



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

MARCELLA VASCONCELOS QUINTELLA JUCÁ

**ESTIMATIVA DA UMIDADE DO SOLO EM DIFERENTES PROFUNDIDADES A
PARTIR DO PRODUTO DO SATÉLITE SOIL MOISTURE OCEAN SALINITY
(SMOS) EM PERNAMBUCO UTILIZANDO UM FILTRO EXPONENCIAL**

Recife

2021

MARCELLA VASCONCELOS QUINTELLA JUCÁ

**ESTIMATIVA DA UMIDADE DO SOLO EM DIFERENTES PROFUNDIDADES A
PARTIR DO PRODUTO DO SATÉLITE SOIL MOISTURE OCEAN SALINITY
(SMOS) EM PERNAMBUCO UTILIZANDO UM FILTRO EXPONENCIAL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito para a obtenção do grau de Mestre em Engenharia Civil.
Área de Concentração: Tecnologia Ambiental e Recursos Hídricos.

Orientador: Prof. Dr. Alfredo Ribeiro Neto.

Recife

2021

Catálogo na fonte
Bibliotecária Maria Luiza de Moura Ferreira, CRB-4 / 1469

J91e

Jucá, Marcella Vasconcelos Quintella.

Estimativa da umidade do solo em diferentes profundidades a partir do produto do satélite SOIL MOISTURE OCEAN SALINITY (SMOS) em Pernambuco utilizando um filtro exponencial / Marcella Vasconcelos Quintella Jucá. - 2021.

81 folhas, il.; tab., abr. e sigl.

Orientador: Prof. Dr. Alfredo Ribeiro Neto.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Civil, 2021.

Inclui Referências.

1. Engenharia Civil. 2. Umidade do solo. 3. Filtro Exponencial. 4. SMOS.
I. Ribeiro Neto, Alfredo (Orientador). II. Título.

UFPE

624 CDD (22. ed.)

BCTG/2022-85

MARCELLA VASCONCELOS QUINTELLA JUCÁ

**ESTIMATIVA DA UMIDADE DO SOLO EM DIFERENTES PROFUNDIDADES A
PARTIR DO PRODUTO DO SATÉLITE SOIL MOISTURE OCEAN SALINITY
(SMOS) EM PERNAMBUCO UTILIZANDO UM FILTRO EXPONENCIAL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito para a obtenção do grau de Mestre em Engenharia Civil.
Área de Concentração: Tecnologia Ambiental e Recursos Hídricos.

Aprovada em 17/08/2021

BANCA EXAMINADORA

Prof^o. Dr. Alfredo Ribeiro Neto (Orientador)
Universidade Federal de Pernambuco

Prof. Dr. Daniel Andrés Rodríguez (Examinador Externo)
Universidade Federal do Rio de Janeiro

Prof.^a Dr.^a Alzira Gabrielle Soares Saraiva Souza (Examinadora Externa)
Instituto Federal de Educação, Ciência e Tecnologia Baiano

AGRADECIMENTOS

Ao meu noivo e amigo, Paulo, por ser refúgio nos momentos difíceis, pelo companheirismo na trajetória árdua, pelo suporte sem medir esforços e por vibrar comigo em cada conquista.

Aos meus pais, Breno e Ana Márcia, pelo suporte, incentivos constantes e amor incondicional.

Ao meu orientador, professor Alfredo, pela paciência e dedicação. Sou muito grata pelas palavras de incentivo e por todo o conhecimento compartilhado, que me motivaram a buscar uma evolução diária mesmo na dificuldade que foi conciliar todas as atividades.

Aos amigos de turma da UFPE e do GRH, em especial Yan e Vitor, pela parceria, amizade e por tantos momentos especiais que vivemos durante essa etapa, e à Gabrielle Saraiva, por toda a paciência em compartilhar seu conhecimento e ajuda fundamental para o desenvolvimento desse trabalho.

Aos meus irmãos, Bruno e Lívia, pelo companheirismo de sempre, pela distração nos momentos de desânimo e pelas constantes palavras de apoio.

Às minhas avós, Floraci e Elza, por sempre acreditarem no meu potencial.

À Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE) pelo suporte financeiro concedido para o desenvolvimento dessa pesquisa.

RESUMO

As secas são desastres naturais cuja severidade e duração apresentam difícil previsibilidade. Esse evento extremo pode ser identificado, por exemplo, quando teores de umidade do solo abaixo da média são detectados. A umidade em profundidades subsuperficiais possui importante papel em aspectos ecológicos e socioeconômicos, sendo a agricultura um setor fortemente afetado pelas secas, dada a dependência da safra da disponibilidade de água na zona de raiz e, portanto, da umidade do solo. Nesse sentido, esse parâmetro é utilizado em modelos hidrológicos e climáticos bem como no monitoramento de culturas, visto que é indicador da disponibilidade de água para a transpiração e fornece previsibilidade acerca da ocorrência de secas agrícolas. Dentre as metodologias de aferição, o sensoriamento remoto é uma opção viável para obtenção de dados de umidade do solo em larga escala, visto que os dados gerados por satélite possuem grande abrangência espacial e tem frequência temporal satisfatória. A missão SMOS obtém informações de umidade do solo através de um radiômetro que opera na Banda L. Portanto, os dados por ele obtidos referem-se à umidade nos primeiros centímetros do solo. Nesse trabalho, um filtro exponencial para estimar o teor de água na zona da raiz a partir de séries temporais de umidade superficial obtidas via sensoriamento remoto foi avaliado para estações do estado de Pernambuco, com base nos dados do SMOS e utilizando estações *in situ* nas profundidades de 20 cm e 40 cm para calibração e definição de parâmetros. Os resultados obtidos para a zona de raiz foram também comparados aos produtos de umidade do solo dos modelos GLDAS-Noah e GLDAS-CLSM. O teor de umidade do solo estimado pelo filtro exponencial apresentou incrementos médios na correlação de Pearson e reduções no RMSE, de 34% e 25%, respectivamente, quando comparados aos dados do SMOS sem sua aplicação, chegando a correlações mais de 100% maiores e RMSE 70% menores. Quanto aos dados resultantes do filtro com o GLDAS, observou-se um padrão espacial na comparação entre estes e os dados provenientes do filtro.

Palavras-chave: umidade do solo; filtro exponencial; SMOS.

ABSTRACT

Droughts are natural disasters whose severity and duration are often hard to predict. This extreme event can be identified, for example, when soil moisture contents lower than average are detected. Soil moisture at subsurface depths plays an important role in ecological and socioeconomic aspects, as agriculture is a business field heavily affected by droughts, given the crops dependence on the availability of water on the root zone, and therefore, of the soil moisture. In this sense, this parameter is used in hydrological and climate models as well as in agricultural monitoring, as it is an indicator for the availability of water for transpiration and provides predictability regarding the occurrence of agricultural droughts. Among the measurement methodologies for this parameter, remote sensing is a viable option to obtain soil moisture information on a large scale, since the data generated by satellite has a large spatial coverage and has a satisfactory temporal frequency. The SMOS mission measures soil moisture information through a radiometer that operates in the L-Band. Therefore, the data obtained refers to the moisture in the first centimeters of the soil. In this study, an exponential filter to estimate the root zone water content from time series of surface moisture obtained via remote sensing was evaluated for in situ stations located in Pernambuco, Brazil based on SMOS data and using in situ stations at 20 cm and 40 cm depths for calibration and parameters setting. The results obtained for the root zone were also compared to the soil moisture products of the GLDAS-Noah and GLDAS-CLSM models. The soil moisture content estimated by the exponential filter resulted in mean Pearson correlation increments and RMSE reductions in the order of 34% and 25%, respectively, when compared to SMOS data without its application, reaching correlations more than 100% higher and RMSE 70% lower. As for the data resulting from the filter with the GLDAS, a spatial pattern was observed in the comparison between these and the data from the filter.

Keywords: soil moisture; exponential filter; SMOS.

