esses dados não estão disponíveis espacialmente no Brasil. Uma alternativa possível é utilizar dados espaciais de textura do solo para estimar os parâmetros necessários para as simulações. Nesse estudo, um mapa de textura do solo foi gerado a partir da base '*global gridded soil information*' (SoilsGrid) (HENGL et al., 2017), com resolução espacial de 250 m. A consistência do mapa foi verificada por meio da comparação com 10 pontos de amostragem *in situ* coletados pelo CEMADEN na BRU. Depois disso, dados espaciais de propriedades hidráulicas do solo (condutividade hidráulica saturada, umidade do solo residual e saturada, índice de distribuição do tamanho dos poros, ponto de murcha permanente, capacidade de campo e ponto de pressão de bolha) foram derivados da conhecida base de dados de Rawls e Brakensiek (1985), conforme executado por Corbari e Mancini (2014).

2.4 Dados de sensoriamento remoto

Dados diários de LST foram utilizados para a calibração do modelo. As imagens foram adquiridas através do radiômetro MODIS, a bordo do satélite Terra, da NASA. O produto selecionado foi o MOD11A1 (<https://lpdaac.usgs.gov/>), com resolução espacial de 1 km e cobertura temporal diária. Conforme mencionado anteriormente, a área de estudo é muito afetada pela cobertura de nuvens na Mata Atlântica ao longo de todo o ano. Por conta disso, apenas 29 imagens diárias de LST foram obtidas para o período de 2016 a 2017. Após uma filtragem inicial, somente imagens com cobertura de nuvens inferior a 20% ao longo de toda a bacia foram selecionadas, reduzindo esse número para 24 imagens.

Dados de índice de área foliar (IAF) também foram obtidos do MODIS/Terra. O produto utilizado foi o MOD15A2H, com resolução espacial de 500 m, gerado a partir de uma composição média referente ao período de 8 dias. A fração vegetativa, também necessária como dado de entrada para o modelo, foi estimada utilizando dados de IAF do MODIS, de acordo com metodologia proposta por Timmermans et al. (2011). O FEST-EWB é bastante sensível às variações desses parâmetros (CORBARI e MANCINI, 2014).

O albedo de superfície foi analisado a partir de dados de reflectância do MODIS, com resolução espacial de 500 m, a cada 8 dias. A reflectância das bandas 1 a 7 foi utilizada para estimar o albedo, de acordo com Liang (2000):

$$\alpha = 0.039_{\rho_1} + 0.504_{\rho_2} + 0.071_{\rho_3} + 0.105_{\rho_4} + 0.252_{\rho_5} + 0.069_{\rho_6} + 0.101_{\rho_7} \quad (24)$$

em que α é o albedo de superfície e ρ_1 a ρ_7 correspondem às bandas de reflectância.

Todos os dados espaciais anteriormente mencionados foram interpolados para a resolução de 250 m, selecionada nesse estudo para as simulações com o modelo FEST-EWB. A interpolação dos dados das estações também considerou essa resolução.

2.5 O modelo hidrológico: FEST-EWB

As simulações foram realizadas utilizando o modelo FEST-EWB, que teve seu desenvolvimento iniciado por Mancini (1990) e foi finalizado por Corbari et al. (2011). O FEST-EWB é um modelo distribuído que computa os processos envolvidos no balanço de água e energia; os principais dados de entrada requeridos para as simulações são: variáveis meteorológicas, parâmetros distribuídos de solo e vegetação, modelo digital de elevação (DEM) e um mapa de uso e cobertura do solo (CORBARI et al., 2015a). Os parâmetros de solo e vegetação incluem a condutividade hidráulica saturada, capacidade de campo, ponto de murcha permanente, conteúdo de água residual e saturado, índice de Brooks-Corey, ponto de pressão de bolha, profundidade do solo, índice de área foliar, altura da vegetação e resistência estomática mínima (CORBARI e MANCINI, 2014).

No FEST-EWB, o módulo do balanço de energia é introduzido. Como o modelo é distribuído, o domínio computacional é discretizado em uma malha regular de células quadradas (pixels com resolução de 250 m x 250 m, no caso desse estudo), em que cada parâmetro é definido ou calculado em passo de tempo horário.

A umidade do solo, para um dado pixel na posição i,j , é definido pela equação do balanço hídrico (CORBARI et al., 2011):

$$\frac{\partial SM_{i,j}}{\partial t} = \frac{1}{dz_{i,j}} (P_{i,j} - R_{i,j} - PE_{i,j} - ET_{i,j}) \quad (25)$$

em que P é a precipitação (mm h^{-1}), R é o fluxo de escoamento (mm h^{-1}), PE é o fluxo de drenagem (mm h^{-1}), ET é a taxa de evapotranspiração (mm h^{-1}) e dz é a profundidade do solo (m). Os termos do sistema estão em função dos parâmetros de solo e vegetação, introduzidos como dados de entrada.

A equação do balanço hídrico é computada em cada pixel (62.500 m^2) do domínio, caracterizado por uma única camada de profundidade do solo (dz), e é acoplada ao balanço energético:

$$R_n - G = H + L_e \quad (26)$$

em que R_n é o saldo de radiação ($W m^{-2}$), G é o fluxo de calor no solo, H é o fluxo de calor sensível e L_e é o fluxo de calor latente. Este último é então a evapotranspiração, que é o elo com a equação do balanço hídrico.

Todos os termos do balanço de energia dependem da RET, de modo que a equação do balanço de energia é resolvida procurando pela temperatura de equilíbrio termodinâmico que fecha a equação. Um esquema de Newton-Raphson é utilizado para resolver esse processo iterativo. Para isso, a heterogeneidade da superfície do pixel, a emissividade da temperatura da superfície do solo e a ligação com a resistência aerodinâmica na estimativa de fluxos turbulentos são considerados. Assim, a LST pode ser vista como um elo de ligação que influencia a umidade do solo (CORBARI et al., 2015b).

2.6 Calibração e validação

O processo de calibração é baseado na minimização dos erros da RET por meio da alteração nos parâmetros de vegetação e solo. Esses parâmetros são modificados pixel a pixel através da comparação da variável interna do modelo (RET) com a LST obtida por sensoriamento remoto. Essa metodologia é baseada em imagens de LST geradas por satélite, que fornecem a oportunidade de calibrar e validar o modelo hidrológico distribuído em cada pixel do domínio da bacia, permitindo uma melhor compreensão dos processos hidrológicos e a análise de modelos em escala de pixels (CORBARI et al., 2015a).

A partir da simulação inicial, os parâmetros são continuamente modificados até que os erros sejam os menores possíveis. No entanto, são sempre mantidos em uma escala de valores fisicamente possível. Várias simulações são realizadas para cada parâmetro individualmente e depois combinando alguns deles, através de uma metodologia baseada em “tentativa e erro”. Após cada simulação, a RET é comparada, pixel a pixel, com a LST fornecida pelo MODIS, e os índices estatísticos são calculados. Os parâmetros de solo e/ou vegetação são então modificados em cada pixel e um novo valor é atribuído de acordo com a magnitude do erro. Após isso, uma nova simulação é realizada, sendo esse procedimento repetido até que o erro seja o menor possível.

A metodologia de calibração do FEST-EWB, baseada na LST, é suficiente para a predição de outros fluxos e variáveis, como a evapotranspiração e umidade do solo, conforme anteriormente demonstrado por Corbari et al. (2015b) e Ravazzani et al. (2017).

Durante a calibração, diferentes índices estatísticos são considerados para avaliar a performance do modelo em termos de RET. Alguns deles são erro médio (EM), o erro médio absoluto (EMA) e a raiz do erro quadrático médio (RMSE), calculados pelas equações abaixo:

$$EM = \sum_{i=1}^n (X_{sim}^i - X_{obs}^i) / n, \quad (27)$$

$$EMA = \sum_{i=1}^n |X_{sim}^i - X_{obs}^i| / n, \quad (28)$$

$$RMSE = \left[\sum_{i=1}^n (X_{sim}^i - X_{obs}^i)^2 / n \right]^{0.5}, \quad (29)$$

em que X_{sim}^i é a variável simulada FEST-EWB, X_{obs}^i é a variável mensurada e n é a dimensão da amostra.

A umidade do solo foi validada utilizando três estações, duas no semiárido e uma na Mata Atlântica. Para todas as validações, o EM, EMA e RMSE foram considerados. Adicionalmente, o coeficiente de determinação (R^2) também foi calculado.

2.7 Definição do número de imagens de LST necessárias para a calibração

Conforme mencionado antes, parte da bacia está inserida em uma área severamente afetada pela cobertura de nuvens. Considerando que a calibração do modelo é baseada na comparação entre a RET (FEST-EWB) e a LST (MODIS), essa característica pode representar uma limitação durante o procedimento de calibração.

De fato, em calibrações anteriores realizadas com o modelo, um grande número de imagens de LST do MODIS foi utilizada como referência. Ravazzani et al. (2017) utilizaram 166 imagens de LST para calibrar o FEST-EWB durante o período de 2010 a 2012, enquanto Corbari e Mancini (2014) utilizaram 129 imagens para calibrar o modelo durante um período de 4 anos. Como a área da bacia do Rio Una não possui uma grande quantidade de imagens de LST com cobertura de nuvens inferior a 20%, um breve teste foi realizado para confirmar o número mínimo necessário para a calibração do modelo durante o período de dois anos.

O teste foi realizado comparando a RET com a LST, considerando diferentes números de imagens: 1, 5, 10, 15, 20 e 24. Após cada comparação, os seguintes critérios foram considerados: 1) índices estatísticos: conforme o número de imagens aumenta, é esperado que os valores dos índices estatísticos atinjam um equilíbrio, onde a inclusão de novas imagens não irá mais trazer grandes impactos na calibração. Assim, os índices foram continuamente comparados com o intuito de detectar o ponto em que as variações se tornaram muito próximas entre os números de imagens; 2) parâmetros de solo e vegetação: a calibração do FEST-EWB é baseada na alteração dos parâmetros de solo e vegetação e, em seguida, na comparação dos novos valores de RET com a LST, visando reduzir erros. A variação nos parâmetros foi observada em cada teste com variação no número de imagens. Novamente, com o aumento do número de imagens é esperado que os parâmetros se tornem mais similares a cada novo teste; 3) histogramas de frequência: o formato do histograma indica o quão similar duas séries de dados são. Nesse sentido, os histogramas (de RET e LST) foram comparados a cada teste, com o aumento do número de imagens, procurando o ponto em que as variações se tornaram menores, indicando que o aumento no número de imagens já não traria variações significativas.

Os testes foram repetidos por várias vezes, alterando a combinação das datas das imagens. Como 24 datas estavam disponíveis, várias combinações foram possíveis.

3 RESULTADOS E DISCUSSÃO

3.1 Número de imagens de LST do MODIS necessário para a calibração

Geralmente, um grande número de imagens do MODIS é utilizado para a calibração do FEST-EWB (CORBARI e MANCINI, 2014; RAVAZZANI et al., 2017), no entanto, nenhuma avaliação havia sido realizada com o intuito de identificar o número mínimo de imagens requerido para executar o procedimento. Nesse estudo, um teste foi realizado para detectar o número de imagens necessário para calibrar o modelo na BRU. Esse procedimento é importante, já que pode confirmar a possibilidade de aplicar o modelo FEST-EWB em áreas densamente afetadas por nuvens, com uma limitada disponibilidade de imagens do MODIS em condições favoráveis ao longo do ano.

Para detectar o número mínimo de imagens, diferentes testes foram realizados alternando o conjunto de dados (datas) em cada um deles. A Tabela 8 representa os índices estatísticos de avaliação para cada um dos testes executados. Os resultados, de modo geral, não variaram consideravelmente quando o conjunto de imagens foi alterado, de modo que a tabela é bastante similar entre as diferentes combinações. De acordo com os índices, é possível perceber que a partir de 15 imagens de LST do MODIS, as variações se tornam menores, indicando que o aumento do número de imagens não causa grandes variações, especialmente quando se considera o EM, EMA e LST média.

Tabela 8. Erro médio absoluto (EMA), erro médio (EM) e erro da raiz quadrada média (RMSE) computados para diferentes números de imagens de RET contra LST do MODIS. Todos os índices de avaliação estão expressos em °C; D.P.: desvio-padrão em torno da média.

Núm. de imagens	EMA	EM	RMSE	Média MODIS	D.P. MODIS	Média FEST-EWB	D.P. FEST-EWB
1	3,59	-1,54	4,54	33,63	5,73	32,09	3,16
5	4,82	-3,40	6,00	35,60	5,19	32,20	2,98
10	5,49	-4,08	6,73	36,17	5,37	32,09	2,87
15	5,80	-4,72	6,96	36,90	5,18	32,18	2,84
20	5,91	-4,80	7,18	37,03	5,32	32,23	2,82
24	5,88	-4,76	7,15	37,13	5,34	32,37	2,84

É importante destacar que os índices acima não representam o processo de calibração. Esses resultados indicam apenas o número mínimo de imagens necessário para ser utilizado durante a calibração do FEST-EWB na BRU. Sendo assim, grandes diferenças entre a LST simulada pelo FEST-EWB e mensurada pelo MODIS são percebidas. Essas diferenças foram ajustadas durante a calibração.

Observando alguns dos parâmetros físicos e hidráulicos do solo usados durante o procedimento, é possível perceber que a partir de 15 imagens, a distribuição espacial do índice de Brooks-Corey, da profundidade do solo e da curva número se torna mais similar, com poucas variações (Figura 64). Considerando que a calibração é baseada na comparação da RET com a LST, o objetivo é reduzir erros. Assim, alterações são realizadas nos parâmetros de solo e vegetação, pixel a pixel, com o intuito de aproximar os valores de RET e LST, em cada simulação. Usando um número de imagens igual ou superior a 15, as mudanças nos parâmetros já não são mais percebidas, indicando que esse número de imagens é suficiente na condição avaliada.

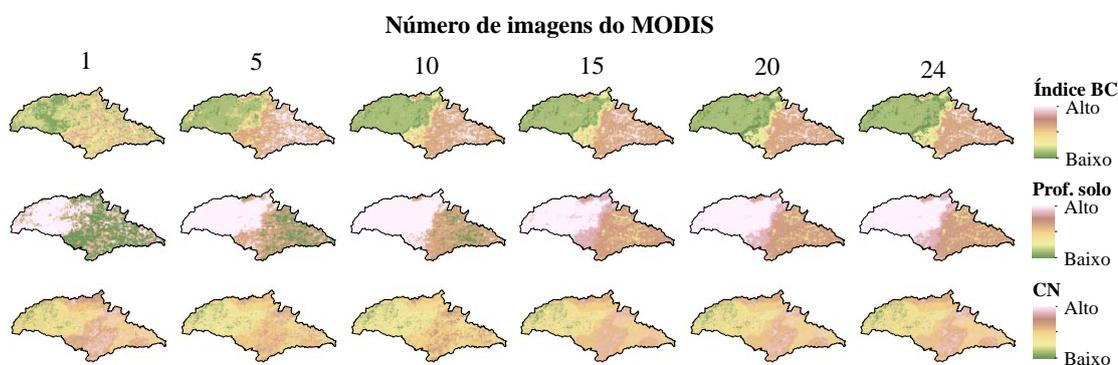


Figura 64. Parâmetros físicos e hidráulicos do solo obtidos a partir de diferentes números de imagens de LST do MODIS durante o teste de 'calibração'. BC: Brooks-Corey; CN: curva número.

A variação nos valores do índice de Brooks-Corey, profundidade do solo e curva número foi de apenas 6,69, 0,90 e 0,22% na bacia, considerando 15 e 24 imagens. Quando 1 a 24 imagens foram consideradas, essa diferença foi maior: 24,41, 17,66 e 8,33%, respectivamente. O teste deixa claro que não é possível calibrar o modelo com apenas uma imagem de LST do MODIS, conforme evidenciado nas diferenças elevadas entre 1 e 24 imagens.

Os histogramas de frequência de LST e RET mostram pequenas variações quando se considera 15 a 24 imagens de RET e dados de LST do MODIS. A média de LST foi de $36,90 \pm 5,18$ °C e $32,18 \pm 2,84$ °C para o FEST-EWB e MODIS, respectivamente, considerando 15 imagens. Quando 24 imagens foram consideradas, os valores médios foram de $37,03 \pm 5,34$ °C e $32,23 \pm 2,84$ °C. Nos dois casos, a distribuição da LST foi muito próxima, mesmo com um incremento de 9 imagens.

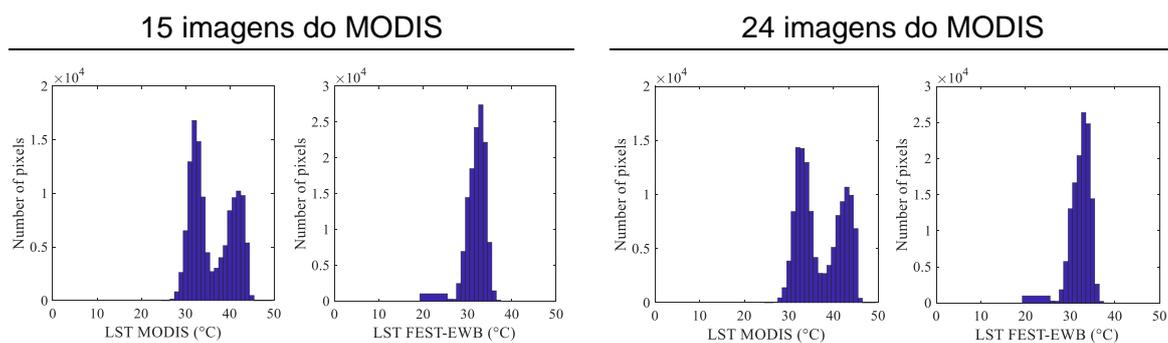


Figura 65. Histogramas de frequência da LST estimada pelo MODIS e FEST-EWB usando 15 e 24 imagens, respectivamente.

Com base nesses resultados, para a calibração do FEST-EWB na BRU, mais de 15 imagens foram consideradas durante o período de estudo (2016-2017). Como determinadas imagens do MODIS possuem limitações na estimativa adequada da LST (KANG et al., 2018), mesmo quando a cobertura de nuvens é inferior a 20%, algumas delas foram filtradas novamente. Apenas imagens com distribuição espacial da LST consistente com aquela registrada nos anos anteriores foram consideradas. Esse procedimento é necessário porque, mesmo de um dia para o outro, há variação significativa no padrão espacial da LST no bioma de Mata Atlântica para algumas datas, ainda que nenhum evento meteorológico que justifique essas alterações tenha sido registrado.

3.2 Calibração

O modelo FEST-EWB é, a princípio, executado na configuração original, onde os parâmetros hidráulicos do solo são definidos de acordo com Rawls e Brakensiek (1985) para os diferentes tipos de solo (CORBARI e MANCINI, 2014). Se necessário, os parâmetros são modificados durante o processo de calibração para melhorar a performance do modelo. Assim, cada parâmetro, em cada pixel, aumenta ou diminui uma determinada porcentagem

considerando a diferença entre a temperatura de superfície do solo simulada e observada.

Na Figura 66, por exemplo, as imagens de LST simulada pelo FEST-EWB e observada pelo MODIS são reportadas para o dia 10 de dezembro de 2016, às 10:30 AM. Na simulação inicial, com a configuração original, a RET apresentou valores de temperatura muito baixos quando comparada ao MODIS. Nesse exemplo, para a primeira simulação, o EM e EMA indicam uma subestimativa de $-5,17\text{ }^{\circ}\text{C}$ e $5,76\text{ }^{\circ}\text{C}$, enquanto o RMSE é igual a $6,58\text{ }^{\circ}\text{C}$. Após a calibração, para a mesma data, o EM e EMA médios apresentaram valores de $-0,61\text{ }^{\circ}\text{C}$ e $2,75\text{ }^{\circ}\text{C}$ sobre a bacia, com RMSE igual a $4,07\text{ }^{\circ}\text{C}$. Observando o formato dos histogramas, é possível perceber que a distribuição da LST simulada pelo FEST-EWB se torna mais similar à registrada pelo MODIS após a calibração, que permitiu ao modelo estimar valores elevados de temperatura mais adequadamente. A LST média foi de $40,75\pm 5,66\text{ }^{\circ}\text{C}$ (MODIS), $35,38\pm 3,46\text{ }^{\circ}\text{C}$ (configuração original do FEST-EWB) e $40,14\pm 4,88\text{ }^{\circ}\text{C}$ (FEST-EWB calibrado), respectivamente.

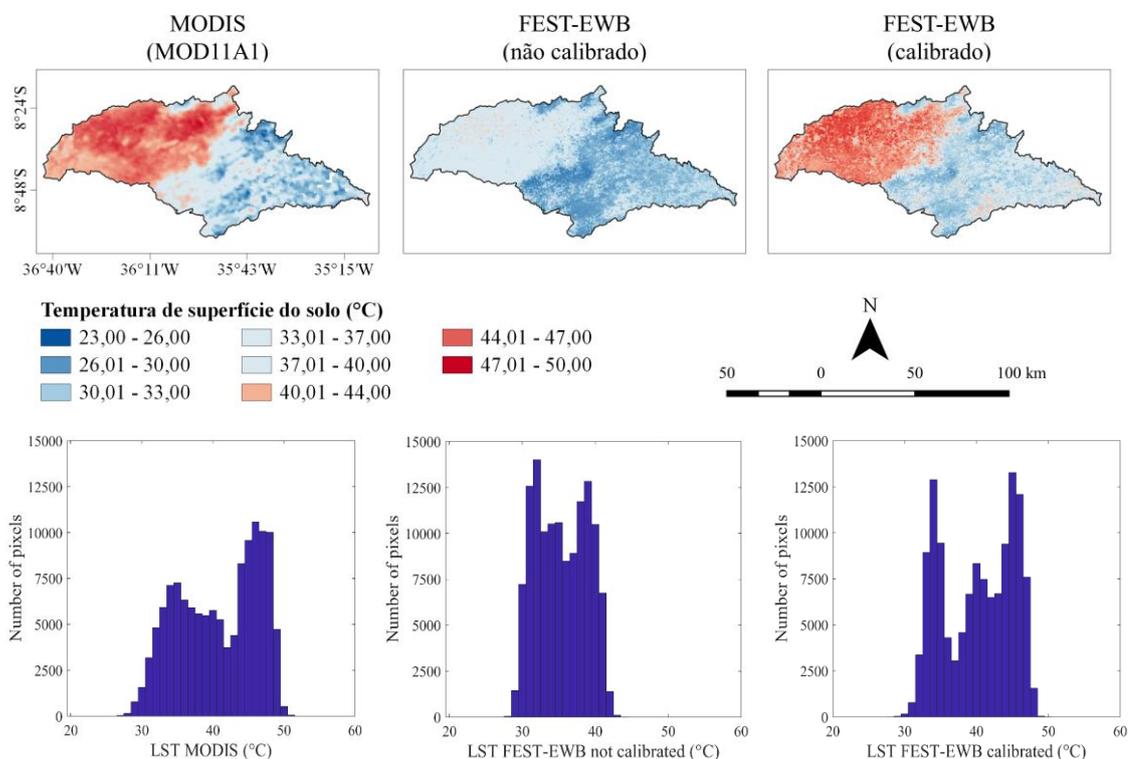


Figura 66. Imagens de temperatura de superfície do solo simulada e observada com seus respectivos histogramas de frequência, para o dia 10 dez. 2016 às 10:30 AM.

A profundidade do solo foi o principal parâmetro de sensibilidade que auxiliou no processo de calibração. Inicialmente, a profundidade do solo foi definida como sendo igual a 1,00 m em toda a bacia. Durante o processo de calibração pixel a pixel, o valor médio foi alterado para 0,63 m. Nesse caso, a redução da profundidade do solo permitiu o aumento da LST. A Tabela 9 mostra os resultados dos parâmetros de avaliação antes e após a calibração do modelo na BRU. Cada parâmetro foi computado individualmente em cada imagem, para cada pixel, e depois um valor médio foi obtido para todo o conjunto de imagens utilizado durante a calibração. Para todas as imagens consideradas, o EM, EMA e RMSE apresentou valores de -2,59 °C, 4,93 °C e 5,49 °C antes da calibração. Após a calibração, os valores foram de 1,31 °C, 3,28 °C e 4,44 °C, respectivamente, reduzindo os erros e aproximando os valores de LST simulada pelo FEST-EWB e observada pelo MODIS.

Tabela 9. Parâmetros de avaliação computados para todas as imagens de RET (FEST-EWB) contra as imagens de LST observada pelo MODIS para as simulações realizadas durante a calibração.

Condição	EM (°C)	EMA (°C)	RMSE (°C)	Média MODIS (°C)	Média FEST-EWB (°C)
Bacia					
Não calibrado	-2,59	4,93	5,49	37,22±5,14	34,63±3,04
Calibrado	1,31	3,28	4,44	37,22±5,14	38,53±4,17
Semiárido					
Calibrado	-0,36	2,54	5,34	40,87±4,06	40,51±3,97
Flor. Atlântica					
Calibrado	3,44	3,93	4,75	32,74±2,42	36,18±1,53

Antes da calibração, o FEST-EWB subestimava a LST. No entanto, após a calibração, o modelo superestimou levemente os valores de LST na bacia. Com o intuito de melhor entender essa tendência, é necessário avaliar as duas regiões climáticas da bacia separadamente, considerando que cada uma delas possui diferentes padrões de LST e cobertura de nuvens, que podem influenciar a calibração. No semiárido, a LST simulada e observada foi muito próxima, com EM igual a -0,36 °C. Na Mata Atlântica, o valor médio de EM foi 3,44 °C. Baseado nisso, é possível perceber que, durante a calibração, a LST aumentou nas duas partes da bacia, com maior intensidade na Mata Atlântica, levando à superestimativa da LST nessa região.

De fato, a Mata Atlântica é bastante afetada pela cobertura de nuvens, com muitos pixels sem dados para algumas datas, já todas as imagens com cobertura de nuvens abaixo de 20% foram consideradas. Essa particularidade pode ter impactado o processo de calibração. Além disso, é importante destacar que o FEST-EWB utiliza outros produtos do MODIS nas simulações, como albedo de superfície e índice de área foliar (IAF) durante todo o período de calibração. Variações na qualidade desses produtos em determinadas épocas do ano também podem levar a diferenças entre a LST simulada e a observada pelo satélite. Embora o albedo e o IAF sejam gerados para um período médio de 8 dias, em uma região densamente nebulosa, alguns pixels podem ter dados de qualidade inferior em determinadas passagens do satélite (PINTO et al., 2014; MUHAMMAD e THAPA, 2019).

Apesar disso, as incertezas na estimativa da LST pelo MODIS estão na mesma faixa de incertezas do FEST-EWB. De acordo com Hulley et al. (2012), as incertezas associadas à estimativa de LST pelo MODIS podem ser aleatórias (ruídos), sistemáticas (calibração), e possuir correlação espaço-temporal devido aos efeitos atmosféricos e da cobertura de nuvens. Nesse sentido, a acurácia do sensor orbital é superior a 1 °C, conforme relatado por Wan et al. (2004). Essa característica torna o MODIS uma boa opção para calibrar modelos hidrológicos distribuídos, como é o caso do FEST-EWB (CORBARI e MANCINI, 2014).

É esperado que o modelo apresente mudanças nos índices de avaliação em diferentes usos do solo e tipos de clima. Realizando uma calibração inicial em uma bacia localizada na Itália, Corbari e Mancini (2014) encontraram variações no padrão de estimativa da LST, com melhores resultados em pastagens, zonas de vegetação escassa e áreas florestais. Na BRU, os melhores resultados foram registrados no semiárido, caracterizado pela Caatinga, um tipo de vegetação desértica encontrada apenas no Brasil. No entanto, é necessário considerar as variações na cobertura de nuvens, que são distintas nas duas condições avaliadas.

Na Figura 67, o EMA foi calculado pixel a pixel pela diferença entre a RET (FEST-EWB) e a LST (MODIS) e, em seguida, um valor médio foi obtido para cada a imagem. Esses dados confirmam os resultados globais anteriormente detectados na bacia. Antes da calibração, o FEST-EWB, em sua

configuração original, apresentava picos mais elevados de EMA. No entanto, após a calibração, esses picos foram reduzidos e se tornaram mais estáveis, indicando a eficiência do procedimento de calibração pixel a pixel.

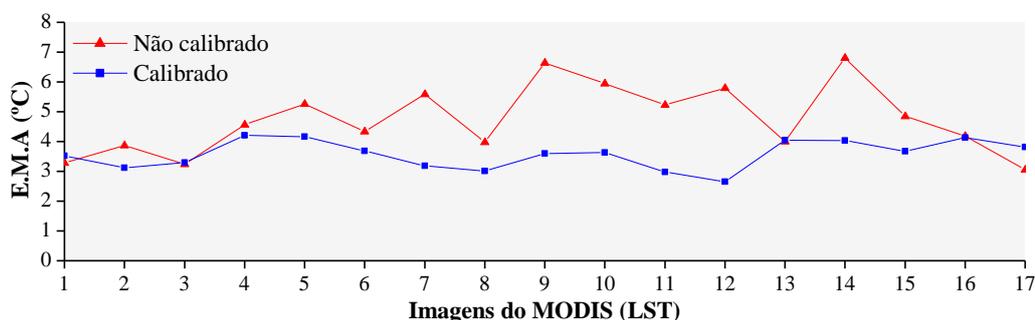


Figura 67. Erro médio absoluto (EMA) obtido pela diferença entre a RET (FEST-EWB) e a LST (MODIS) antes e após a calibração, para cada imagem utilizada durante o procedimento.