LISTA DE FIGURAS

Figura 1 –	Visão global da umidade do solo para o GLDAS-Noah, em Janeiro de 2000	31
Figura 2 –	Visão global da umidade do solo para o GLDAS-CLSM na zona de raiz (até 100 cm), em fevereiro de 2003	31
Figura 3 –	Mapa das mesorregiões do estado de Pernambuco, incluindo a distribuição espacial das estações in situ e grade do satélite SMOS	32
Figura 4 –	Mapa de localização do Estado de Pernambuco e mesorregiões	33
Figura 5 –	Distribuição espacial das estações in situ e grade do satélite SMOS	37
Figura 6 –	Comparação da umidade do solo obtida in situ, pelo satélite SMOS e SWI para as estações Araripina-APAC (a); Salgueiro – APAC (b); Arcoverde – Acqua (c); e Salgueiro – Acqua (d)	46
Figura 7 –	Comparação da umidade do solo obtida in situ, pelo satélite SMOS e SWI para as estações Ipubi - Acqua (a); Bodocó - Acqua (b); São José do Belmonte – Acqua; e Carnaíba – Acqua (d)	46
Figura 8 –	Comparação da umidade do solo obtida in situ, pelo satélite SMOS e SWI para as estações Floresta - Acqua (a); e Cabrobó - Acqua (b)	50
Figura 9 –	Comparação da umidade do solo obtida in situ, pelo satélite SMOS e SWI para as estações Brejo da Madre de Deus - Acqua (a); Frei Miguelinho - Acqua (b); Cupira – APAC (c); e Venturosa – Acqua (d)	52
Figura 10 –	Frequências de ocorrência do r de Pearson antes e depois aplicação do filtro	54
Figura 11 –	Frequências de ocorrência do RMSE antes e depois aplicação do filtro	54

Figura 12 –	Espacialização do parâmetro T calculado para a profundidade de 20 cm (mapa superior) e 40 cm (mapa inferior)	56
Figura 13 –	Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 e 40 cm, GLDAS-Noah (a) e GLDAS-CLSM (b) para a estação Araripina (APAC)	59
Figura 14 –	Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 cm, GLDAS-Noah (a) e GLDAS-CLSM (b) para a estação Exu (CEMADEN Acqua)	60
Figura 15 –	Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 e 40 cm, GLDAS-Noah (a) e GLDAS-CLSM (b) para a estação Petrolina 1 (CEMADEN Acqua)	61
Figura 16 –	Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 e 40 cm, GLDAS-Noah (a) e GLDAS-CLSM (b) para a estação Carpina (APAC)	62
Figura 17 –	Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 e 40 cm, GLDAS-Noah (a) e GLDAS-CLSM (b) para a estação Jataúba (CEMADEN Acqua)	64
Figura 18 –	Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 e 40 cm, GLDAS-Noah e GLDAS-CLSM para a estação Venturosa (CEMADEN Acqua)	65
Figura 19 –	Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 e 40 cm, GLDAS-Noah e GLDAS-CLSM para a estação Salgadinho (CEMADEN Acqua)	66

LISTA DE TABELAS

Tabela 1 –	Visão geral dos resultados de T, r e RMSE obtidos para a Mesorregião do Sertão Pernambucano	47
Tabela 2 –	Análise da variação da correlação e do RMSE adotando diferentes valores de T para a Mesorregião do Sertão Pernambucano	49
Tabela 3 –	Visão geral dos resultados de T, r e RMSE obtidos para a Mesorregião do Sertão de São Francisco	50
Tabela 4 –	Visão geral dos resultados de T, r e RMSE obtidos para as Mesorregiões Metropolitana do Recife e Zona da Mata	51
Tabela 5 –	Visão geral dos resultados de T, r e RMSE obtidos para o Agreste Pernambucano	53
Tabela 6 –	Visão geral dos resultados de T, r e RMSE e comparação com os dados do SMOS obtidos para todas as Mesorregiões de Pernambuco, nas profundidades de 40 e 20 cm	55
Tabela 7 –	Valores de r e RMSE obtidos para a comparação do SMOS, SWI2, SWI3 e GLDAS-Noah para o Sertão Pernambucano	57
Tabela 8 –	Valores de r e RMSE obtidos para a comparação do SMOS, SWI2, SWI3 e GLDAS-CLSM para o Sertão Pernambucano	58
Tabela 9 –	Valores de r e RMSE obtidos para a comparação do SMOS, SWI2 e GLDAS-Noah para o Sertão de São Francisco	60
Tabela 10 –	Valores de r e RMSE obtidos para a comparação do SMOS, SWI2 e GLDAS-CLSM para o Sertão de São Francisco	61
Tabela 11 –	Valores de r e RMSE obtidos para a comparação do SMOS, SWI2, SWI3 e GLDAS-CLSM para a Zona da Mata	62
Tabela 12 –	Valores de r e RMSE obtidos para a comparação do SMOS, SWI2, SWI3 e GLDAS-Noah para a Zona da Mata	63
Tabela 13 –	Valores de r e RMSE obtidos para a comparação do SMOS, SWI2, SWI3 e GLDAS-CLSM para o Agreste Pernambucano	63
Tabela 14 –	Valores de r e RMSE obtidos para a comparação do SMOS, SWI2, SWI3 e GLDAS-Noah para o Agreste Pernambucano	65

LISTA DE ABREVIATURAS E SIGLAS

APAC	Agência Pernambucana de Águas e Clima
BEC	<i>Barcelona Expert Center</i>
CCI	<i>Climate Change Initiative</i>
CEMADEN	Centro Nacional de Monitoramento e Alertas de Desastres Naturais
CE ACQUA	Estações CEMADEN do tipo Acqua
CE AGRO	Estações CEMADEN do tipo Agro
CLSM	<i>Catchment Land Surface Model</i>
SUR	<i>Surface</i>
COSMOS	<i>CosmicRay Soil Moisture Observing System</i>
EMC	<i>Environmental Modeling Center</i>
ERS	<i>European Remote Sensing</i>
ESA	Agência Espacial Europeia
ESA CCI SM	Umidade do Solo da Iniciativa de Mudança Climática da Agência Espacial Europeia
FOV	<i>Field of View</i>
GEWEX	<i>Global Energy and Water Cycle Experiment</i>
GLDAS	<i>Global Land Data Assimilation System</i>
GSFC	<i>Goddard Space Flight Center</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
LSM	<i>Land Surface Model</i>
MIRAS	<i>Microwave Imaging Radiometer using Aperture Synthesis</i>
NASA	<i>National Aeronautics and Space Administration</i>
NCEP	<i>National Centers for Environmental Prediction</i>
NDVI	Índice de Vegetação de Diferença Normalizada
NOAA	<i>National Oceanic and Atmospheric Administration</i>
OSU	<i>Oregon State University</i>
REMEDHUS	Rede de Estações de Medição da Umidade do Solo
RMSE	<i>Root Mean Square Error</i>
RZ	<i>Root Zone</i>
SARs	Radares de Abertura Sintética

SMAP	<i>Soil Moisture Active Passive</i>
SMOS	<i>Soil Moisture Ocean Salinity</i>
SM10	Dados Noah 0-10cm
SM1040	Dados Noah 10-40cm
SSS	<i>Sea Surface Salinity</i>
SWI	<i>Soil Water Index</i>
SWI2	SWI calculado para 20 cm
SWI3	SWI calculado para 40 cm
TB	Temperatura de Brilho
US2	Umidade do solo obtida <i>in situ</i> para a profundidade de 20 cm
US3	Umidade do solo obtida <i>in situ</i> para a profundidade de 40 cm
VCI	Índice de Condição de Vegetação

SUMÁRIO

1	INTRODUÇÃO	14
1.1	OBJETIVO GERAL	18
1.2	OBJETIVOS ESPECÍFICOS	18
2	EVENTOS DE SECA E FORMAS DE ESTIMATIVA DA UMIDADE DO SOLO	19
2.1	SECAS E REGIÕES SEMIÁRIDAS	19
2.2	SENSORIAMENTO REMOTO APLICADO AO ESTUDO DA UMIDADE DO SOLO	21
2.3	MISSÃO SMOS	23
2.4	FILTRO EXPONENCIAL	25
2.5	MODELOS DE SUPERFÍCIE	28
3	METODOLOGIA	32
3.1	ÁREA DE ESTUDO	32
3.2	DADOS IN SITU DE UMIDADE DO SOLO	34
3.2.1	APAC	35
3.2.2	CEMADEN	36
3.2.3	Consistência dos dados das estações in situ	36
3.3	DADOS SMOS	37
3.4	APLICAÇÃO DO FILTRO EXPONENCIAL	38
3.4.1	Análises estatísticas	41
3.4.2	Comparação do filtro exponencial com os dados das estações in situ	41
3.4.3	Comparação do filtro exponencial com o GLDAS-Noah e GLDAS-CLSM	42
4	RESULTADOS E DISCUSSÃO	44

4.1	COMPARAÇÃO ENTRE O FILTRO EXPONENCIAL, SMOS E ESTAÇÕES IN SITU	44
4.1.1	Comparação entre SWI, SMOS e US2	45
4.1.2	Comparação entre SWI do SMOS, SMOS e US3	55
4.2	COMPARAÇÃO ENTRE O FILTRO EXPONENCIAL, SMOS E MODELOS DE SUPERFÍCIE TERRESTRE	56
5	CONCLUSÕES E RECOMENDAÇÕES	69
5.1	TRABALHOS FUTUROS	70
	REFERÊNCIAS	71

1 INTRODUÇÃO

Segundo Wilhite, Svoboda e Hayes (2007), uma seca é causada por uma deficiência de precipitação devido à variabilidade climática, e seus impactos resultam da combinação entre esse evento natural e a demanda sobre os recursos hídricos locais. Além da precipitação reduzida, a evapotranspiração excessiva também pode resultar em uma seca, e as demandas de uso da água podem ser ainda maiores devido à ineficiência na gestão e distribuição de água na região afetada (WANG *et al.*, 2016). Trata-se, resumidamente, de um período de escassez em que há discrepância entre a demanda de água e sua disponibilidade para as necessidades locais (ZINK *et al.*, 2016).