Conforme mostrado anteriormente, os índices de avaliação variaram bastante na bacia devido às condições climáticas distintas, que também geram grande diversidade ambiental e paisagística. Enquanto o semiárido é marcado pela vegetação nativa da Caatinga, a Mata Atlântica possui florestas mais densas e áreas com produção de cana-de-açúcar, sendo severamente afetada pela cobertura de nuvens. Por esse motivo, as diferenças entre a LST simulada pelo FEST-EWB e observada pelo MODIS tendem a ser maiores nessa região ao longo do período de calibração (Figura 68). No semiárido, o EMA médio foi de 2,54 °C, enquanto na Mata Atlântica o valor foi de 3,93 °C e, nesse caso, superestimando o LST.

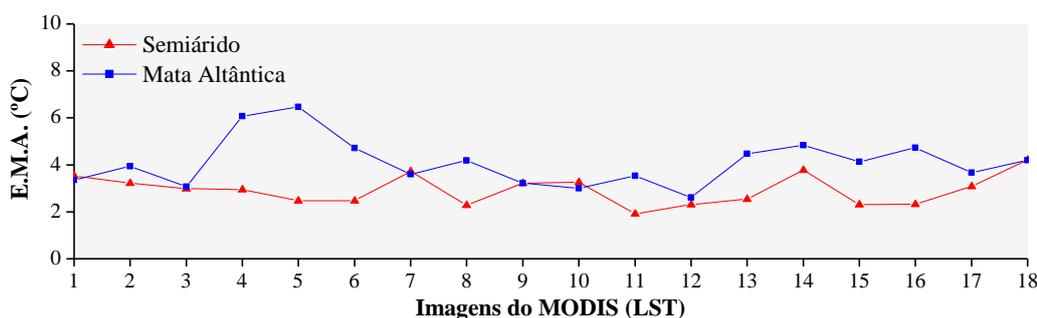


Figura 68. Erro médio absoluto (EMA) obtido pela diferença entre a RET (FEST-EWB) e a LST (MODIS) antes e após a calibração, para cada imagem utilizada durante o procedimento nas duas regiões climáticas da BRU.

3.3 Validação

Após a calibração do modelo FEST-EWB, os dados de LST e umidade do solo gerados foram validados utilizando dados registrados *in situ* por estações agrometeorológicas, nos dois tipos climáticos da bacia.

3.3.1 Temperatura de superfície do solo (LST)

Na configuração original, o FEST-EWB subestimou a LST. Após a calibração, os valores de LST aumentaram na bacia, aproximando-se dos registrados pelo MODIS. Durante a calibração, o MODIS é usado como referência e serve para validar indiretamente o FEST-EWB em escala espacial. No entanto, uma validação em escala pontual deve ser realizada para garantir a confiabilidade dos dados gerados pelo modelo. A Figura 69 mostra as validações realizadas em duas estações, uma localizada no semiárido (Figura 69A) e outra na Mata Atlântica (Figura 69B).

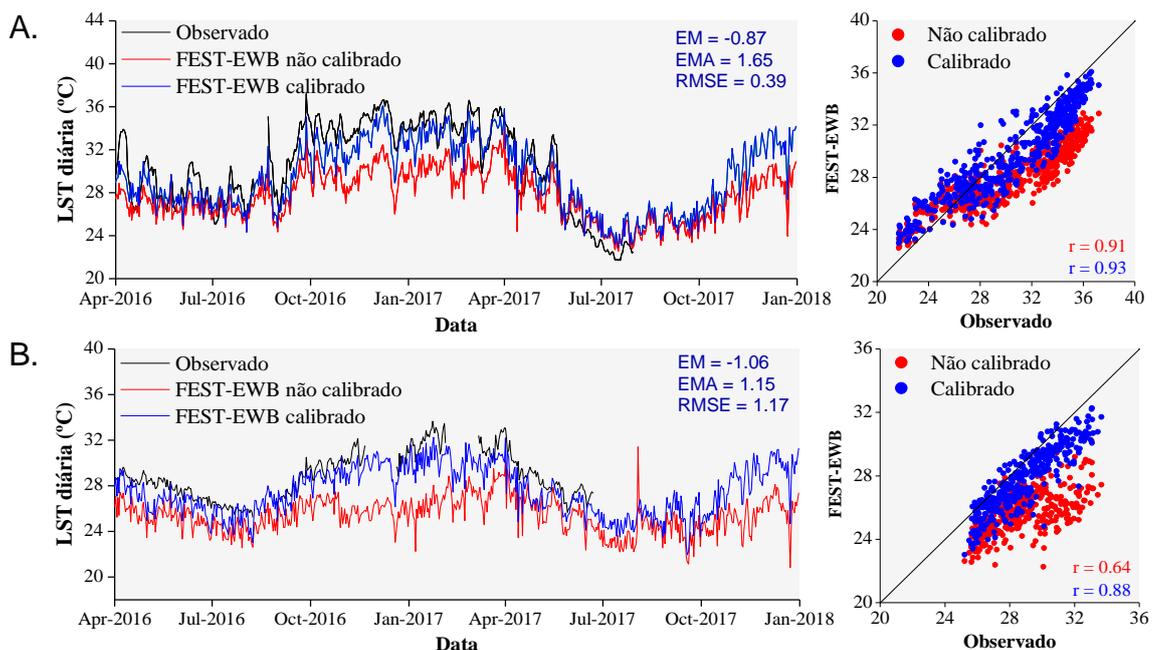


Figura 69. Comparação da LST diária estimada pelo FEST-EWB e observada pelas estações em superfície durante os anos de 2016 e 2017. (A) São Bento do Una, semiárido; (B) Barreiros, Mata Atlântica; r = coeficiente de correlação. EM, EMA e RMSE referem-se aos dados calibrados.

Nos dois casos, a LST aumentou após a calibração, especialmente durante o período de setembro de 2016 a maio de 2017, quando foram registradas as temperaturas mais altas na bacia. Antes da calibração, o FEST-

EWB tinha limitações para estimar a LST quando os valores aumentavam, o que foi corrigido após o procedimento. Além disso, é interessante notar que, embora a Mata Atlântica tenha superestimado a LST em escala espacial (EM= 3,44 °C) quando comparada ao MODIS, em escala pontual houve uma ligeira tendência de subestimativa (EM= -1,06 °C). Novamente, esse padrão pode destacar as limitações das estimativas de LST pelo MODIS nessa região.

Após a calibração, as duas estações no semiárido e na Mata Atlântica apresentaram valores de EMA iguais a 1,65 °C e 1,15 °C durante a validação, respectivamente, inferiores aos registrados espacialmente durante a comparação com dados do MODIS. Embora a validação tenha apresentado bons resultados em ambos os casos, a estação de Barreiros (Mata Atlântica) foi avaliada separadamente, já que essa região é mais afetada pela cobertura de nuvens.

Para essa avaliação, os dados de LST do MODIS foram plotados para dar uma ideia da qualidade das estimativas do satélite quando comparado aos dados do FEST-EWB e de superfície. Ao contrário dos gráficos anteriores, que mostravam a média diária de LST, a Figura 70 representa a LST referente ao horário de passagem do satélite (10:30 AM). É possível notar que, nesse momento específico, a LST observada pelo MODIS ($r = 0,69$) e estimada pelo FEST-EWB ($r = 0,78$) é superior à registrada *in situ*. No entanto, os dados MODIS variam significativamente dos valores de referência (*in situ*). Esse padrão é incomum, já o satélite tem boa precisão na estimativa da LST, fato confirmado em vários estudos (WANG et al., 2008; LU et al., 2018; DUAN et al., 2019). Conforme mencionado por Kang et al. (2018), a presença de nuvens interfere na recepção do sinal MODIS, o que de fato pode causar interferência na qualidade dos dados medidos e afetar sua aplicação em algumas regiões.

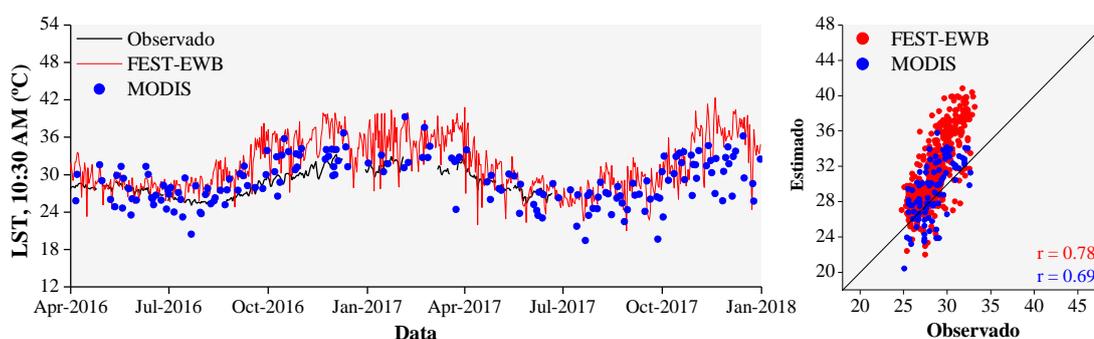


Figura 70. Comparação da LST diária (10:30 AM) simulada pelo FEST-EWB, estimada pelo MODIS e observada na estação de Barreiros (Mata Atlântica).

Mesmo com as limitações do MODIS em parte da bacia, os dados de LST observados pelo satélite foram essenciais para a calibração do FEST-EWB, permitindo obter bons resultados, inclusive em escala pontual. Obviamente, a qualidade dos dados de sensoriamento remoto é inferior à registrada *in situ* devido a vários fatores, principalmente em virtude das resoluções espaciais e temporais dos sensores, algoritmo, ângulo de visão etc. Corbari et al. (2015b), comparando dados gerados com um modelo de balanço de energia residual (REB) com informações estimadas pelo MODIS, em uma área agrícola, perceberam que as diferenças aumentam quando dados de satélite são usados em substituição aos dados *in situ* nas comparações. Esse mesmo padrão é esperado em outros modelos, como o FEST-EWB, o que reforça a importância da validação de dados de superfície.

3.3.2 Umidade do solo (US)

Em todos os casos, a umidade do solo apresentou melhores valores após a calibração, indicando que alterações nos parâmetros do solo e da vegetação afetam diretamente a dinâmica temporal da LST e US. A Tabela 10 evidencia o resumo de alguns índices de avaliação. Como o FEST-EWB estava subestimando inicialmente a LST, os valores de US tenderam a ser mais altos na bacia. Com a calibração e aumento da LST, naturalmente os valores de US diminuíram em todos os pontos, aproximando-se dos dados registrados pelas estações *in situ*. Nas estações localizadas no semiárido (São Bento do Una e Lajedo), a redução na US foi ainda mais acentuada. De fato, nessa região, a LST foi muito subestimada pelo modelo antes da calibração, como mostra a Figura 66. Assim, espera-se que haja uma maior mudança na dinâmica da US nessa área após a calibração. Corbari and Mancini (2014), calibrando o modelo FEST-EWB na Itália, também observaram que a mudança na dinâmica da LST causa variação em suas variáveis conectadas, como US e evapotranspiração.

Tabela 10. Índices de avaliação da umidade do solo estimada pelo FEST-EWB antes e depois da calibração na Bacia do Rio Una. EM e EMA estão expressos em $m^3 m^{-3}$.

Estação	Clima	Antes da calibração			Após a calibração		
		EM	EMA	R ²	EM	EMA	R ²
Barreiros	Mata Atl.	-0,01	0,08	0,63	-0,03	0,05	0,80
São Bento do Una	Semiárido	0,16	0,16	0,52	0,00	0,03	0,51
Lajedo	Semiárido	0,06	0,09	0,23	-0,01	0,03	0,67

A variação temporal da umidade do solo registrada pelas estações e estimada pelo FEST-EWB (na melhor simulação) pode ser vista na Figura 71. Embora a flutuação dos dados tenha sido semelhante antes e após a calibração, o procedimento permitiu a remoção de tendências, tornando os dados *in situ* e simulados mais semelhantes. As três estações estão inseridas em diferentes condições e, portanto, foram selecionadas para validação. A estação de São Bento do Una está localizada no extremo oeste da bacia, no semiárido, onde as temperaturas são as mais altas ao longo do ano. Isso pode ser percebido pelo baixo conteúdo de água armazenado no solo durante o período do estudo. A estação de Lajedo, também inserida no semiárido, fica mais próxima da zona de transição climática, local em que os valores de US se tornam mais elevados. A estação de Barreiros está localizada no extremo leste da bacia, no clima de Mata Atlântica e perto do litoral. Nesta região, o conteúdo de água armazenado no solo é o mais alto da bacia.

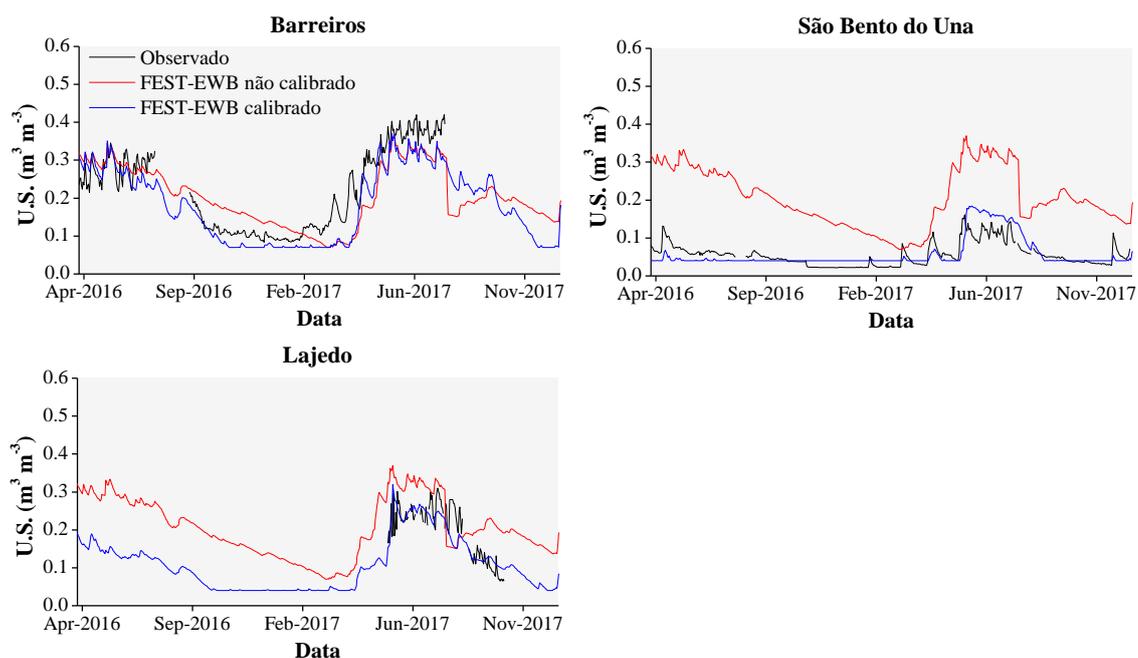


Figura 71. Comparação da umidade do solo (U.S.) simulada e observada na Bacia do Rio Una durante os anos de 2016 e 2017.

Desde que as primeiras calibrações foram realizadas, o FEST-EWB tem mostrado bons resultados na estimativa de várias variáveis de balanço hídrico e energético. Embora neste estudo o foco tenha sido LST e US, outras variáveis já foram adequadamente estimadas pelo modelo em diferentes aplicações. Corbari e Mancini (2014), Corbari et al. (2015b) e Ravazzani et al. (2017), por exemplo, utilizaram o modelo para estimar a evapotranspiração e

os fluxos de energia. No último estudo citado, o FEST-EWB também foi validado com dados do US, representando consistentemente a variação do conteúdo de água ao longo de um período de três anos adotado na avaliação.

4 CONCLUSÕES

Este estudo foi realizado com o objetivo de calibrar e validar um modelo de balanço de água e energia distribuído (FEST-EWB) em uma bacia inserida em uma zona de transição climática entre o semiárido e a Mata Atlântica. Como a área da Mata Atlântica é caracterizada pela alta incidência de nuvens, o estudo investigou a possível influência desse padrão na calibração do modelo, uma vez que imagens do sensor MODIS são utilizadas durante o procedimento. De fato, nessa região, os índices de avaliação indicaram que o FEST-EWB superestimou espacialmente a LST quando comparado à área semiárida, levando a uma grande variação da LST, embora a validação com dados *in situ* tenha apresentado bons resultados.

Esses resultados indicam que, ainda que os dados do sensor MODIS permitam que o modelo seja calibrado adequadamente, seu uso pode ser prejudicado em áreas fortemente afetadas pela cobertura de nuvens, especialmente quando o número de imagens disponível é limitado, como neste caso. Apesar disso, mesmo com um pequeno número de imagens do MODIS, a calibração foi possível, mostrando resultados satisfatórios para LST e umidade do solo na bacia.

Os resultados obtidos são relevantes, principalmente quando se considera que mais de 80% do território de Pernambuco está inserido no semiárido, onde foram registrados os melhores resultados com a calibração. Assim, espera-se que resultados semelhantes sejam obtidos com a calibração do FEST-EWB em outras bacias, especialmente nesta área, já que elas são pouco afetadas pela cobertura de nuvens.

De modo geral, os resultados gerados neste estudo evidenciam que a primeira calibração e validação do modelo FEST-EWB no Nordeste do Brasil foi bem-sucedida. Em investigações futuras, é importante calibrar o modelo em bacias maiores e com uma rede de dados de superfície mais completa, permitindo a validação de fluxos de energia que, como a umidade do solo, estão relacionados à LST.

CONSIDERAÇÕES FINAIS

Dentre as ações do novo Plano Nacional de Segurança Hídrica, destacam-se (1) o monitoramento de eventos extremos e posterior (2) gestão dos riscos a eles associados. Nesse sentido, qualquer método alternativo ao monitoramento de atributos relacionados à gestão de recursos hídricos, especialmente aqueles que atuam diretamente na incidência de seca ou são afetados por ela, deve ser sempre utilizado e aprimorado.

Nesse estudo, métodos alternativos baseados em sensoriamento remoto foram adotados para avaliar a variabilidade espaço-temporal da precipitação, umidade do solo e a sua aplicabilidade na detecção de eventos de seca e escassez hídrica. Além disso, um modelo hidrológico distribuído (FEST-EWB) teve a sua primeira aplicação realizada na América, sendo a sua eficiência testada em uma bacia hidrográfica inserida em zona de transição climática entre a Mata Atlântica e o semiárido. Aplicações anteriores com o modelo costumaram ocorrer na Itália, onde a sazonalidade climática é bem definida, inclusive com presença de neve em diversas bacias durante vários meses do ano, situação contrária à detectada no Nordeste.

Em ambos os casos, tanto por meio de sensoriamento remoto quanto de modelagem hidrológica, os dados obtidos foram bastante consistentes, evidenciando a necessidade de impulsionar estudos que façam uso de métodos alternativos em substituição à tradicional avaliação baseada em dados de superfície, que costumam ser escassos ou falhos. Uma das principais limitações à adoção de novos métodos ou tecnologias ainda reside na limitante resolução espacial (no caso dos satélites) ou do elevado esforço necessário para a calibração de modelos hidrológicos distribuídos, que requerem quantidades massivas de dados de entrada (como o FEST-EWB).

Em decorrência das limitações supracitadas, fica evidente a necessidade de, em estudos posteriores, avaliar a aplicabilidade de técnicas que permitam realizar o *downscaling* dos dados espaciais obtidos por sensoriamento remoto, possibilitando refinar a resolução espacial desses produtos e favorecer a sua aplicação em microescala, o que ainda representa um desafio. No caso do FEST-EWB, que teve um alto potencial para a modelagem da temperatura de superfície e da umidade do solo, especialmente

no semiárido, é válido confirmar se esse mesmo padrão se mantém nas demais bacias da região. Por se tratar de uma primeira aplicação, a continuidade desse estudo é essencial, inclusive com a validação de outras componentes do balanço de água e energia também fornecidas pelo modelo, como a evapotranspiração, escoamento e vazão que, nesse estudo, não foram avaliadas em decorrência da escassez de dados *in situ*.

REFERÊNCIAS

AADHAR, S.; MISHRA, V. High-resolution near real-time drought monitoring in South Asia. **Scientific Data**, v. 4, p. 170145, 2017. DOI: 10.1038/sdata.2017.145.

ABBASPOUR, K. C.; VAGHEFI, S. A.; SRINIVASAN, R. A guideline for successful calibration and uncertainty analysis for soil and water assessment: a review of papers from the 2016 International SWAT conference. **Water**, 10(6), 2018. DOI: 10.3390/w10010006.

ADEYEWA, Z. D.; NAKAMURA, K. Validation of TRMM Radar Rainfall Data over Major Climatic Regions in Africa. **Journal of Applied Meteorology**, v. 42, nº 2, p. 331–347, 2003. DOI: 10.1175/1520-0450.

AL-YAARI, A.; WIGNERON, J. P.; DUCHARNE, A.; KERR, Y. H.; WAGNER, W.; LANNOY, G. DE; REICHLER, 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. DOI: 10.1016/j.rse.2014.07.013.

AL-YAARI, A.; WIGNERON, J. P.; DUCHARNE, A.; KERR, Y.; ROSNAY, P. DE; JEU, R. DE; GOVIND, A.; BITAR, A. AL; ALBERGEL, C.; MUÑOZ-SABATER, J.; RICHAUME, P.; MIALON, A. Global-scale evaluation of two satellite-based passive microwave soil moisture datasets (SMOS and AMSR-E) with respect to Land Data Assimilation System estimates. **Remote Sensing of Environment**, v. 149, p. 181–195, 2014. DOI: 10.1016/j.rse.2014.04.006.

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**, nº November 2015, p. 431–448, 2013. DOI: 10.1201/b15610-22.

ALI, Z.; HUSSAIN, I.; FAISAL, M. Annual Characterization of Regional Hydrological Drought using Auxiliary Information under Global Warming Scenario. **Natural Hazards and Earth System Sciences Discussions**, nº February, p. 1–20, 2019. DOI: 10.5194/nhess-2018-373.

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. In press, n° 0, p. 1–15, 2017. DOI: 10.1590/0001-3765201720170209.

AMEKUDZI, L. K.; OSEI, M. A.; ATIAH, W. A.; ARYEE, J. N. A.; AHIATAKU, M. A.; QUANSAH, E.; PREKO, K.; DANUOR, S. K.; FINK, A. H. Validation of TRMM and FEWS Satellite Rainfall Estimates with Rain Gauge Measurement over Ashanti Region, Ghana. **Atmospheric and Climate Sciences**, v. 06, n° 04, p. 500–518, 2016. DOI: 10.4236/acs.2016.64040.

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. DOI: 10.1175/JHM-D-12-016.1.

AMRI, R.; ZRIBI, M.; LILI-CHABAANE, Z.; DUCHEMIN, B.; GRUHIER, C.; CHEHBOUNI, A. Analysis of vegetation behavior in a North African semi-arid region, Using SPOT-VEGETATION NDVI data. **Remote Sensing**, v. 3, n° 12, p. 2568–2590, 2011. DOI: 10.3390/rs3122568.

ANAM, R.; CHISHTIE, F.; GHUFFAR, S.; QAZI, W.; SHAHID, I. Inter-comparison 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. DOI: 10.1080/22797254.2017.1352461.

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 Física**, v. 51, n° 2, p. 440–453, 2017a. DOI: 10.1016/S0140-6736(00)04868-6.

ANDRADE, C. W. L. De; 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, 2017b. DOI: 10.24221/jeap.2.3.2017.1446.239-248.

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, nº 3, p. 447–462, 2017.

ANJOS, R. S.; NÓBREGA, R. S.; CANDEIAS, A. L. B. Possíveis causas para os erros das estimativas do satélite TRMM - Estudo de caso na microrregião de Itaparica - PE. **Revista Brasileira de Climatologia**, v. 21, p. 295–312, 2017.

ANTONIO, J. A. P. de; OLIVEIRA, P. J. de. Sensoriamento Remoto I. São Cristovão: Universidade Federal de Sergipe, 2010. 62 p.

ARAÚJO, D. C. dos S.; MONTENEGRO, S. M. G. L.; GUSMÃO, A. C. V. e L.; RODRIGUES, D. F. B. Validation of SMOS - IC Soil Moisture Over Brazilian Semiarid using in situ Measurements. **EPiC Series in Engineering**, v. 3, nº November 2009, p. 54–61, 2018.

ARAUJO, D. C. S.; MONTENEGRO, S. M. G. L.; MONTENEGRO, A. A. A.; SANTOS, D. P.; RODRIGUES, R. A. S. Temporal stability of soil moisture in banana cropping area in the Brazilian semiarid region. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 23, nº 11, p. 852–859, 2019. DOI: <http://dx.doi.org/10.1590/1807-1929/agriambi.v20n10p880-885>.

AUGUSTO, C.; SANTOS, G.; MOURA, R.; NETO, B.; SOBRAL, J.; PASSOS, D. A.; SILVA, R. M. Drought assessment using a TRMM-derived standardized precipitation index for the upper São Francisco River basin, Brazil. **Environ Monit Assess**, v. 189, p. 1–19, 2017. DOI: 10.1007/s10661-017-5948-9.

BAI, J.; CUI, Q.; CHEN, D.; YU, H.; MAO, X.; MENG, L.; CAI, Y. Assessment of the SMAP-Derived Soil Water Deficit Index (SWDI-SMAP) as an Agricultural Drought Index in China. **Remote Sensing**, v. 10, nº 8, p. 1302, 2018a. DOI: 10.3390/rs10081302.

BAI, L.; SHI, C.; LI, L.; YANG, Y.; WU, J. Accuracy of CHIRPS satellite-rainfall products over mainland China. **Remote Sensing**, v. 10, nº 3, 2018b. DOI: 10.3390/rs10030362.

BAYER, D.; COLLISCHONN, W. Análise de Sensibilidade do Modelo MGB-IPH a Mudanças de uso da Terra. **Revista Brasileira de Recursos Hídricos**, v. 18, nº 3, p. 165–179, 2016. DOI: 10.21168/rbrh.v18n3.p165-179.

BERIA, H.; NANDA, T.; BISHT, D. S.; CHATTERJEE, C. Does the GPM mission improve the systematic error component in satellite rainfall estimates over TRMM? An evaluation at a pan-India scale. **Hydrology and Earth System Sciences**, v. 21, nº 12, p. 6117–6134, 2017. DOI: 10.5194/hess-21-6117-2017.

BEZERRA, J. M.; MOURA, G. B. de A.; SILVA, B. B. Da; LOPES, P. M. O.; SILVA, Ê. F. de F. e. Parâmetros biofísicos obtidos por sensoriamento remoto em região semiárida do estado do Rio Grande do Norte, Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, nº 1, p. 73–84, 2014. DOI: 10.1590/s1415-43662014000100010.

BITTELLI, M. Measuring soil water content: A review. **HortTechnology**, v. 21, nº 3, p. 293–300, 2011.

BLAIN, G. C. Aplicação do conceito do Índice padronizado de precipitação à série decenal da diferença entre precipitação pluvial e evapotranspiração potencial. **Bragantia**, v. 70, nº 1, p. 234–245, 2011. DOI: 10.1590/S0006-87052011000100031.

BROCCA, L.; HASENAUER, S.; LACAVA, T.; MELONE, F.; MORAMARCO, T.; WAGNER, W.; DORIGO, W.; MATGEN, P.; MARTÍNEZ-FERNÁNDEZ, J.; LLORENS, P.; LATRON, J.; MARTIN, C.; BITTELLI, M. Soil moisture estimation through ASCAT and AMSR-E sensors: An intercomparison and validation study across Europe. **Remote Sensing of Environment**, v. 115, nº 12, p. 3390–3408, 2011. DOI: 10.1016/j.rse.2011.08.003.

BROCCA, L.; TARPANELLI, A.; MORAMARCO, T.; MELONE, F.; RATTO, S. M.; CAUDURO, M.; FERRARIS, S.; BERNI, N.; PONZIANI, F.; WAGNER, W.; MELZER, T. Soil Moisture Estimation in Alpine Catchments through Modeling and Satellite Observations. **Vadose Zone Journal**, v. 12, nº 3, p. 1–10, 2013. DOI: 10.2136/vzj2012.0102.

BROCCA, L.; MELONE, F.; MORAMARCO, T. Distributed rainfall-runoff modelling for flood frequency estimation and flood forecasting. **Hydrological Processes**, v. 25, nº 18, p. 2801–2813, 2011. DOI: 10.1002/hyp.8042.

BROCCA, Luca; CROW, W. T.; CIABATTA, L.; MASSARI, C.; ROSNAY, P. DE; ENENKEL, M.; HAHN, S.; AMARNATH, G.; CAMICI, S.; TARPANELLI, A.; WAGNER, W. A Review of the Applications of ASCAT Soil Moisture Products.

IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, v. 10, n° 5, p. 2285–2306, 2017. DOI: 10.1109/JSTARS.2017.2651140.