As secas são consideradas um dos eventos naturais mais caros, especialmente porque podem atingir grandes áreas e persistir por décadas (WANG; LETTENMAIER; SHEFFIELD, 2011). Em algumas regiões do Brasil, especialmente no Sertão nordestino, os baixos índices de chuvas dificultam ainda mais a vida da população, que já se encontra vulnerável sob uma perspectiva econômica-social. Usualmente, quatro tipos de seca são definidos: meteorológica, agrícola, hidrológica e socioeconômica (FERNANDES, 2009). Enquanto a primeira se refere aos índices de precipitação e a terceira aos níveis dos reservatórios de água, a seca agrícola resulta da combinação destas, e impacta diretamente a agricultura devido à deficiência na umidade do solo.

De forma geral, a escassez de chuvas por longos períodos, aliada à altas temperaturas, resulta no aumento da demanda de água, esgotando a umidade do solo na zona da raiz e, conseqüentemente, causando as secas agrícolas (MISHRA; SHAH; THRASHER, 2014). A seca socioeconômica, por sua vez, está diretamente relacionada com o impacto dos três tipos de seca sobre as atividades humanas, podendo ocorrer em situações de déficit hídrico resultante da ausência ou redução na precipitação, aumento na demanda ou mau gerenciamento dos recursos hídricos (FERNANDES, 2009)

A mensuração de uma seca inclui a análise e compreensão de suas características, como frequência, extensão espacial, intensidade, magnitude e duração do evento, e de seu potencial de ocorrência, e tal compreensão é fundamental para o monitoramento em tempo real (MISHRA; SHAH; THRASHER,

2014; SVOBODA *et al.*, 2002). O aprimoramento de técnicas de monitoramento e previsão viabilizam, além da preparação aos eventos extremos, a adoção de melhores práticas de gestão e atenuação da vulnerabilidade da população à seca e seus impactos (SVOBODA *et al.*, 2002).

No contexto da seca agrícola, a umidade do solo é um dos parâmetros mais importantes para viabilizar estimativas de sua ocorrência, já que afeta diretamente o crescimento da safra e impacta os fluxos de troca entre água e energia entre atmosfera e superfície terrestre através da transpiração e evaporação (XU *et al.*, 2018). A umidade do solo pode ser definida como a quantidade de água armazenada nas proximidades da superfície do solo, e é usualmente dividida entre umidade superficial, que se refere ao teor de água nos primeiros centímetros do solo, e umidade da zona de raiz, mais próxima da zona insaturada (KERR *et al.*, 2010).

Informações precisas sobre o teor de umidade do solo possuem grande relevância para diversos processos biofísicos relacionados às trocas de energia e massa entre a hidrosfera, atmosfera e biosfera (ZHANG *et al.*, 2014). Esse parâmetro afeta os processos hidrometeorológicos dentro da camada limite atmosférica, estabelecendo, portanto, uma relação direta com o clima global e os sistemas meteorológicos – a umidade do solo pode ser uma importante fonte de água atmosférica e, quando persistem baixos teores de umidade do solo, ocorre um aumento na probabilidade do surgimento de condições de seca (PETROPOULOS; IRELAND; BARRETT, 2015; ROBINSON *et al.*, 2008)

Nesse sentido, a umidade do solo é um parâmetro extremamente relevante para o monitoramento da ocorrência de secas e previsão de outros eventos climáticos extremos, como inundações e deslizamentos de terra, além de viabilizar informações para uma efetiva gestão dos recursos hídricos, programações e estratégias de manejo da irrigação e previsão da dinâmica da vegetação e produção agrícola (BECK *et al.*, 2021; LIU *et al.*, 2011; VERECKEN *et al.*, 2014; XU *et al.*, 2018).

A umidade do solo apresenta grande variação espacial e temporal. Dados de umidade do solo podem ser obtidos *in situ* medidos em estações de monitoramento, através de modelos de superfície terrestre ou ainda estimado por satélites (LIU; LIU; WANG, 2019). Apesar de apresentarem grande confiabilidade para o monitoramento da umidade do solo na camada superficial e nas camadas mais profundas, as medições *in situ* são limitadas pela reduzida cobertura espacial e temporal (WANG;

LETTENMAIER; SHEFFIELD, 2011; XU *et al.*, 2018). Considerando a necessidade de obter dados contínuos, com maior periodicidade e maior cobertura do espaço, a utilização de sensoriamento remoto é uma opção viável e amplamente utilizada.

A utilização de radiômetros é comumente utilizada no contexto das micro-ondas no sensoriamento remoto para o monitoramento da umidade do solo, especialmente utilizando micro-ondas passivas (VERECKEN *et al.*, 2014). O sinal de micro-ondas na Banda L é impulsionado pela umidade do solo, efeitos de vegetação e temperatura da superfície, enquanto a atmosfera e características como rugosidade do solo e topografia exercem menor influência (KERR *et al.*, 2012). Sendo assim, ao contrário de instrumentos que utilizam maiores frequência (como na Banda C e X), medições usando a banda L resultam em dados de umidade do solo mais precisos e com menos ruídos (CHAN *et al.*, 2016; REICHEL *et al.*, 2017).

A Missão Soil Moisture Ocean Salinity (SMOS) fornece observações globais da Temperatura de brilho (TB), registrando a energia emitida pela superfície da terra através do sensor de micro-ondas passivas Microwave Imaging Radiometer using Aperture Synthesis (MIRAS), radiômetro que opera na banda L em uma frequência de 1,4 GHz (DE JEU *et al.*, 2014; GONZÁLEZ-ZAMORA *et al.*, 2015; KERR *et al.*, 2010; KERR *et al.*, 2012; LIU *et al.*, 2011; SOUZA *et al.*, 2018). A missão SMOS foi lançada pela Agência Espacial Europeia (ESA) em novembro de 2009, e os dados estão disponíveis desde 2010 na resolução temporal de um dia, composição de 3 dias e de 9 dias, além de dados mensais e anuais. A resolução espacial média é de 43 km, e pode ser melhorada a depender do nível de processamento (KERR *et al.*, 2010; SMOS-BEC, 2018; SOUZA *et al.*, 2018).

Na banda L, a TB emitida pelo solo é muito impactada pela umidade do solo nos primeiros 5 centímetros do solo, portanto o SMOS representa a umidade capturada nas proximidades da superfície (JACQUETTE *et al.*, 2010; KERR *et al.*, 2001). A umidade superficial do solo é afetada pela precipitação de curto prazo, mas as demais profundidades do solo também fornecem importantes informações para monitoramentos e modelagens meteorológicas (JACQUETTE *et al.*, 2010; MANFREDA *et al.*, 2014; SABATER *et al.*, 2007).

A umidade solo na chamada Zona de Raiz é especialmente importante em regiões vegetadas, dada sua influência direta nas taxas de evapotranspiração e papel fundamental para o crescimento das plantas (FORD; HARRIS; QUIRING, 2014; HU;

SI, 2014; YANG *et al.*, 2012). Com isso, fornece importante insumos para o estudo e previsibilidade de secas agrícolas. Além da importância nas aplicações agrícolas, estimativas da umidade nessa zona também impactam a quantificação de carbono nos solos, fundamental para análises de mudanças climáticas futuras (TOBIN *et al.*, 2017).

Nesse cenário, uma alternativa para sua mensuração é estabelecer uma relação entre a umidade da superfície do solo e o perfil de umidade através de abordagens que abranjam diferentes profundidades (GAO *et al.*, 2017). Wagner, Lemoine e Rott (1999) propuseram o Filtro Exponencial para estimar a umidade no perfil do solo a partir dos dados obtidos na superfície. O método fundamenta-se na solução analítica de uma equação diferencial, assumindo que a variação da umidade média do solo no perfil está diretamente relacionada à diferença entre os valores da superfície e do perfil (LACAVA *et al.*, 2012). O filtro necessita de apenas um parâmetro como entrada, chamado de tempo característico, T , que expressa a defasagem entre processos na superfície e no perfil da zona não-saturada, isto é, a variação temporal da umidade no perfil da zona de raiz. A constante T computa o *Soil Water Index* (SWI), que representa o teor de umidade do solo variando de 0 a 1. Para tanto, dados de umidade do solo coletados *in situ* são utilizados para a definição do parâmetro T ótimo.

O potencial da aplicação do filtro a partir de dados obtidos por satélites já foi amplamente avaliado (ALBERGEL *et al.*, 2008; BROCCA *et al.*, 2010; CEBALLOS *et al.*, 2005; MANFREDA *et al.*, 2014). Algumas aplicações foram feitas utilizando como entrada os dados do SMOS, e identificando que esse método pode fornecer estimativas precisas da umidade do solo na zona de raiz (FORD; HARRIS; QUIRING, 2014; LACAVA *et al.*, 2012). Considerando que tais estudos foram feitos em outros países, identificou-se a oportunidade de avaliar sua aplicabilidade no nordeste brasileiro, especificamente em Pernambuco.