BROCCA, Luca; CIABATTA, L.; MASSARI, C.; CAMICI, S.; TARPANELLI, A. Soil Moisture for Hydrological Applications: Open Questions and New Opportunities. **Water**, v. 9, n° 2, p. 140, 2017. DOI: 10.3390/w9020140.

BRUNNER, P.; FRANSSSEN, H. H.; KGOTLHANG, L.; BAUER-GOTTWEIN, P.; KINZELBACH, W. How can remote sensing contribute in groundwater modeling? **Hydrogeology Journal**, v. 15, p. 5–18, 2007. DOI: 10.1007/s10040-006-0127-z.

BUYTAERT, W.; FRIESEN, J.; LIEBE, J.; LUDWIG, R. Assessment and Management of Water Resources in Developing, Semi-arid and Arid Regions. **Water Resource Manage**, v. 26, p. 841–844, 2012. DOI: 10.1007/s11269-012-9994-3.

CAMPELLO DE MELO, D. F. B.; RIBEIRO, M. H. G.; ALBUQUERQUE JUNIOR, E. C.; GONÇALVES, E. A. P. Evaluation of the Una-Pernambuco River Basin: water quality perspective after construction of 4 flooding containment dams. **Revista Brasileira de Geografia Física**, v. 11, n° 2, p. 612–627, 2018.

CAO, Y.; ZHANG, W.; WANG, W. Evaluation of TRMM 3B43 data over the Yangtze River Delta of China. **Scientific Reports**, n° August 2017, p. 1–12, 2018. DOI: 10.1038/s41598-018-23603-z.

CÁSSIA, R. Políticas públicas no Nordeste do Brasil: a produção de enclaves e de desigualdades socioespaciais. **GOT - Geography and Spatial Planning Journal**, n° 8, p. 11–31, 2015. DOI: 10.17127/got/2015.8.002.

CAVALCANTE, K. L.; DEON, M. D.; SILVA, H. K. P. Estudo das características restritivas dos efluentes das estações de tratamento de esgoto de Petrolina-PE para uso na agricultura irrigada. **Revista Brasileira de Agricultura Irrigada**, v. 7679, p. 1331–1338, 2017. DOI: 10.7127/rbai.v11n200620.

CHAMPAGNE, C.; ROWLANDSON, T.; BERG, A.; BURNS, T.; L'HEUREUX, J.; TETLOCK, E.; ADAMS, J. R.; MCNAIRN, H.; TOTH, B.; ITENFISU, D.

Satellite surface soil moisture from SMOS and Aquarius: Assessment for applications in agricultural landscapes. **International Journal of Applied Earth Observation and Geoinformation**, v. 45, p. 143–154, 2016. DOI: 10.1016/j.jag.2015.09.004.

CHAO, L.; ZHANG, K.; LI, Z.; ZHU, Y.; WANG, J.; YU, Z. Geographically weighted regression based methods for merging satellite and gauge precipitation. **Journal of Hydrology**, v. 558, p. 275–289, 2018. DOI: 10.1016/j.jhydrol.2018.01.042.

CHEN, C.; CHEN, Q.; DUAN, Z.; ZHANG, J.; MO, K.; LI, Z.; TANG, G. Multiscale comparative evaluation of the GPM IMERG v5 and TRMM 3B42 v7 precipitation products from 2015 to 2017 over a climate transition area of China. **Remote Sensing**, v. 10, n° 6, p. 1–18, 2018. DOI: 10.3390/rs10060944.

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. DOI: 10.4028/www.scientific.net/AMR.781-784.2292.

CHEN, Yingjun; 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. DOI: 10.1002/jgrd.50250.

CHEN, Yingying; 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. DOI: 10.1002/2016JD026388.

CIRILO, J. A. Políticas Públicas De Recursos Hídricos Para O Semi-Árido. **Estudos Avançados**, v. 22, n° 63, p. 61–82, 2008a. DOI: 10.1590/S0103-40142008000200005.

CORBARI, C; BISSOLATI, M.; MANCINI, M. Multi-scales and multi-satellites estimates of evapotranspiration with a residual energy balance model in the Muzza agricultural district in Northern Italy. **Journal of Hydrology**, v. 524, p. 243–254, 2015b. DOI: 10.1016/j.jhydrol.2015.02.041.

CORBARI, C.; RAVAZZANI, G.; MARTINELLI, J.; MANCINI, M. Elevation based correction of snow coverage retrieved from satellite images to improve model calibration. **Hydrology and Earth System Sciences**, v. 13, p. 639–649, 2009.

CORBARI, C.; MANCINI, M. Calibration and Validation of a Distributed Energy–Water Balance Model Using Satellite Data of Land Surface Temperature and Ground Discharge Measurements. **Journal of Hydrometeorology**, v. 15, n° 1, p. 376–392, 2013. DOI: 10.1175/jhm-d-12-0173.1.

CORBARI, C.; RAVAZZANI, G.; MANCINI, M. A distributed thermodynamic model for energy and mass balance computation : FEST – EWB. **Hydrological Processes**, v. 1452, n° November 2010, p. 1443–1452, 2011. DOI: 10.1002/hyp.7910.

CORBARI, C.; TIMMERMANS, W.; ANDREU, A. Intercomparison of Surface Energy Fluxes Estimates from the FEST-EWB and TSEB Models over the Heterogeneous REFLEX 2012 Site (Barrax, Spain). **Acta Geophysica**, v. 63, n° 6, p. 1609–1638, 2015a. DOI: 10.2478/s11600-014-0258-x.

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. DOI: 10.1016/j.rse.2007.07.001.

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.

CUI, C.; XU, J.; ZENG, J. Soil Moisture Mapping from Satellites : and ESA CCI over Two Dense Network Regions at Different Spatial Scales. **Remote Sensing**, v. 10, n° 33, p. 1–19, 2018. DOI: 10.3390/rs10010033.

CUNHA, A. P. M. A. et al. Extreme drought events over Brazil from 2011 to 2019. **Atmosphere**, v. 10, n° 11, p. 642, 2019. DOI: 10.3390/atmos10110642.

DAMBERG, L.; AGHAKOUCHAK, A. Global trends and patterns of drought from space. **Theoretical and Applied Climatology**, v. 117, n° 3–4, p. 441–448, 2014. DOI: 10.1007/s00704-013-1019-5.

DEMBÉLÉ, M.; ZWART, S. J. Evaluation and comparison of satellite-based rainfall products in Burkina Faso , West Africa. **International Journal of Remote Sensing**, v. 37, n° 17, p. 3995–4014, 2016. DOI: 10.1080/01431161.2016.1207258.

DENTE, L.; SU, Z.; WEN, J. Validation of SMOS soil moisture products over the Maqu and Twente Regions. **Sensors (Switzerland)**, v. 12, n° 8, p. 9965–9986, 2012. DOI: 10.3390/s120809965.

DINKU, T.; FUNK, C.; PETERSON, P.; MAIDMENT, R.; TADESSE, T.; GADAIN, H.; CECCATO, P. Validation of the CHIRPS satellite rainfall estimates over eastern Africa. **Quarterly Journal of the Royal Meteorological Society**, v. 144, n° April, p. 292–312, 2018. DOI: 10.1002/qj.3244.

DJAMAI, N.; MAGAGI, R.; GOÏTA, K.; HOSSEINI, M.; COSH, M. H.; BERG, A.; TOTH, B. Evaluation of SMOS soil moisture products over the CanEx-SM10 area. **Journal of Hydrology**, v. 520, n° January, p. 254–267, 2015. DOI: 10.1016/j.jhydrol.2014.11.026.

DORE, M. H. I. Climate change and changes in global precipitation patterns: What do we know? **Environment International**, v. 31, n° 8, p. 1167–1181, 2005. DOI: 10.1016/j.envint.2005.03.004.

DUAN, S. B.; LI, Z. L.; LI, H.; GÖTTSCHE, F. M.; WU, H.; ZHAO, W.; LENG, P.; ZHANG, X.; COLL, C. Validation of Collection 6 MODIS land surface temperature product using in situ measurements. **Remote Sensing of Environment**, v. 225, n° February, p. 16–29, 2019. DOI: 10.1016/j.rse.2019.02.020.

DUARTE, A.; JUNIOR, M.; DA, C.; SILVEIRA, S.; DAS, F.; VASCONCELOS, C.; GUIMARÃES, S. O.; MICAEL, J.; DA, F. Classificação Climática de Thornthwaite para o Brasil com Base em Cenários de Mudanças Climáticas do IPCC-AR5. **Revista Brasileira de Meteorologia**, v. 33, n° 4, p. 647–664, 2018.

EMAMI, F.; KOCH, M. Modeling the Impact of Climate Change on Water Availability in the Zarrine River Basin and Inflow to the Boukan Dam, Iran. **Climate**, v. 7, n° 51, p. 1–20, 2019.

FARIAS, A. A.; SOUZA, J. T. A.; SOUSA, F. de A. S. De. Identificação e análise de secas severas e extremas no município de Taperoá-PB. **Revista Brasileira**

de Geografia Física, v. 07, nº 05, p. 818–826, 2014.

FERNANDES, D. S.; HEINEMANN, A. B.; PAZ, R. L.; AMORIM, A. de O.; CARDOSO, A. S. Índices para a Quantificação da Seca. **Embrapa Arroz e Feijão**, Santo Antônio de Goiás, p. 48, 2009.

FERNANDEZ-MORAN, R.; AL-YAARI, A.; MIALON, A.; MAHMOODI, A.; BITAR, A. AL; LANNOY, G. DE; RODRIGUEZ-FERNANDEZ, N.; LOPEZ-BAEZA, E.; KERR, Y.; WIGNERON, J. P. SMOS-IC: An alternative SMOS soil moisture and vegetation optical depth product. **Remote Sensing**, v. 9, nº 5, p. 1–26, 2017. DOI: 10.3390/rs9050457.

FERREIRA, F. H. G.; LANJOUW, P.; NERI, M. A robust poverty profile for Brazil using multiple data sources. **Revista Brasileira de Economia**, v. 57, nº 1, p. 59–92, 2003. DOI: 10.1590/s0034-71402003000100003.

FICK, S. E.; HIJMANS, R. J. WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. **International Journal of Climatology**, v. 37, nº 12, p. 4302–4315, 2017. DOI: 10.1002/joc.5086.

FONTES JÚNIOR, R.; MONTENEGRO, A. Impact of land use change on the water balance in a representative watershed in the semiarid of the State of Pernambuco using the SWAT model. **Engenharia Agricola**, v. 39, nº 1, p. 110–117, 2019. DOI: 10.1590/1809-4430-Eng.Agric.v39n1p110-117/2019.

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAND, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations - A new environmental record for monitoring extremes. **Scientific Data**, v. 2, nº December, 2015. DOI: 10.1038/sdata.2015.66.

GALVÍNCIO, J. D.; MOURA, M. S. B. Aspectos climáticos da captação de água de chuva no estado de pernambuco. **Revista de Geografia**, v. Vol. 22, N, p. 96–113, 2005.

GANASRI, B. P. A Review on Hydrological Models ENGINEERING (ICWRCOE 2015) A Review on Hydrological Models. **Aquatic Procedia**, v. 4, p. 1001–1007, 2015. DOI: 10.1016/j.aqpro.2015.02.126.

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, n° October 2017, p. 150–157, 2018. DOI: 10.1016/j.atmosres.2018.05.016.

GAO, F.; ZHANG, Y.; REN, X.; YAO, Y.; HAO, Z.; CAI, W. Evaluation of CHIRPS and its application for drought monitoring over the Haihe River Basin, China. **Natural Hazards**, v. 92, n° 1, p. 155–172, 2018. DOI: 10.1007/s11069-018-3196-0.

GARNAUD, C.; BÉLAIR, S.; CARRERA, M. L.; MCNAIRN, H.; PACHECO, A. Field scale variability of soil moisture and L-band brightness temperature from land surface modeling. **Journal of Hydrometeorology**, v. 18, n° 3, p. 573–589, 2016. DOI: 10.1175/JHM-D-16-0131.1.

GHEYI, H. R.; SILVA PAZ, V. P.; MEDEIROS, S. de S.; GALVÃO, C. de O. Recursos hídricos em regiões semiáridas: estudos e aplicações. Cruz das Almas, BA - Universidade Federal do Recôncavo Baiano: [s.n.], 2012. 258 p.

GITHUNGO, W.; OTENGI, S.; WAKHUNGU, J.; MASIBAYI, E. Infilling Monthly Rain Gauge Data Gaps with Satellite Estimates for ASAL of Kenya. **Hydrology**, v. 3, n° 4, p. 40, 2016. DOI: 10.3390/hydrology3040040.

GIULIANI, G.; RAHMAN, K.; RAY, N.; LEHMANN, A. OWS4SWAT: Publishing and Sharing SWAT Outputs with OGC standards. **International Journal of Advanced Computer Science and Applications**, v. 3, n° 3, p. 90–98, 2013. DOI: 10.14569/specialissue.2013.030311.

GRAYSON, R. B.; WESTERN, A. W.; WALKER, J. P.; KANDEL, D. G.; COSTELLOE, J. F.; WILSON, D. J. Controls on patterns of soil moisture in arid and semi-arid systems. **Dryland Ecohydrology**, p. 109–127, 2006. DOI: 10.1007/1-4020-4260-4_7.

GUANZIROLI, C. E.; SABBATO, A. Di; VIDAL, M. F. Evolução da agricultura familiar nordestina: uma análise Comparativa entre os dois censos agropecuários. **Revista de economia do Nordeste**, v. 45, n° Suplemento Especial, p. 93–105, 2014.

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. DE. Projeções de mudanças climáticas sobre o nordeste Brasileiro dos

modelos do CMIP5 e do CORDEX. **Revista Brasileira de Meteorologia**, v. 31, nº 3, p. 337–365, 2016. DOI: 10.1590/0102-778631320150150.

GUO, H.; BAO, A.; LIU, T.; CHEN, S.; NDAYISABA, F. Evaluation of PERSIANN-CDR for meteorological drought monitoring over China. **Remote Sensing**, v. 8, nº 5, p. 1–17, 2016. DOI: 10.3390/rs8050379.

GUO, H.; BAO, A.; LIU, T.; NDAYISABA, F.; HE, D.; KURBAN, A.; MAEYER, P. DE. Meteorological drought analysis in the Lower Mekong Basin using satellite-based long-term CHIRPS product. **Sustainability (Switzerland)**, v. 9, nº 6, 2017. DOI: 10.3390/su9060901.

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, nº 4, p. 1–17, 2018. DOI: 10.3390/rs10040569.

HENGL, T. et al. SoilGrids250m: Global gridded soil information based on machine learning. **PLoS ONE**, v. 12, nº 2, p. 1–40, 2017. DOI: 10.1371/journal.pone.0169748.