Neste trabalho, estimativas da umidade do solo obtidas pelo satélite SMOS foram aplicadas ao Filtro Exponencial para avaliar sua performance na estimativa da umidade do solo da zona de raiz em localidades do estado de Pernambuco, a partir de séries temporais de umidade superficial provenientes de estações *in situ* da APAC (Agência Pernambucana de Águas e Clima) e CEMADEN (Centro Nacional de Monitoramento e Alertas de Desastres Naturais). Os resultados obtidos para a zona de raiz foram também comparados aos produtos de umidade do solo dos modelos

GLDAS Noah e Catchment, com o intuito de comparar os cenários antes da aplicação do filtro e depois e contribuindo para a análise da efetividade da aplicação do filtro exponencial.

1.1 OBJETIVO GERAL

Avaliar técnica que permita estimar a umidade do solo em diferentes profundidades com dados do satélite SMOS para o Estado de Pernambuco, abrangendo o período de 2015 a 2019.

1.2 OBJETIVOS ESPECÍFICOS

- Aplicar o Filtro Exponencial aos dados de umidade do solo do Satélite SMOS utilizando dados *in situ* de duas redes de monitoramento, APAC e CEMADEN, para calibração e definição de parâmetros;
- Analisar a performance da aplicação do Filtro Exponencial a partir de análises estatísticas entre os dados obtidos por esse método e os dados coletados nas redes de monitoramento *in situ*;
- Analisar a performance da aplicação do Filtro Exponencial a partir de análises estatísticas entre os dados obtidos por esse método e dados de dois modelos de superfície terrestre.

2 EVENTOS DE SECA E FORMAS DE ESTIMATIVA DA UMIDADE DO SOLO

Neste item serão abordados tópicos sobre secas e umidade do solo, especialmente no contexto do sensoriamento remoto e aplicação do filtro exponencial para obtenção de estimativas de umidade do solo na Zona de Raiz.

2.1 SECAS E REGIÕES SEMIÁRIDAS

Uma seca é um evento climático extremo e temporário, resultante da ocorrência de reduzidos níveis de precipitação durante meses ou anos (DAI, 2011). A difícil previsibilidade da severidade e duração de uma seca torna esse evento tanto um risco, pela possibilidade de ocorrência em qualquer região geográfica, como um desastre, considerando o potencial de causar impactos consideravelmente negativos à vida humana e aos sistemas naturais, especialmente em regiões de maior vulnerabilidade social e econômica.

Sabendo que uma seca pode ocorrer inclusive em locais considerados úmidos, faz-se necessário que estudos sobre sua ocorrência, indícios e progressão sejam continuamente desenvolvidos. O entendimento dos padrões e características de eventos de seca e variações de umidade constitui fator fundamental para a gestão integrada de recursos hídricos, bem como garante a mitigação dos seus efeitos (WU *et al.*, 2018; YE *et al.*, 2016). A previsão desse evento nos primeiros sinais de ocorrência é fundamental para que os impactos sejam controlados ou mitigados (HAO; SINGH; XIA, 2018).

Usualmente, as secas são divididas em quatro tipos: meteorológica, quando as condições atmosféricas resultam na redução ou ausência de precipitação; agrícola, que pode ser causada pela ausência de água nas camadas superficiais do solo; hidrológica, caracterizada pela redução do escoamento superficial e do nível de rios e lagos; e socioeconômica, que se refere aos impactos das secas hidrológica, agrícola e meteorológica sobre a oferta e demanda de bens e serviços (HEIM, 2002). De maneira geral, a redução de precipitação pode resultar em menores teores de umidade do solo e dos níveis de água de corpos d'água. A ocorrência de uma seca pode estar associada não apenas à redução dos índices de precipitação em uma

determinada localidade, mas também de outras variáveis que incluem redução da temperatura, ventos fortes e baixa umidade relativa (MISHRA; SINGH, 2010).

O fenômeno da seca pode ser identificado em um sistema quando este apresenta um período em que a quantidade de água presente em seu ciclo hidrológico é inferior àquela normalmente observada, fato que pode ser constatado, por exemplo, pela ocorrência de menores teores de umidade do solo (VAN LOON; VAN LANEN, 2013; VAN LOON *et al.*, 2016). A baixa umidade do solo reduz a evapotranspiração e eleva o fluxo de calor sensível direcionado para a atmosfera favorecendo a elevação da temperatura do ar, condição na qual ocorre redução do vapor d'água e aumento da demanda por evaporação (RUOSTEENOJA *et al.*, 2018). Com isso, o teor de umidade do solo é progressivamente reduzido.

O semiárido nordestino compõe uma das regiões secas mais populosas do mundo, com precipitações abaixo de 800 mm por ano, alta variabilidade espacial e temporal de chuvas, bem como alto potencial de evaporação devido às altas temperaturas e elevados índices de energia solar (LIMA; ALVES, 2015). Nesse sentido, é uma região extremamente vulnerável à ocorrência de secas. Aliadas aos fatores climáticos, a degradação de terras e desertificação, decorrentes da ação antrópica indistinta, compõem fatores de risco à ocorrência desses eventos (MARENGO *et al.*, 2018).

A seca que se intensificou em 2012 e continuou, em menor grau, em 2015 já é considerada a mais impactante das últimas décadas devido à sua alta intensidade e longa duração (MARENGO; CUNHA; ALVES, 2016). Segundo (ALVALÁ *et al.*, 2019), 184 municípios de Pernambuco foram afetados pela seca entre 2015 e 2016, englobando uma área de 35.843,18 km².

Além disso, a população da região semiárida possui alta vulnerabilidade social, e a ocorrência de uma seca pode comprometer a segurança hídrica e as atividades econômicas. Os eventos extremos de seca afetam diretamente a saúde humana, o abastecimento de água e a produção de alimentos, e a previsão e gestão de seus efeitos depende de um monitoramento efetivo e permanente (GETIRANA, 2016; MARENGO; TORRES; ALVES, 2017).

No cenário de mudanças climáticas, as perspectivas de longo prazo de elevação da frequência e duração de eventos de seca na região nordeste causam preocupações acerca dos impactos nos recursos, oferta de água e produção de

alimentos, e reforçam a necessidade do estabelecimento de medidas preventivas que reduzam seus impactos e elevem a resiliência da população, especialmente dos grupos que dependem unicamente da agricultura de subsistência (MARENGO; TORRES; ALVES, 2017).

2.2 SENSORIAMENTO REMOTO APLICADO AO ESTUDO DA UMIDADE DO SOLO

Diante da dependência de água e de umidade do solo para o crescimento das culturas, a agricultura usualmente é o setor mais afetado pela ocorrência de uma seca, e essa vulnerabilidade reforça a importância da previsibilidade e monitoramento desses eventos para a adoção de medidas que reduzam seus impactos (NARASIMHAN; SRINIVASAN, 2005). Os fluxos de água e energia na superfície terrestre e na atmosfera têm relação direta com a umidade do solo – os processos de evaporação, infiltração e escoamento superficial são desencadeados por esse parâmetro (BARRÉ; DUESMANN; KERR, 2008).

A umidade do solo influencia ainda os balanços de massa e energia entre a superfície e a atmosfera (KERR, 2007). Segundo Wei (1995), o controle que a umidade do solo exerce sobre a partição de energia disponível em trocas de calor sensível e latente com a atmosfera e o entendimento de sua ligação com os fenômenos de evaporação e transpiração é fundamental para a previsão da conexão entre os processos que ocorrem na superfície terrestre com o clima e o tempo.

Nesse contexto, a umidade do solo e sua variabilidade espaço-temporal são informações de grande importância para modelos numéricos de tempo, climáticos e hidrológicos, bem como para o monitoramento de vegetações – a relação entre a umidade do solo e o conteúdo de água da vegetação fornece insumos relevantes para modelagens hidrológicas de monitoramento de reservatórios de água, por exemplo (BARRÉ; DUESMANN; KERR, 2008). A previsão do escoamento superficial requer informações sobre o volume de chuva e a capacidade de uma bacia hidrográfica de infiltrar essa precipitação, e tal capacidade é diretamente determinada pelas condições de umidade do solo (CROW; RYU, 2009).

Ainda no campo dos modelos hidrológicos, esse parâmetro aprimora a previsão de precipitação e ocorrência de enchentes e secas, além de fornecer insumos para a

tomada de decisão no âmbito da gestão de recursos hídricos (DIRMEYER *et al.*, 2006; DORIGO *et al.*, 2011; WANG; LETTENMAIER; SHEFFIELD, 2011).