HOUGHTON, J. T.; DING, Y.; GRIGGS, D. J.; NOGUER, M.; LINDEN, P. J. VAN DER; DAI, X.; MASKELL, K.; JOHNSON, C. A. Climate Change 2001: The Scientific Basis. Contribution of Working Group I to the Third Assessment Report of the Intergovernmental Panel on Climate Change. **IPCC, 2001**. New York: Cambridge University Press, 2001. p. 1–892.

HUANG, X.; WANG, D.; LIU, Y.; FENG, Z.; WANG, D. Evaluation of extreme precipitation based on satellite retrievals over China. **Frontiers of Earth Science**, v. 12, nº 4, p. 846–861, 2018. DOI: 10.1007/s11707-017-0643-2.

HULLEY, G. C.; HUGHES, C. G.; HOOK, S. J.,. Quantifying uncertainties in land surface temperature and emissivity retrievals from ASTER and MODIS thermal infrared data. **Journal of Geophysical Research**, 10, 2012. DOI: 10.1029/2012JD018506.

JACKSON, T. J.; BINDLISH, R.; COSH, M. H.; ZHAO, T.; STARKS, P. J.; BOSCH, D. D.; SEYFRIED, M.; MORAN, M. S.; GOODRICH, D. C.; KERR, Y. H.; LEROUX, D. Validation of Soil Moisture and Ocean Salinity (SMOS) Soil

Moisture Over Watershed Networks in the U.S. **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n° July, p. 1530–1543, 2015. DOI: 10.1109/TGRS.2011.2168533.

JESUS, A. DE; BREÑA-NARANJO, J. A.; PEDROZO-ACUÑA, A.; YAMANAKA, V. H. A. The use of TRMM 3B42 product for drought monitoring in Mexico. **Water**, v. 8, n° 8, 2016. DOI: 10.3390/w8080325.

JEYASEELAN, A. T. Droughts & Floods Assessment and Monitoring using Remote Sensing and GIS. In: SIVAKUMAR, M. V. K. et al. (Orgs.). **Satellite Remote Sensing and GIS Applications in**. 1182 ed. [s.l.]: World Meteorological Organisation, 2004. 423p. p.

JOHN, V. O.; TABATA, T.; RÜTHRICH, F.; ROEBELING, R.; HEWISON, T.; STÖCKLI, R.; SCHULZ, J. On the Methods for Recalibrating Geostationary Longwave Channels Using Polar Orbiting Infrared Sounders. **Remote Sensing**, v. 11, n° 10, p. 1171, 2019. DOI: 10.3390/rs11101171.

JOSHI, N.; BAUMANN, M.; EHAMMER, A.; FENSHOLT, R.; GROGAN, K.; HOSTERT, P.; JEPSEN, M. R.; KUEMMERLE, T.; MEYFROIDT, P.; MITCHARD, E. T. A.; REICHE, J.; RYAN, C. M.; WASKE, B. 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. DOI: 10.3390/rs8010070.

KANG, C. S.; KANNIAH, K. D.; KERR, Y. H.; CRACKNELL, A. P. Analysis of in-situ soil moisture data and validation of SMOS soil moisture products at selected agricultural sites over a tropical region. **International Journal of Remote Sensing**, v. 37, n° 16, p. 3636–3654, 2016. DOI: 10.1080/01431161.2016.1201229.

KANG, J.; TAN, J.; JIN, R.; LI, X.; ZHANG, Y. Reconstruction of MODIS land surface temperature products based on multi-temporal information. **Remote Sensing**, v. 10, n° 7, 2018. DOI: 10.3390/rs10071112.

KERR, Y. H. et al. The SMOS Mission: New Tool for Monitoring Key Elements of the Global Water Cycle. **Proceedings of the IEEE**, v. 98, n° 5, p. 666–687, 2010. DOI: 10.1109/JPROC.2010.2043032.

KHAN, A. S.; CRUZ, J. A. N.; SILVA, L. M. R.; LIMA, PATRICIA, V. P. sales.

Efeito da Seca sobre a Produção, a Renda e o Emprego Agrícola na Microrregião Geográfica de Brejo Santo e no Estado do Ceará. **Revista Econômica do Nordeste**, v. 36, nº 2, p. 242–262, 2005.

KLEIDON, A.; RENNER, M. A simple explanation for the sensitivity of the hydrologic cycle to surface temperature and solar radiation and its implications for global climate change. **Earth System Dynamics**, v. 4, nº 2, p. 455–465, 2013. DOI: 10.5194/esd-4-455-2013.

KOCH, M.; MISSIMER, T. M. Water Resources Assessment and Management in Drylands. **Water**, v. 8, nº 239, p. 1–5, 2016. DOI: 10.3390/w8060239.

KOSTER, R. D.; BROCCA, L.; CROW, W. T.; BURGIN, M. S.; LANNOY, G. J. M. DE. Precipitation estimation using L-band and C-band soil moisture retrievals. **Water Resources Research**, v. 52, nº 9, p. 7213–7225, 2016. DOI: 10.1002/2016WR019024.

KUMARASAMY, K.; BELMONT, P. Calibration parameter selection and watershed hydrology model evaluation in time and frequency domains. **Water**, v. 10, nº 710, 2018. DOI: 10.3390/w10060710.

LEKULA, M.; LUBCZYNSKI, M. W. Use of remote sensing and long-term in-situ time-series data in an integrated hydrological model of the Central Kalahari Basin, Southern Africa. **Hydrogeology Journal**, v. 27, p. 1541–1562, 2019.

LEROUX, D. J.; KERR, Y. H.; BITAR, A. A.; BINDLISH, R.; MEMBER, S.; JACKSON, T. J.; BERTHELOT, B.; PORTET, G. Comparison Between SMOS , VUA , ASCAT , and ECMWF Soil Moisture Products Over Four Watersheds in U.S. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, nº 3, p. 1562–1571, 2014.

LI, X.; ZHANG, Q.; YE, X. Dry/wet conditions monitoring based on TRMM rainfall data and its reliability validation over poyang lake basin, China. **Water (Switzerland)**, v. 5, nº 4, p. 1848–1864, 2013. DOI: 10.3390/w5041848.

LI, Z.; SHAO, Q.; XU, Z.; CAI, X. Analysis of parameter uncertainty in semi-distributed hydrological models using bootstrap method: A case study of SWAT model applied to Yingluoxia watershed in northwest China. **Journal of Hydrology**, v. 385, nº 1–4, p. 76–83, 2010. DOI: 10.1016/j.jhydrol.2010.01.025.

LIANG, Shunlin. Narrowband to broadband conversions of land surface albedo: I. Algorithms. **Remote Sensing of Environment**, v. 76, p. 213–238, 2000. DOI: 10.1016/S0034-4257(02)00068-8.

LIANG, Shuqi; 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. DOI: 10.1155/2018/1362708.

LIMA, G. S. A.; FERREIRA, N. C.; FERREIRA, M. E. Modelagem da Perda Superficial de Solo para Cenários de Agricultura e Pastagem na Região Metropolitana de Goiânia. **Revista Brasileira de Cartografia**, v. 70, nº 4, p. 1510–1536, 2018. DOI: 10.14393/rbcv70n4-46513.

LITTLE, A. D.; NEIL, D. O.; SACHSE, G. W.; FISHMAN, J.; KRUEGER, A. J. Remote sensing from Geostationary orbit: GEO TROPSAT, a new concept for atmospheric remote sensing. **Sensors, Systems, and Next-Generation Satellites**, v. 3221, nº July 2013, p. 480–488, 2004. DOI: 10.1117/12.298116.

LIU, S. S.; ZHANG, Q.; LI, X. C.; SONG, W. J.; YANG, J. N.; LIU, X. J. Temporal and Spatial Variations of Vegetation Cover in Xinjiang from 2002 to 2015 and Their Response to Climate. **IOP Conference Series: Earth and Environmental Science**, v. 74, nº 1, p. 2–7, 2017. DOI: 10.1088/1755-1315/74/1/012021.

LIU, X.; LIU, F. M.; WANG, X. X.; LI, X. D.; FAN, Y. Y.; CAI, S. X.; AO, T. Q. Combining rainfall data from rain gauges and TRMM in hydrological modelling of Laotian data-sparse basins. **Applied Water Science**, v. 7, nº 3, p. 1487–1496, 2017. DOI: 10.1007/s13201-015-0330-y.

LIU, Z. Comparison of Integrated Multisatellite Retrievals for GPM (IMERG) and TRMM Multisatellite Precipitation Analysis (TMPA) Monthly Precipitation Products: Initial Results. **Journal of Hydrometeorology**, v. 17, nº 3, p. 777–790, 2016. DOI: 10.1175/JHM-D-15-0068.1.

LOPES, H. L.; ACCIOLY, L. J. O.; SILVA, F. H. B. B.; SOBRAL, M. C. M.; FILHO, J. C. D. A.; CANDEIAS, A. L. B. Espacialização da umidade do solo por meio da temperatura da superfície e índice de vegetação. **Revista brasileira engenharia agrícola ambiental**, nº 87, p. 973–980, 2011. DOI: 10.1590/S1415-

43662011000900014.

LOPES, I.; MONTENEGRO, A. A. A.; LIMA, J. L. M. P. Performance of Conservation Techniques for Semiarid Environments: Field Observations with Caatinga, Mulch, and Cactus Forage Palma. **Water**, v. 11, n° 792, p. 1–15, 2019.

LÓPEZ, P. L.; SUTANUDJAJA, E. H.; SCHELLEKENS, J.; STERK, G.; BIERKENS, M. F. P. Calibration of a large-scale hydrological model using satellite-based soil moisture and evapotranspiration products. **Hydrology and Earth System Sciences**, v. 21, p. 3125–3144, 2017.

LOUZADA, F. L. R. de 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. DOI: 10.1590/1809-4430-eng.agric.v38n3p376-386/2018.

LU, L.; ZHANG, T.; WANG, T.; ZHOU, X. Evaluation of collection-6 MODIS land surface temperature product using multi-year ground measurements in an arid area of northwest China. **Remote Sensing**, v. 10, n° 11, 2018. DOI: 10.3390/rs10111852.

LU, Xinyu; 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. DOI: 10.1007/s12665-018-7378-6.

LU, Xuefei; 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 e. **Biochemical Pharmacology**, v. 8, n° December, p. 59–68, 2016. DOI: 10.1016/j.ejrh.2016.07.003.

MA, C.; LI, X.; WEI, L.; WANG, W. Multi-scale validation of SMAP soil moisture products over cold and arid regions in Northwestern China using distributed ground observation data. **Remote Sensing**, v. 9, n° 4, 2017. DOI: 10.3390/rs9040327.

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, nº 2, p. 327–340, 2017. DOI: 10.1590/S1413-41522016145177.

MACIEL, S. A.; BARCELOS, B. F.; OLIVEIRA, L. A. De. Análise da influência da altitude na temperatura e na precipitação da Mesorregião Norte de Minas – Minas Gerais. **Revista Geonorte**, v. 1, nº Especial 2, p. 250–261, 2012.

MAGALHÃES, A. G.; MONTENEGRO, A. A. D. A.; ANDRADE, C. W. L.; MONTENEGRO, S. M. G. L.; FONTES JÚNIOR, R. V. de P. Hydrological modeling of an experimental basin in the semiarid region of the Brazilian State of Pernambuco. **Ambiente e Água**, v. 13, nº 6, p. 1–19, 2018. DOI: 10.4136/1980-993X.

MANCINI, M. La modellazione distribuita della risposta idrologica: Effetti della variabilità spaziale e della scala di rappresentazione del fenomeno dell'assorbimento. Ph.D. dissertation, **Politecnico di Milano**, 127 pp, 1990.

MANTAS, V. M.; LIU, Z.; CARO, C.; PEREIRA, A. J. S. C. Validation of TRMM multi-satellite precipitation analysis (TMPA) products in the Peruvian Andes. **Atmospheric Research**, v. 163, p. 132–145, 2015. DOI: 10.1016/j.atmosres.2014.11.012.

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

MARENGO, Jose A. Vulnerabilidade, impactos e adaptação à mudança do clima no semi-árido do Brasil. **Parcerias Estratégicas**, v. 13, nº 27, p. 149–176, 2009.

MARENGO, Jose A.; ALVES, L. M.; SOARES, W. R.; RODRIGUEZ, D. A.; CAMARGO, H.; RIVEROS, M. P.; PABLÓ, A. D. Two contrasting severe seasonal extremes in tropical South America in 2012: Flood in Amazonia and drought in Northeast Brazil. **Journal of Climate**, v. 26, nº 22, p. 9137–9154, 2013. DOI: 10.1175/JCLI-D-12-00642.1.

MARENGO, JOSÉ A.; ALVES, L. M.; ALVALA, R. C. .; CUNHA, A. P.; 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**,

v. 90, nº 2, p. 1973–1985, 2018b. DOI: 10.1590/0001-3765201720170206.

MARENGO, Jose A.; TORRES, R. R.; ALVES, L. M. Drought in Northeast Brazil—past, present, and future. **Theoretical and Applied Climatology**, v. 129, nº 3–4, p. 1189–1200, 2017. DOI: 10.1007/s00704-016-1840-8.

MARONEZE, M. M.; ZEPKA, L. Q.; VIEIRA, J. G.; QUEIROZ, M. I.; JACOB-LOPES, E. A tecnologia de remoção de fósforo: Gerenciamento do elemento em resíduos industriais. **Revista Ambiente e Agua**, v. 9, nº 3, p. 445–458, 2014. DOI: 10.4136/1980-993X.

MARTÍNEZ-FERNÁNDEZ, J.; GONZÁLEZ-ZAMORA, A.; SÁNCHEZ, N.; GUMUZZIO, A. A soil water based index as a suitable agricultural drought indicator. **Journal of Hydrology**, v. 522, p. 265–273, 2015. DOI: 10.1016/j.jhydrol.2014.12.051.

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 Deficit Index. **Remote Sensing of Environment**, v. 177, p. 277–286, 2016. DOI: 10.1016/j.rse.2016.02.064.

MARTINS, E.; MAGALHÃES, A. A seca de 2012-2015 no Nordeste e seus impactos. **Parcerias Estratégicas**, v. 20, nº 41, p. 107–128, 2015.

MCKEE, T. B.; DOESKEN, N. J.; KLEIST, J. The relationship of drought frequency and duration to time scales. **AMS 8th Conference on Applied Climatology**, nº January, p. 179–184, 1993. DOI: citeulike-article-id:10490403.

MERCURE, J. F. et al. System complexity and policy integration challenges: The Brazilian Energy- Water-Food Nexus. **Renewable and Sustainable Energy Reviews**, v. 105, nº January, p. 230–243, 2019. DOI: 10.1016/j.rser.2019.01.045.

MERONI, M.; REMBOLD, F.; FASBENDER, D.; VRIELING, A. Evaluation of the Standardized Precipitation Index as an early predictor of seasonal vegetation production anomalies in the Sahel. **Remote Sensing Letters**, v. 8, nº 4, p. 301–310, 2017. DOI: 10.1080/2150704X.2016.1264020.

MIRANDA, S. C.; MATA, C. R.; FONSECA, K. S.; DE-CERVALHO, P. S.

Apontamentos sobre mudanças climáticas na agricultura brasileira. **Enciclopédia Bioesfera**, v. 15, nº 27, p. 95–106, 2018. DOI: 10.18677/EnciBio.

MISHRA, A.; VU, T.; VALIYA, A.; ENTEKHABI, D. Drought monitoring with soil moisture active passive (SMAP) measurements. v. 552, nº January 2015, p. 620–632, 2017. DOI: 10.1016/j.jhydrol.2017.07.033.

MOHANTY, B. P.; COSH, M. H.; LAKSHMI, V.; MONTZKA, C. Soil Moisture Remote Sensing: State-of-the-Science. **Vadose Zone Journal**, v. 16, nº 1, p. 1–9, 2017. DOI: 10.2136/vzj2016.10.0105.

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

MONTENEGRO, A.; RAGAB, R. Hydrological response of a Brazilian semi-arid catchment to different land use and climate change scenarios: A modelling study. **Hydrological Processes**, v. 24, nº 19, p. 2705–2723, 2010. DOI: 10.1002/hyp.7825.

MORAN, M. S.; DOORN, B.; ESCOBAR, V.; BROWN, M. E. Connecting NASA Science and Engineering with Earth Science Applications. **Journal of Hydrometeorology**, v. 16, nº 2, p. 473–483, 2015. DOI: 10.1175/JHM-D-14-0093.1.

MUHAMMAD, S.; THAPA, A. A combined Terra/Aqua MODIS snow-cover and RGI6.0 glacier product (MOYDGL06*) for the High Mountain Asia between 2002 and 2018. **Earth System Science Data Discussions**, nº June, p. 1–19, 2019. DOI: 10.5194/essd-2019-78.

NAUMANN, G.; DUTRA, E.; BARBOSA, P.; PAPPENBERGER, F.; WETTERHALL, F.; VOGT, J. V. Comparison of drought indicators derived from multiple data sets over Africa. **Hydrology and Earth System Sciences**, v. 18, nº 5, p. 1625–1640, 2014. DOI: 10.5194/hess-18-1625-2014.

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**, nº April, p. 1–34, 2018. DOI: 10.5194/hess-2018-177.

NICLOS, R.; RIVAS, R.; GARCIA-SANTOS, V.; DONA, C.; VALOR, E.; HOLZMAN, M.; BAYALA, M.; CARMONA, F.; OCAMPO, D.; SOLDANO, A.; THIBEAULT, M.; CASELLES, V.; SANCHEZ, J. 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. DOI: 10.1109/TGRS.2015.2460332.

ODOULAMI, R. C.; AKINSANOLA, A. A. Recent assessment of West African summer monsoon daily rainfall trends. **Weather**, v. 73, n° 9, p. 283–287, 2018. DOI: 10.1002/wea.2965.

OLIVEIRA, F. M. De; LIRA, V. M. De; DANTAS, R. T.; SOUZA, W. M. De. Variabilidade temporal da precipitação em municípios localizados em diferentes sub-regiões do estado de pernambuco. **Caminhos de Geografia**, v. 6, n° 19, p. 175–184, 2006.

OLIVEIRA, L. B. De. Uso e manejo da água na região semiárida do Nordeste do Brasil. **Anais da Academia Pernambucana de Ciência Agrônômica**, v. 11/12, p. 50–64, 2015.

OLIVEIRA, L. M. M. De; MONTENEGRO, S. M. G. L.; SILVA, B. B. Da; ANTONINO, A. C. D.; MOURA, A. E. S. S. De. Evapotranspiração real em bacia hidrográfica do Nordeste brasileiro por meio do SEBAL e produtos MODIS. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n° 10, p. 1039–1046, 2014. DOI: 10.1590/1807-1929/agriambi.v18n10p1039-1046.

OLIVEIRA, P. T. S.; NEARING, M. A.; MORAN, M. S.; GOODRICH, D. C.; WENDLAND, E.; GUPTA, H. V. Trends in water balance components across the Brazilian Cerrado. **Water Resources Research**, p. 7100–7114, 2014. DOI: 10.1002/2013WR015202.Received.

ONGOMA, V.; CHENA, H.; GAOA, C. Projected changes in mean rainfall and temperature over east Africa based on CMIP5 models. **International Journal of Climatology**, v. 38, n° 3, p. 1375–1392, 2018. DOI: 10.1002/joc.5252.

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. DOI: 10.3390/rs9111168.

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, nº December, p. 55–66, 2018. DOI: 10.5194/piahs-380-55-2018.

PAREDES-TREJO, F.; BARBOSA, H. Evaluation of the SMOS-derived soil water deficit index as agricultural drought index in Northeast of Brazil. **Water**, v. 9, nº 6, 2017. DOI: 10.3390/w9060377.

PASSOS, J. S. A. Variabilidade espaço-temporal da precipitação do Alto São Francisco (SUB-40) utilizando dados do sensor PR/TRMM. 93 p. - Universidade Federal da Paraíba, 2015.

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, nº 11, p. 15729–15747, 2015. DOI: 10.3390/rs71115729.

PINTO, C. E. T.; MENEZES, P. H. B. J.; MARTINEZ, J.-M.; ROIG, H. L.; VILLAR, R. A. E. Uso de imagens MODIS no monitoramento do fluxo de sedimentos no reservatório de Três Marias. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, nº 5, p. 507–516, 2014. DOI: 10.1590/s1415-43662014000500007.

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, nº 9, p. 993–998, 2012. DOI: 10.1590/s1415-43662012000900010.

PRASETIA, R.; AS-SYAKUR, A. R.; OSAWA, T. Validation of TRMM Precipitation Radar satellite data over Indonesian region. **Theoretical and Applied Climatology**, v. 112, nº 3–4, p. 575–587, 2013. DOI: 10.1007/s00704-012-0756-1.

RAHMANI, A.; GOLIAN, S.; BROCCA, L. Multiyear monitoring of soil moisture over Iran through satellite and reanalysis soil moisture products. **International Journal of Applied Earth Observations and Geoinformation**, v. 48, p. 85–

95, 2016. DOI: 10.1016/j.jag.2015.06.009.

RAMESH, D.; VISHNU, B. V. Analysis of Crop Yield Prediction using Data Mining Techniques. **International Journal of Research in Engineering and Technology**, v. 4, n° 1, p. 470–473, 2015.

RAVAZZANI, G.; CORBARI, C.; CEPPI, A.; FEKI, M.; MANCINI, M.; FERRARI, F.; GIANFREDA, R.; COLOMBO, R.; GINOCCHI, M.; MEUCCI, S.; VECCHI, D. DE; DELL'ACQUA, F.; OBER, G. From (cyber)space to ground: New technologies for smart farming. **Hydrology Research**, v. 48, n° 3, p. 656–672, 2017. DOI: 10.2166/nh.2016.112.

REBEL, K. T.; DE JEU, R. A. M.; CIAIS, P.; VIOVY, N.; PIAO, S. L.; KIELY, G.; DOLMAN, A. J. A global analysis of soil moisture derived from satellite observations and a land surface model. **Hydrol. Earth Syst. Sci.**, v. 16, n° 2005, p. 833–847, 2012. DOI: 10.5194/hess-16-833-2012.

REBOITA, M. S.; KRUSCHE, N. Normais Climatológicas Provisórias de 1991 a 2010 para Rio Grande , RS Provisional Climatological Normals from 1991 to 2010 for Rio Grande RS. **Revista Brasileira de Meteorologia**, v. 33, p. 165–179, 2018.

REBOUÇAS, A. D. C. Água na região Nordeste: desperdício e escassez. **Estudos Avançados**, v. 11, n° 29, p. 127–154, 1997. DOI: 10.1590/S0103-40141997000100007.

REIS, J. B. C.; RENNÓ, C. D.; LOPES, E. S. S. Validation of satellite rainfall products over a mountainous watershed in a humid subtropical climate region of Brazil. **Remote Sensing**, v. 9, n° 12, p. 1–18, 2017. DOI: 10.3390/rs9121240.

REN, P.; LI, J.; FENG, P.; GUO, Y.; MA, Q. Evaluation of multiple satellite precipitation products and their use in hydrological modelling over the Luanhe River Basin, China. **Water (Switzerland)**, v. 10, n° 6, 2018. DOI: 10.3390/w10060677.

RODRIGO, S.; BRAGA, C. C.; SANSIGOLO, C. A.; PAULA, A. Determinação de Regiões Homogêneas do Índice de Precipitação Normalizada (SPI) na Amazônia Oriental Determination of Homogeneous Precipitation Regions of the Standardized Precipitation Index (SPI) in the Eastern Amazon. p. 111–122, 2017.

ROSSATO, L.; MARENGO, J. A.; ANGELIS, C. F. De; PIRES, L. B. M.; MENDIONDO, E. M. Impact of soil moisture over Palmer Drought Severity Index and its future projections in Brazil. **Brazilian Journal of Water Resources**, v. 22, 2017. DOI: 10.1590/2318-0331.0117160045.

ROZANTE, J. R.; MOREIRA, D. S.; FERNANDES, A. A.; NETO, S. V. B. Desempenho dos produtos de estimativa de precipitação do TRMM sobre a América do Sul. In: **Anais do XVI Congresso Brasileiro de Meteorologia**. Belém, Pará: [s.n.], 2010.

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, nº 287, p. 1–25, 2016. DOI: 10.3390/rs8040287.

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, nº 170, p. 1–17, 2019. DOI: 10.3390/w11010170.

SANTOS, S. M. da S.; ASSIS, J. M. de O.; MEIRA, W. de S. Trends of climate change on the Una River Basin, Pernambuco – Brazil. **Revista Brasileira de Geografia Física**, v. 7, nº 2, p. 243–257, 2014.

SANTOS, S. R. Q. Dos; SANSIGOLO, C. A.; NEVES, T. T. de A. T.; CAMPOS, T. L. de O. B.; SANTOS, A. P. P. Dos. Frequências dos eventos extremos de seca e chuva na Amazônia utilizando diferentes bancos de dados de precipitação. **Revista Brasileira de Geografia Física**, v. 10, nº 2, p. 468–478, 2017. DOI: 10.5935/1984-2295.20140015.

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, nº 4, p. 1356–1370, 2013.

SAXTON, K. E.; RAWLS, W. J. Soil water characteristic estimates by texture and organic matter for hydrologic solutions. **Soil Science Society of America Journal**, v. 70, nº 5, p. 1569–1578, 2006. DOI: 10.2136/sssaj2005.0117.

SAZIB, N.; MLADENOVA, I.; BOLTEN, J. Leveraging the Google Earth Engine for drought assessment using global soil moisture data. **Remote Sensing**, v.

10, nº 8, 2018. DOI: 10.3390/rs10081265.

SCAINI, A.; SÁNCHEZ, N.; VICENTE-SERRANO, S. M.; MARTÍNEZ-FERNÁNDEZ, J. SMOS-derived soil moisture anomalies and drought indices: A comparative analysis using in situ measurements. **Hydrological Processes**, v. 29, nº 3, p. 373–383, 2015. DOI: 10.1002/hyp.10150.

SENEVIRATNE, S. I.; CORTI, T.; DAVIN, E. L.; HIRSCHI, M.; JAEGER, E. B.; LEHNER, I.; ORLOWSKY, B.; TEULING, A. J. Investigating soil moisture-climate interactions in a changing climate: A review. **Earth-Science Reviews**, v. 99, nº 3–4, p. 125–161, 2010. DOI: 10.1016/j.earscirev.2010.02.004.

SHEFFIELD, J.; WOOD, E. F.; CHANEY, N.; GUAN, K.; SADRI, S.; YUAN, X.; OLANG, L.; AMANI, A.; ALI, A.; DEMUTH, S.; OGALLO, L. A drought monitoring and forecasting system for sub-sahara african water resources and food security. **Bulletin of the American Meteorological Society**, v. 95, nº 6, p. 861–882, 2014. DOI: 10.1175/BAMS-D-12-00124.1.

SHRESTHA, N. K.; QAMER, F. M.; PEDREROS, D.; MURTHY, M. S. R.; WAHID, S. M.; SHRESTHA, M. Evaluating the accuracy of Climate Hazard Group (CHG) satellite rainfall estimates for precipitation based drought monitoring in Koshi basin, Nepal. **Journal of Hydrology: Regional Studies**, v. 13, nº September, p. 138–151, 2017. DOI: 10.1016/j.ejrh.2017.08.004.

SILVA, A. O. Da; QUELUZ, J. T. G.; KLAR, A. E. Spatial distribution of climatic water balance in different rainfall regimes in the State of Pernambuco. **Revista Brasileira de Tecnologia Aplicada nas Ciências Agrárias**, v. 6, nº 1, p. 7–19, 2013. DOI: 10.5935/paet.v6.n1.01.

SILVA, B. B. DA; FERREIRA, M. A. F.; SILVA, V. P. R. DA; FERREIRA, R. C. Desempenho de modelo climático aplicado à precipitação pluvial do Estado de Pernambuco. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, nº 4, p. 387–395, 2010.

SILVA LELIS, L. C.; DUARTE BOSQUILIA, R. W.; DUARTE, S. N. Assessment of precipitation data generated by GPM and TRMM satellites. **Revista Brasileira de Meteorologia**, v. 33, nº 1, p. 153–163, 2018. DOI: 10.1590/0102-7786331004.

SILVA, M. T.; SILVA, V. de P. R. Da; AZEVEDO, P. V. De. O cultivo do algodão

herbáceo no sistema de sequeiro no Nordeste do Brasil, no cenário de mudanças climática. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, nº 1, p. 80–91, 2013. DOI: 10.1590/s1415-43662012000100011.

SILVA, W. P.; ALMEIDA, C. D. G. C. De; ROLIM, M. M.; SILVA, Ê. F. D. F.; PEDROSA, E. M. R.; SILVA, V. G. F. Monitoramento da salinidade de águas subterrâneas em várzea cultivada com cana-de-açúcar fertirrigada com vinhaça. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, nº 4, p. 394–401, 2014.

SILVEIRA, C. S.; SOUZA FILHO, F. de A.; COSTA, A. A.; CABRAL, S. L. Avaliação de desempenho dos modelos do CMIP5 quanto à representação dos padrões de variação da precipitação no século XX sobre a região Nordeste do Brasil, Amazônia e bacia do prata e análise das projeções para o cenário RCP 8.5. **Revista Brasileira de Meteorologia**, v. 28, nº 3, p. 317–330, 2013. DOI: 10.1590/S0102-77862013000300008.