Considerando a importância de usar a umidade do solo como parâmetro indicador da ocorrência de eventos extremos, uma cobertura em larga escala do teor de água em intervalos de tempo regulares e representativos se faz necessária para a concepção e aplicabilidade de modelos preditivos com alta confiabilidade. Como as redes de observação *in situ* da umidade do solo estão limitadas à locais específicos, sua aferição a partir dessa abordagem está limitada à um número reduzido de estações instaladas e que fornecem dados em intervalos de tempo discretos e, portanto, não representam com fidelidade a variabilidade espacial e temporal desse parâmetro (ROBOCK *et al.*, 2000; WANG; LETTENMAIER; SHEFFIELD, 2011).

Nesse cenário, a utilização de sensoriamento remoto constitui uma importante ferramenta para suprir tais limitações, principalmente pela possibilidade de uma ampla e representativa cobertura espacial. O uso de sensoriamento remoto por micro-ondas passivas e ativas se mostra eficaz para estimar as propriedades dielétricas do solo com base na emissividade da superfície terrestre, devido ao contraste entre as propriedades dielétricas da água líquida e do material do solo (GONZÁLEZ-ZAMORA *et al.*, 2015; MOHANTY *et al.*, 2017; ROSSATO, 2010).

Estudos mostram que quando os sensores de micro-ondas são operados em baixas frequências, nas bandas X, C e L, as aferições são minimamente afetadas pelas nuvens e pelas condições atmosféricas, além de que a profundidade de penetração é significativa, da ordem de 5 cm, tornando as estimativas mais representativas (KERR *et al.*, 2010; MOHANTY *et al.*, 2017).

A abordagem do sensoriamento através de micro-ondas ativas fundamenta-se no uso dos chamados Radares de Abertura Sintética (SARs), os quais oferecem medições com maior resolução espacial, porém com baixa resolução temporal, além de sofrerem perturbações devido à cobertura vegetal e à rugosidade da superfície terrestre (GONZÁLEZ-ZAMORA *et al.*, 2015; KERR *et al.*, 2010; KUMAR *et al.*, 2018). Os sensores de micro-ondas passivas, por sua vez, são conhecidos como radiômetros e estimam a umidade do solo através da TB, energia emitida naturalmente pela superfície da Terra, em menores resoluções espaciais (PAN; SAHOO; WOOD, 2014; SOUZA *et al.*, 2018).

De maneira geral, a maior sensibilidade à umidade do solo é observada quando o monitoramento do parâmetro é realizado a partir de radiômetros de micro-ondas que operam na banda L (21 cm, 1,4 GHz) (KERR *et al.*, 2001). Por esse motivo, missões dedicadas ao monitoramento da umidade do solo são munidas de radiômetros operantes nessa banda, tais como os satélites Soil Moisture and Ocean Salinity (SMOS) e Soil Moisture Active and Passive (SMAP) (DE JEU *et al.*, 2014; KERR, 2007).

2.3 MISSÃO SMOS

A missão SMOS foi lançada pela Agência Espacial Europeia (ESA) em 2009, e fornece dados continuamente desde 2010. O satélite carrega a bordo o sensor de micro-ondas passivas MIRAS, radiômetro interferométrico bidimensional que opera na banda L em uma frequência de 1,4 GHz (CUI *et al.*, 2018; KERR *et al.*, 2010; SMOS-BEC, 2018). O sensor é formado por três braços conectados a um hub central, e possui no total 69 antenas espaçadamente distribuídas (MCMULLAN *et al.*, 2008). O objetivo básico e principal da missão é fornecer mapas globais de umidade do solo nos continentes e da salinidade da superfície do mar (Sea Surface Salinity – SSS) com específica precisão, resolução espacial e variabilidade temporal (BARRÉ; DUESMANN; KERR, 2008).

O fato de ser um interferômetro bidimensional permite a medição da Temperatura de Brilho em diferentes ângulos de incidência e para duas polarizações, fornecendo instantaneamente uma imagem completa e aumentando sua acurácia (KERR *et al.*, 2001). A capacidade de observação multiangular de um radiômetro espacial interferométrico 2D é resultante do campo de visão instantâneo bidimensional (Field of View – FOV); cada área dentro desse campo é visualizada a partir de um ângulo de visão específico, e conforme o satélite segue seu trajeto, diferentes temperaturas de brilho emitidas por um mesmo local são recepcionadas em ângulos de incidência distintos (WIGNERON *et al.*, 2000). Nesse contexto, a concepção do SMOS parte do objetivo de distinguir as contribuições do solo e da vegetação para a emissividade terrestre a partir de tais informações angulares.

O monitoramento da umidade do solo pelo SMOS ocorre a cada três dias, quando ocorre a revisita de um ponto específico da superfície, e os produtos são

disponibilizados em uma resolução espacial de 43 km (CUI *et al.*, 2018; KERR, 2007). A depender do nível de processamento, a resolução pode melhorar para 40 Km no produto L2, 25 km no L3 e 1 km no L4 (SOUZA *et al.*, 2018). Após os processos de calibração e correção, os mapas da temperatura de brilho em diferentes polarizações são gerados, tanto para as áreas terrestres fotografadas como para os oceanos e, a partir daí, a informação geofísica de interesse para a missão é gerada (BARRÉ; DUESMANN; KERR, 2008).

O SMOS está inserido em uma órbita sol-síncrona, isto é, geocêntrica e com combinação de altitude e inclinação para que o satélite passe sobre um ponto específico da superfície terrestre no mesmo horário solar local (BARRÉ; DUESMANN; KERR, 2008). Em sua órbita ascendente, movimentação no sentido sul-norte, o satélite passa no equador às 6 horas da manhã, horário escolhido para reduzir perturbações no sinal da banda L e minimizar o efeito Faraday (KERR *et al.*, 2001). Tal abordagem reduz especialmente a perturbação causada pela radiação solar.

Os produtos do SMOS são amplamente utilizados para o monitoramento de secas, a partir do cálculo de índices de secas agrícolas que medem anomalias nos solos (CHAKRABARTI *et al.*, 2014; MARTINEZ-FERNANDEZ *et al.*, 2015; MOHANTY *et al.*, 2017; PAREDES-TREJO; BARBOSA, 2017; SOUZA *et al.*, 2018; SOUZA; RIBEIRO NETO; SOUZA, 2021). Tal abordagem no Nordeste brasileiro é particularmente relevante dada a vulnerabilidade dessa região à ocorrência de secas, e a combinação de produtos de satélites e modelos matemáticos de monitoramento constitui uma importante ferramenta para a tomada de decisão diante da ocorrência de eventos adversos.

A qualidade dos dados do SMOS pode ser afetada pela chamada Interferência de Radiofrequência (RFI), a qual afeta a construção das imagens e, portanto, seu algoritmo e produtos devem ser validados a partir da comparação com estações *in situ* de umidade do solo, em diferentes regiões climáticas (BIRCHER *et al.*, 2012).

Souza *et al.* (2018) realizaram a validação dos dados do SMOS para todo o estado de Pernambuco, considerando a Zona da Mata, Agreste e Sertão, suas regiões climáticas, a partir da comparação com mensurações de estações *in situ*, e as análises estatísticas mostraram resultados relevantes. Foi feita ainda uma avaliação da seca no período de 2010 a 2017, indicando anomalias igual ou menor a -50% para umidade do solo e para precipitação, principalmente no ano de 2012. Souza, Ribeiro Neto e

Souza (2019) utilizaram a umidade do solo do satélite SMOS para avaliar o desempenho do índice VCI obtido através do NDVI e encontraram correlação r de Pearson muito forte para o agreste e sertão pernambucano, além de constatar que os anos de 2012 a 2017 foram os mais secos para o Estado de Pernambuco. Os dados do SMOS foram usados também para estimar secas meteorológicas e agrícolas a partir de índices de seca (SOUZA; RIBEIRO NETO; SOUZA, 2021).

2.4 FILTRO EXPONENCIAL

Apesar da abrangência temporal e espacial oferecida pelo SMOS, a umidade do solo medida por satélites que operam na banda L corresponde àquela observada próximo à superfície, de até cinco centímetros de profundidade (AL BITAR *et al.*, 2012; ESCORIHUELA *et al.*, 2010). Especificamente nos primeiros dois centímetros de profundidade, a variabilidade do teor de umidade do solo é muito alta devido à evaporação; para as camadas mais profundas, a variabilidade depende da topografia, tipos de solo e de cobertura vegetal, além da atuação de forças atmosféricas (WAGNER; LEMOINE; ROTT, 1999).

A umidade do solo na região mais superficial se relaciona diretamente com a precipitação de curto prazo e pode indicar a ocorrência de uma seca meteorológica; a medição desse parâmetro na chamada zona de raiz, por sua vez, é fator determinante para o crescimento da vegetação, dado que é responsável pela disponibilidade de água para a transpiração e, portanto, um indicador de uma seca agrícola (BOLTEN *et al.*, 2010; WANG; LETTENMAIER; SHEFFIELD, 2011).

A profundidade das raízes pode variar desde alguns centímetros até mais de dois metros, porém a zona de raiz é frequentemente considerada como os primeiros 100 cm do solo, dado a suposição de que a maior densidade de raízes de plantas geralmente existe nesta faixa de profundidade (BALDWIN *et al.*, 2017). A zona de raiz é a principal ligação entre a vegetação e os recursos dos quais necessita, bem como constitui uma parte crítica da zona vadosa superior em termos da divisão da chuva e da água utilizada na irrigação em evaporação, transpiração, escoamento e drenagem profunda (LAZAROVITCH *et al.*, 2018).

Os principais métodos utilizados para mensurar o perfil de umidade do solo a partir de medições na superfície podem ser classificados de três diferentes formas:

assimilação de dados, métodos analíticos e métodos estatísticos (GAO *et al.*, 2017). Segundo os autores, os métodos estatísticos são utilizados principalmente devido à sua simplicidade, mas podem limitar a abordagem visto que dependem unicamente de dados, e na maior parte das vezes apenas medições superficiais coletadas por satélites, de até 5 cm de profundidade, estão disponíveis.

A assimilação de dados, por sua vez, se refere ao método que utiliza os produtos de umidade do solo dos satélites combinados à modelos hidrológicos para obter uma melhor representatividade do perfil de umidade do solo; sua precisão, entretanto, depende da compreensão dos processos hidrológicos do solo, bem como da necessidade de dados de entrada do modelo que consistem em parâmetros que representam as propriedades do solo e da vegetação (DUMEDAH; WALKER; MERLIN, 2015; HU; SI, 2014; SABATER *et al.*, 2007). Nesses casos, o perfil de solo em estudo depende diretamente do modelo, então o método de assimilação escolhido influencia os resultados (ALBERGEL *et al.*, 2008; SABATER *et al.*, 2007).

Por fim, os métodos analíticos usualmente necessitam de um menor número de dados de entrada e são computacionalmente mais eficientes do que os métodos de assimilação, mas existe um desafio em definir uma relação analítica entre a umidade do solo na superfície e nas camadas inferiores (GAO *et al.*, 2017; MANFREDA *et al.*, 2007; MANFREDA *et al.*, 2014). Wagner, Lemoine e Rott (1999) forneceram uma grande contribuição nesse sentido, e propuseram um modelo empírico baseado no cálculo do *Soil Water Index* (SWI), para estimar o teor de água do perfil – o SWI representa o teor de umidade do solo da zona da raiz a partir de séries temporais de umidade superficial obtidas via sensoriamento remoto. O Filtro Exponencial, modo como é chamado, foi desenvolvido para examinar tendências de umidade do solo a partir de dados do dispersômetro do ERS (European Remote Sensing) na Ucrânia (TOBIN *et al.*, 2017).

Para a obtenção do filtro, um único parâmetro T deve ser determinado, e ele representa a escala de tempo de variação da umidade do solo em dias. Esse método é utilizado para estimar a umidade do solo na zona de raiz em locais onde apenas a umidade na superfície é medida, e é adequado para o acompanhamento das condições do solo quase em tempo real (FORD; HARRIS; QUIRING, 2014).

Diversos estudos já foram desenvolvidos para analisar o potencial desse método em dados coletados por satélites (FORD; HARRIS; QUIRING, 2014; GAO *et*

al., 2017; LACAVA *et al.*, 2012; MANFREDA, S. *et al.*, 2014; MISHRA *et al.*, 2020; TOBIN *et al.*, 2017). Dentre as abordagens a partir desses satélites, inclui-se o ASCAT e ERS (BROCCA *et al.*, 2010; CEBALLOS *et al.*, 2005; WAGNER; LEMOINE; ROTT, 1999). Outras abordagens basearam-se na aplicação do filtro exponencial à dados de umidade do solo obtidas *in situ* ou estimada por modelos (ALBERGEL *et al.*, 2008; FORD; HARRIS; QUIRING, 2014).

Ceballos *et al.* (2005) validaram a aplicação do filtro exponencial utilizando dados de satélite provenientes da missão ERS e de estações *in situ* da rede REMEDHUS (Rede de Estações de Medição da Umidade do Solo, Espanha) para estimar o teor de umidade do solo até 100 cm de profundidade em uma região semiárida e com baixa precipitação anual, da ordem de 400 mm, e encontraram um coeficiente de correlação R² médio de 0,75.

Albergel *et al.* (2008) utilizaram dados *in situ* de 12 estações observados a uma profundidade de 5 cm e aplicaram o filtro exponencial. Na comparação com estações situadas a 30 cm, um T ótimo de 6 dias foi encontrado. A aplicação do método foi considerada satisfatória após a otimização do parâmetro T, e a variabilidade interanual e sazonal da umidade do solo na zona de raiz foi bem representada pelo filtro exponencial.

Calvet (2008) estimou o valor da duração de tempo característica (T) do filtro exponencial aplicado aos produtos de umidade do solo do satélite ASCAT a partir da comparação com estações *in situ* localizadas no sudoeste da França e estabelecidas em uma profundidade de 30 cm, apresentando valores de correlação significativos e com a maior correlação calculada para valores de T=14 dias. Em média, foi obtido um coeficiente de correlação e RMSE de 0,558 e 0,289, respectivamente, e a maior correlação obtida foi de 0,918. De maneira geral, observou-se que o SWI apresentou boa correlação com os dados *in situ*.

Brocca *et al.* (2010) investigaram o potencial do produto de umidade do solo do satélite ASCAT para aplicações hidrológicas através do cálculo do SWI e sua comparação com o padrão temporal de umidade do solo derivado de um modelo contínuo de chuva-vazão, obtendo coeficientes de correlação R² maiores que 0,90 e RMSE menores que 0,014 m³/m³.

Para o SMOS, consideráveis estudos foram desenvolvidos. Dentre eles, (FORD; HARRIS; QUIRING, 2014) aplicaram o filtro exponencial usando a umidade

do solo próxima da superfície proveniente do SMOS e dados *in situ* de estações situadas em 25 cm de profundidade e verificaram que, apesar de haver uma variabilidade espacial e temporal do desempenho, esse método pode fornecer estimativas precisas da umidade do solo na zona de raiz – com correlação superando 0,90 em alguns locais. Lacava *et al.* (2012) aplicaram o filtro exponencial aos produtos do SMOS para três localidades da Itália e Luxemburgo, comparando com os dados *in situ* observados em profundidades de 5 e 10 cm e resultando em um valor de $T=15$ dias.

No presente estudo, será avaliada a aplicação do Filtro Exponencial descrito por Albergel *et al.* (2008) para estimar a umidade do solo da zona da raiz a partir de observações próximas à superfície, derivadas do SMOS, em localidades do Estado de Pernambuco. O satélite SMOS foi escolhido dado que, conforme mencionado, a validação dos dados para todo o Estado já foi realizada, inclusive utilizando as estações *in situ* do CEMADEN e APAC.

2.5 MODELOS DE SUPERFÍCIE

Visando a obtenção de representações cada vez mais precisas das interações entre a superfície terrestre e a atmosfera, as buscas por parametrizações dos processos de superfície do solo tornaram-se mais intensas ao longo do tempo. Os chamados modelos de superfície (Land Surface Model – LSM) apresentam grande relevância nos estudos de simulação dos fluxos de energia e de água em resposta às forças atmosféricas atuantes na superfície (EK *et al.*, 2003). Tais modelos são fundamentais para compreender e prever a troca de massa e energia entre a biosfera terrestre e a atmosfera – eles representam os principais processos que regulam a troca de energia e matéria: fotossíntese, respiração e evapotranspiração, os quais influenciam o sistema climático através do controle do balanço energético e das trocas de gases de efeito estufa (WILLIAMS *et al.*, 2009).

No início dos anos 1990, o Environmental Modeling Center (EMC), parte do National Centers for Environmental Prediction (NCEP), iniciou os testes para avaliar a eficiência do LSM desenvolvido para previsões numéricas de tempo na Oregon State University (OSU). Após comparação com outros modelos similares, o EMC escolheu esse modelo para refinamento e implementações nos modelos regionais e global de

tempo e clima do NCEP (MITCHELL, 2005). Nesse contexto, o NCEP ampliou as colaborações no desenvolvimento do LSM com o suporte do Global Energy and Water Cycle Experiment (GEWEX), incorporando maior complexidade ao modelo, o qual foi renomeado para Noah LSM (TIMM, 2011). O Noah é responsável pela representação dos processos hidrodinâmicos e termodinâmicos do sistema solo-atmosfera e pela estimativa das variáveis que caracterizam os processos físicos.

O LSM Catchment Land Surface Model (CLSM), por sua vez, simula mudanças de armazenamento de água subterrânea a partir de interações terra-atmosfera - precipitação e evapotranspiração – usando como variáveis a umidade excessiva do solo em relação ao estado de equilíbrio na camada superficial (até 2 cm) e na zona da raiz (até 100 cm), bem como o déficit de captação, isto é, a quantidade de água necessária para saturar o perfil de solo (LI *et al.*, 2019).