SOARES, A.; PAZ, A.; PICCILLI, D. Avaliação das estimativas de chuva do satélite TRMM no Estado da Paraíba. **Revista Brasileira de Recursos Hídricos**, v. 21, nº 2, p. 288–299, 2016. DOI: 10.21168/rbrh.v21n2.p288-299.

SOARES CRUZ, M. A.; ROCHA, L. T.; ARAGÃO, R. DE; ALMEIDA, A. Q. DE. Applicability of TRMM Precipitation for Hydrologic Modeling in a Basin in the Northeast Brazilian Agreste. **Revista Brasileira de Meteorologia**, v. 33, nº 1, p. 57–64, 2018. DOI: 10.1590/0102-7786331013.

SOFUE, Y.; HOSHINO, B.; DEMURA, Y.; KAI, K.; BABA, K.; NDUATI, E.; KONDOH, A.; STERNBERG, T. Satellite Monitoring of Vegetation Response to Precipitation and Dust Storm Outbreaks in Gobi Desert Regions. **Land**, v. 7, nº 1, p. 19, 2018. DOI: 10.3390/land7010019.

SOUZA, A.; NETO, A.; ROSSATO, L.; ALVALÁ, R.; SOUZA, L. Use of SMOS L3 Soil Moisture Data: Validation and Drought Assessment for Pernambuco State, Northeast Brazil. **Remote Sensing**, v. 10, nº 8, p. 1314, 2018. DOI: 10.3390/rs10081314.

SOUZA, F. V.; PAZ, A. R. Representação dos processos hidrológicos em bacia hidrográfica do semiárido paraibano com modelagem hidrológica distribuída. **Revista Brasileira de Recursos Hídricos**, v. 21, nº 3, p. 556–569, 2016. DOI:

10.1590/2318-0331.011616009.

TAN, M. L.; IBRAHIM, A. L.; DUAN, Z.; CRACKNELL, A. P.; CHAPLOT, V. Evaluation of Six High-Resolution Satellite and Ground-Based Precipitation Products over Malaysia. **Remote Sensing**, v. 7, p. 1504–1528, 2015. DOI: 10.3390/rs70201504.

TAN, M. L.; TAN, K. C.; CHUA, V. P.; CHAN, N. W. Evaluation of TRMM product for monitoring drought in the Kelantan River Basin, Malaysia. **Water**, v. 9, n° 1, 2017. DOI: 10.3390/w9010057.

TAN, M. L.; DUAN, Z. Assessment of GPM and TRMM precipitation products over Singapore. **Remote Sensing**, v. 9, n° 7, p. 1–16, 2017. DOI: 10.3390/rs9070720.

TANG, G.; ZENG, Z.; LONG, D.; GUO, X.; YONG, B.; ZHANG, W.; HONG, Y. Statistical and Hydrological Comparisons between TRMM and GPM Level-3 Products over a Midlatitude Basin: Is Day-1 IMERG a Good Successor for TMPA 3B42V7? **Journal of Hydrometeorology**, v. 17, n° 1, p. 121–137, 2015. DOI: 10.1175/jhm-d-15-0059.1.

TANGDAMRONGSUB, N.; STEELE-DUNNE, S. C.; GUNTER, B. C.; DITMAR, P. G.; SUTANUDAJA, E. H.; SUN, Y.; XIA, T.; WANG, Z. Improving estimates of water resources in a semi-arid region by assimilating GRACE data into the PCR-GLOBWB hydrological model. **Hydrology and Earth System Sciences**, v. 21, n° 4, p. 2053–2074, 2017. DOI: 10.5194/hess-21-2053-2017.

TAO, H.; FISCHER, T.; ZENG, Y.; FRAEDRICH, K. Evaluation of TRMM 3B43 precipitation data for drought monitoring in Jiangsu Province, China. **Water (Switzerland)**, v. 8, n° 6, p. 1–13, 2016. DOI: 10.3390/w8060221.

TAVARES, B. S.; CORRÊA, M. M.; SOUZA, R. V. C. C.; SCARIOTTO, M. C.; MENDES, I. S.; MEDEIROS, L. R. S. Water quality in Una River Basin – Pernambuco. **Geama - Scientific Journal of Environmental Sciences**, v. 4, n° 1, p. 26–32, 2018.

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. DOI: 10.1590/S0102-69922016.00030010.

TIMMERMANS, W. J.; JIMÉNEZ-MUÑOZ, J. C.; HIDALGO, V.; SOBRINO, J. A.; RICHTER, K.; D'URSO, G.; SATALINO, G.; MATTIA, F.; LATHAUWER, E. DE; PAUWELS, V. R. N. Estimation of the spatially distributed surface energy budget for AgriSAR 2006, Part I: Remote sensing model intercomparison. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 4, n° 2, p. 465–481, 2011. DOI: 10.1109/JSTARS.2010.2098019.

TRENBERTH, K. E.; DAI, A.; RASMUSSEN, R. M.; PARSONS, D. B. The changing character of precipitation. **American Meteorology Society**, v. 84, n° 1205–1217, 2003.

TUO, Y.; DUAN, Z.; DISSE, M.; CHIOGNA, G. Evaluation of precipitation input for SWAT modeling in Alpine catchment: A case study in the Adige river basin (Italy). **Science of the Total Environment**, v. 573, p. 66–82, 2016. DOI: 10.1016/j.scitotenv.2016.08.034.

TUTTLE, S. E.; SALVUCCI, G. D. A new approach for validating satellite estimates of soil moisture using large-scale precipitation: Comparing AMSR-E products. **Remote Sensing of Environment**, v. 142, p. 207–222, 2014. DOI: 10.1016/j.rse.2013.12.002.

UMAR, M.; MUNIR, S.; ALI, I.; QURESHI, S.; NOTARNICOLA, C.; RAHMAN, S.; WENG, Q. Soil Moisture Using Optical Remote Sensing and Ground Measurements. In: WENG, Q. (Org.). **Remote Sensing for Sustainability**. [s.l.]: CRC Press, 2016. p. 243–266.

USOWICZ, B.; MARCZEWSKI, W.; USOWICZ, J. B.; LUKOWSKI, M. I.; LIPIEC, J. Comparison of Surface Soil Moisture from SMOS Satellite and Ground Measurements. **International Agrophysics**, v. 28, n° 3, p. 359–369, 2014. DOI: 10.2478/intag-2014-0026.

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. DOI: 10.1016/j.rala.2016.06.002.

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.

WAGNER, W. et al. 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. DOI: 10.1127/0941-2948/2013/0399.

WAGNER, W. et al. Clarifications on the “comparison between SMOS, VUA, ASCAT, and ECMWF Soil Moisture Products over Four Watersheds in U.S.” **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n° 3, p. 1901–1906, 2014. DOI: 10.1109/TGRS.2013.2282172.

WAN, G.; YANG, M.; LIU, Z.; WANG, X.; LIANG, X. The precipitation variations in the Qinghai-Xizang (Tibetan) Plateau during 1961-2015. **Atmosphere**, v. 8, n° 5, 2017. DOI: 10.3390/atmos8050080.

Wan, Z.; Zhang, Y.; Zhang, Q. Quality assessment and validation of the MODIS global land surface temperature. **International Journal of Remote Sensing**, 25(1), 261-274, 2004. DOI: 10.1080/0143116031000116417.

WANG, Wei; 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.

WANG, Wenhui; LIANG, S.; MEYERS, T. Validating MODIS land surface temperature products using long-term nighttime ground measurements. **Remote Sensing of Environment**, v. 112, n° 3, p. 623–635, 2008. DOI: 10.1016/j.rse.2007.05.024.

WANG, X.; DING, Y.; ZHAO, C.; WANG, J. Validation of TRMM 3B42V7 rainfall product under complex topographic and climatic conditions over Hexi region in the Northwest Arid Region of China. **Water (Switzerland)**, v. 10, n° 8, 2018. DOI: 10.3390/w10081006.

WEHBE, Y.; GHEBREYESUS, D.; TEMIMI, M.; MILEWSKI, A.; AL, A. Assessment of the consistency among global precipitation products over the United Arab Emirates. **Journal of Hydrology: Regional Studies**, v. 12, n° May, p. 122–135, 2017. DOI: 10.1016/j.ejrh.2017.05.002.

WILKS, D. S. Statistical Methods in the Atmospheric Sciences. **International Geophysics Series Vol 100**, v. 59, n° January 2015, p. 627, 2006. DOI: 10.1198/jasa.2007.s163.

WU, Qiaofeng; LIU, S.; CAI, Y.; LI, X.; JIANG, Y. Improvement of hydrological model calibration by selecting multiple parameter ranges. **Hydrology and Earth System Sciences**, v. 21, p. 393–407, 2017. DOI: 10.5194/hess-21-393-2017.

WU, Qiusheng; 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. DOI: 10.1016/j.jag.2015.10.011.

XIE, P.; JOYCE, R.; WU, S.; YOO, S.-H.; YAROSH, Y.; SUN, F.; LIN, R. Reprocessed, Bias-Corrected CMORPH Global High-Resolution Precipitation Estimates from 1998. **Journal of Hydrometeorology**, v. 18, n° 6, p. 1617–1641, 2017. DOI: 10.1175/JHM-D-16-0168.1.

XIONG, L.; YANG, H.; ZENG, L.; XU, C. Y. Evaluating consistency between the remotely sensed soil moisture and the hydrological model-simulated soil moisture in the Qujiang catchment of China. **Water (Switzerland)**, v. 10, n° 3, 2018. DOI: 10.3390/w10030291.

XU, R.; TIAN, F.; YANG, L.; HU, H.; LU, H.; HOU, A. Ground validation of GPM IMERG and TRMM 3B42V7 rainfall products over southern Tibetan Plateau based on a high-density rain gauge network. **Journal of Geophysical Research: Atmospheres**, v. 122, n° 2, p. 910–924, 2017. DOI: 10.1002/2016JD025418.

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. DOI: 10.3390/rs10020301.

YANG, L.; WEI, W.; CHEN, L.; JIA, F.; MO, B. Spatial variations of shallow and deep soil moisture in the semi-arid Loess Plateau, China. **Hydrology and Earth System Sciences**, v. 16, n° 9, p. 3199–3217, 2012. DOI: 10.5194/hess-16-3199-2012.

YOUNIS, S. M. Z.; IQBAL, J. Estimation of soil moisture using multispectral and FTIR techniques. **Egyptian Journal of Remote Sensing and Space Science**,

v. 18, n° 2, p. 151–161, 2015. DOI: 10.1016/j.ejrs.2015.10.001.

YU, D.; XIE, P.; DONG, X.; HU, X.; LIU, J.; LI, Y.; PENG, T.; MA, H.; WANG, K.; XU, S. Improvement of the SWAT model for event-based flood forecasting on a sub-daily time scale. **Hydrology and Earth System Sciences**, v. 22, p. 1–24, 2017. DOI: 10.5194/hess-2017-180.

ZAD, S. N. M.; ZULKAFI, Z.; MUHARRAM, F. M. Satellite rainfall (TRMM 3B42-V7) performance assessment and adjustment over Pahang river basin, Malaysia. **Remote Sensing**, v. 10, n° 3, p. 1–24, 2018. DOI: 10.3390/rs10030388.

ZANZARINI, F. V.; PISSARRA, T. C. T.; BRANDAO, F. J. C.; TEIXEIRA, D. D. B. Spatial correlation of the vegetation index (NDVI) of a Landsat/ETM plus images with soil attributes. **Revista Brasileira De Engenharia Agrícola E Ambiental**, v. 17, n° 6, p. 608–614, 2013. DOI: 10.1590/S1415-43662013000600006.

ZERI, M.; ALVALÁ, R. C. S.; CARNEIRO, R.; CUNHA-ZERI, G.; COSTA, J. M.; SPATAFORA, L. R.; URBANO, D.; VALL-LLOSSERA, M.; MARENGO, J. Tools for communicating agricultural drought over the Brazilian Semiarid using the soil moisture index. **Water (Switzerland)**, v. 10, n° 10, 2018. DOI: 10.3390/w10101421.

ZETTAM, A.; TALEB, A.; SAUVAGE, S.; BOITHIAS, L.; BELAIDI, N.; SÁNCHEZ-PÉREZ, J. M. Modelling Hydrology and Sediment Transport in a Semi-Arid and Anthropized Catchment Using the SWAT Model : The Case of the Tafna River (Northwest Algeria). **Water**, v. 9, n° 216, p. 1–18, 2017. DOI: 10.3390/w9030216.

ZHANG, Dan; 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. DOI: 10.3390/rs11020151.

ZHANG, Dianjun; ZHOU, G. Estimation of Soil Moisture from Optical and Thermal Remote Sensing: A Review. **Sensors**, v. 16, n° 8, p. 1308, 2016. DOI: 10.3390/s16081308.

ZHANG, P.; SHAO, M. Temporal stability of surface soil moisture in a desert area of northwestern China. **Journal of Hydrology**, v. 505, p. 91–101, 2013.

DOI: 10.1016/j.jhydrol.2013.08.045.

ZHANG, Q.; SHI, P.; SINGH, V. P.; FAN, K.; HUANG, J. Spatial downscaling of TRMM-based precipitation data using vegetative response in Xinjiang, China. **International Journal of Climatology**, v. 37, n° 10, p. 3895–3909, 2017. DOI: 10.1002/joc.4964.

ZHANG, X; SRINIVASAN, R.; LIEW, M. Van. Multi-site calibration of the SWAT model for hydrologic modeling. **Transactions of the ASABE**, v. 51, n° 6, p. 2039–2049, 2008.

ZHANG, Xuefei; ZHANG, T.; ZHOU, P.; SHAO, Y.; GAO, S. Validation analysis of SMAP and AMSR2 soil moisture products over the United States using ground-based measurements. **Remote Sensing**, v. 9, n° 2, 2017. DOI: 10.3390/rs9020104.

ZHANG, Yonggen; 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, p. 9774–9790, 2018.

ZHANG, Yueyuan; 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. DOI: 10.3390/rs10010119.

ZHU, J.; WINTER, C. L.; WANG, Z. Nonlinear effects of locally heterogeneous hydraulic conductivity fields on regional stream-aquifer exchanges. **Hydrology and Earth System Sciences**, v. 19, n° 11, p. 4531–4545, 2015. DOI: 10.5194/hess-19-4531-2015.

ZHU, L.; SUOMALAINEN, J.; LIU, J.; HYYPPÄ, J.; KAARTINEN, H.; HAGGREN, H. A Review: Remote Sensing Sensors. In: RUSTAMOV, R. B. (Org.). **Multi-purposeful Application of Geospatial Data**. [s.l.]: IntechOpen, 2017. v. 12, p. 19–42. DOI: <http://dx.doi.org/10.5772/57353>.