O CLSM se diferencia dos demais modelos de superfície por não possuir camadas verticais de solo; ele usa a bacia hidrográfica derivada topograficamente como o elemento da superfície terrestre, e não uma grade, como nos modelos tradicionais. Já o Noah possui 4 camadas verticais de solo, camada superficial (0 a 10cm de espessura), zona de raízes (10 a 40cm), zona de raízes profundas (40-100cm) e zona abaixo das raízes (100-200cm). Entende-se, portanto, que as diferentes estruturas dos dois modelos resultam em diferenças na estimativa da umidade do solo.

O Global Land Data Assimilation System (GLDAS), desenvolvido em conjunto pela National Aeronautics and Space Administration (NASA), Goddard Space Flight Center (GSFC), National Oceanic and Atmospheric Administration (NOAA) e NCEP, incorpora modelos de superfície e seus produtos incluem umidade do solo, temperatura da superfície e parâmetros de fluxo, como evaporação (FANG *et al.*, 2009). Dentre os modelos inseridos, inclui-se o Noah LSM e o Catchment Land Surface Model. O GLDAS utiliza técnicas de assimilação de dados para integrar dados de satélite e observações em campo aos modelos avançados de superfície terrestre e gerar estimativas mais acuradas do estado natural do ambiente (RODELL *et al.*, 2004).

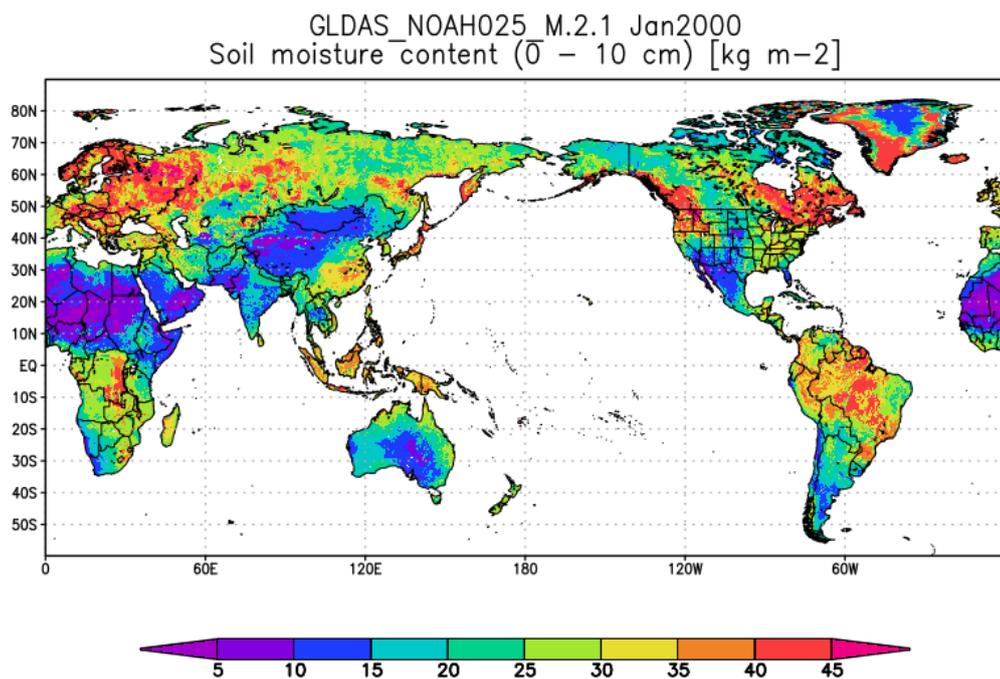
De forma geral, o GLDAS inclui 4 componentes: 1) modelagem do solo, com o intuito de preparar a inclusão dos diferentes modelos de superfície; 2) observações da superfície terrestre, tendo as previsões meteorológicas do NCEP como base da

geração do modelo, e os dados de satélite; 3) assimilação dos dados; e 4) calibração e validação (DE SOUZA, 2015).

A aplicação de modelos de superfície terrestre para o estudo de secas e gerenciamento hídrico é amplamente difundida. Como exemplos de aplicação do GLDAS e assimilação dos modelos de superfície, Sahoo *et al.* (2021) examinaram as mudanças no armazenamento de água subterrânea em um distrito de Bengala Ocidental, na Índia, usando o GLDAS versão 2 (GLDAS-2) CLSM. Liu *et al.* (2019) compararam os dados multi-satélite do ESA CCI e do GLDAS-Noah para realizar uma análise da seca global de 1991 a 2015. Zawadzki e Kędzior (2016) avaliaram a variabilidade da umidade do solo ao longo de uma bacia hidrográfica, e para tanto compararam os dados de umidade do solo do SMOS com as simulações de umidade do solo do GLDAS Noah com 3 horas de resolução temporal, produzido para os primeiros centímetros do solo (0–10 cm) e com resolução espacial de 0,25°.

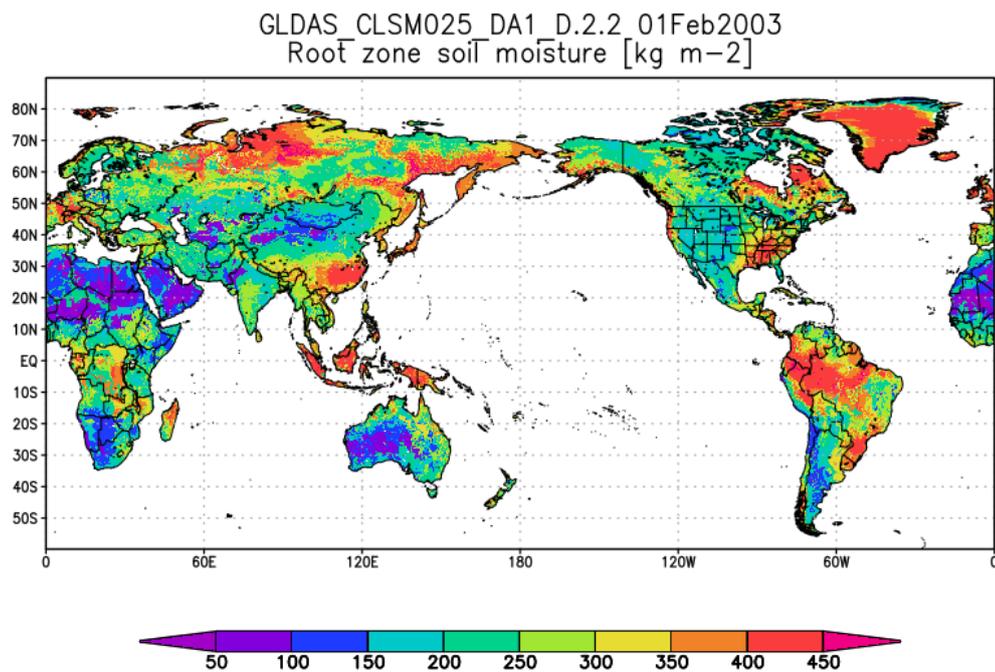
O GLDAS versão 2 (GLDAS-2) possui três componentes: GLDAS-2.0, GLDAS-2.1 e GLDAS-2.2. O primeiro é forçado inteiramente com os dados meteorológicos de Princeton. O GLDAS-2.1 apresenta uma combinação de modelo e dados observados. Por fim, o GLDAS-2.2 utiliza a assimilação de dados, ao contrário dos dois primeiros. Os produtos GLDAS possuem resolução temporal de 3 horas e alta resolução espacial, chegando a 0,25°. A visão global do parâmetro umidade do solo é apresentada nas figuras 1 e 2, para o GLDAS Noah (janeiro de 2000) e GLDAS CLSM (fevereiro de 2003), respectivamente.

Figura 1 – Visão global da umidade do solo para o GLDAS-Noah, em Janeiro de 2000



Fonte: GES DISC NASA Global Land Data Assimilation System (2021)

Figura 2 – Visão global da umidade do solo para o GLDAS-CLSM na zona de raiz (até 100 cm), em fevereiro de 2003

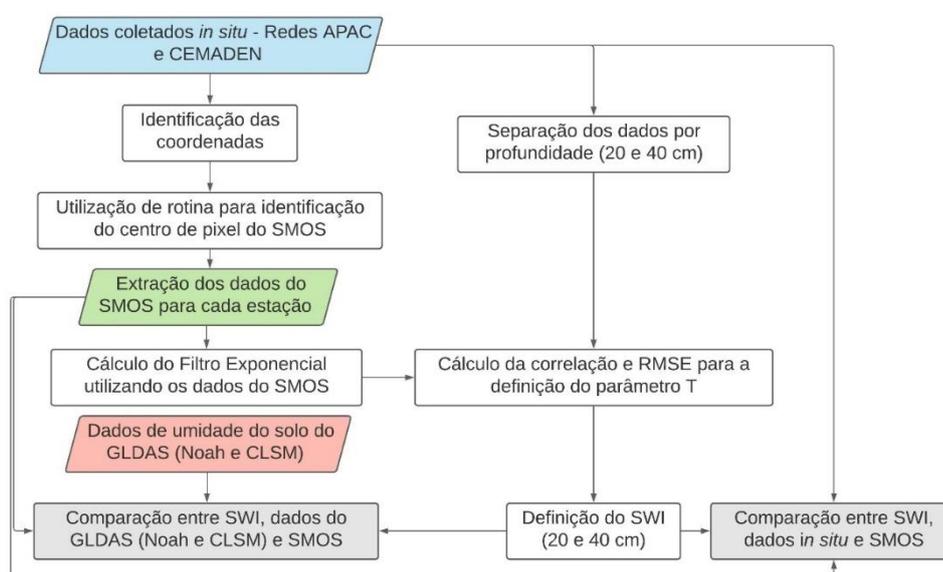


Fonte: GES DISC NASA Global Land Data Assimilation System (2021)

3 METODOLOGIA

A metodologia utilizada para a condução do presente estudo foi detalhada na Figura 3. Como informações de entrada, foram utilizados os dados obtidos *in situ* pelas redes de monitoramento da APAC e CEMADEN, estimativas da umidade do solo do satélite SMOS e estimativas dos modelos de superfície terrestre GLDAS-Noah e GLDAS-CLSM. Os dados *in situ* e as estimativas do SMOS foram utilizadas para o cálculo do SWI.

Figura 3 - Mapa das mesorregiões do estado de Pernambuco, incluindo a distribuição espacial das estações *in situ* e grade do satélite SMOS



Fonte: A autora (2021)

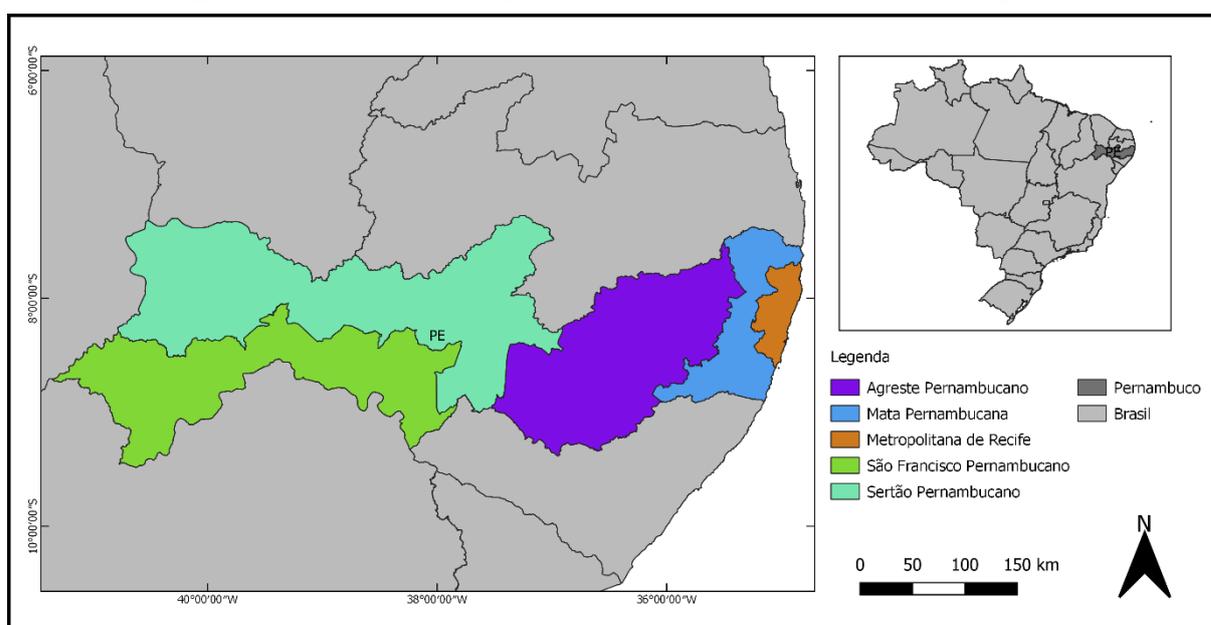
3.1 ÁREA DE ESTUDO

A área de estudo objeto do presente trabalho incorpora todo o Estado de Pernambuco. Localizado no nordeste brasileiro, Pernambuco possui uma área de aproximadamente 98.068 Km² e está situado entre as coordenadas 7°15' e 9°30' Sul e 34°48' e 41°23' Oeste (Figura 4).

O Estado possui 89% de seu território com clima semiárido, e o restante com clima úmido e subúmido, de acordo com a classificação climática de Thornthwaite (ASFORA; LIMA; LACERDA, 2017). De forma geral, apresenta baixa amplitude térmica, com temperaturas que variam entre 25 e 31 °C no ano, e alta variabilidade

espacial e temporal da precipitação. Os maiores índices pluviométricos são observados no litoral, onde predomina o clima tropical úmido, e decrescem em direção ao interior do continente, com clima semiárido.

Figura 4 – Mapa de localização do Estado de Pernambuco e mesorregiões



Fonte: A autora (2021)

O clima semiárido, presente nas Mesorregiões do Sertão e Agreste, caracteriza-se pelos baixos índices pluviométricos, com longos períodos secos e chuvas escassas, concentradas em poucos meses do ano e altas temperaturas. A pluviosidade média mantém-se entre 500 e 800 milímetros (mm) anuais. Na região semiárida do Nordeste brasileiro predominam solos rasos, que tendem a se saturar com os eventos chuvosos e perder água facilmente em períodos de seca (MENEZES *et al.*, 2013).

Já o clima tropical úmido, presente na região metropolitana do Recife e na Zona da Mata, caracteriza-se por baixa amplitude térmica, com alta umidade relativa do ar e pluviosidade média anual na faixa de 1.500 e 2.500 mm (ASFORA; LIMA; LACERDA, 2017). Nessas regiões, os períodos chuvosos são intensos e se prolongam por mais de seis meses.

As cinco mesorregiões pernambucanas, identificadas pelo Instituto Brasileiro de Geografia e Estatística (IBGE) a partir das diferentes paisagens e caracterização do uso do solo, são: Metropolitana, Mata, Agreste, Sertão do São Francisco e Sertão

Pernambucano. De maneira geral, a mesorregião Metropolitana do Recife apresenta regularidade na ocorrência de eventos secos e chuvosos, enquanto no Agreste Pernambucano são predominantes os episódios extremamente secos; já nas mesorregiões do sertão, além do elevado número de eventos extremamente secos, fortes chuvas se concentram entre os meses de dezembro e fevereiro (NÓBREGA; FARIAS; SANTOS, 2015).

As análises conduzidas neste trabalho foram realizadas em municípios das cinco mesorregiões, e os resultados foram apresentados de forma agrupada para cada uma delas de forma a facilitar a visualização dos dados e a identificação de padrões.

3.2 DADOS *IN SITU* DE UMIDADE DO SOLO

Os dados de umidade do solo *in situ* coletados pelas redes da APAC e do CEMADEN foram utilizados para a aplicação e avaliação do filtro exponencial proposto por (WAGNER; LEMOINE; ROTT, 1999).

As redes possuem períodos distintos: a base de dados da APAC abrange o período de 2013 a 2019, e a do CEMADEN de 2015 a 2019. Com o objetivo de equiparar o horizonte temporal, a análise foi realizada para o período entre maio de 2015 e agosto de 2019 para os dados da APAC, e entre julho de 2015 e abril de 2019 para os dados do CEMADEN.

Para cada estação *in situ*, a umidade do solo do pixel do SMOS correspondente foi extraída. Considerando os critérios condicionados à aplicação do filtro exponencial, conforme apresentado a seguir em tópico específico, foram consideradas apenas estações com pelo menos 30% de dados disponíveis no intervalo de tempo da base de dados. Uma análise preliminar de consistência também foi realizada com o objetivo de desconsiderar estações com períodos de dados inferior a um ano ou com valores de umidade do solo discrepantes na maior parte do período considerado. No total, 55 estações *in situ* foram selecionadas para o estudo, sendo 9 da APAC e 46 do CEMADEN.

3.2.1 APAC

A APAC possui 12 estações de umidade do solo no estado de Pernambuco, compostas por uma sonda de perfil do modelo PR2/4, a qual possui quatro sensores e mede a umidade do solo nas profundidades de 10, 20 e 40 cm. A umidade do solo é medida indiretamente pela sonda através da emissão de um campo eletromagnético. Ao aplicar um campo eletromagnético constante e obter como resultado uma diferença de potencial estável é possível calcular a permissividade elétrica do solo, a qual está diretamente relacionada ao seu conteúdo de água. Dessa forma, a sonda determina a umidade do solo em volts.

Com alcance de até $1,0 \text{ m}^3.\text{m}^{-3}$, a acurácia estimada é de $\pm 0,06 \text{ m}^3.\text{m}^{-3}$ quando realizada uma calibração generalizada para solos minerais ou orgânicos, e pode chegar a $\pm 0,4 \text{ m}^3.\text{m}^{-3}$, se uma calibração específica para cada tipo de solo for realizada. Para os solos minerais, os erros esperados são da ordem de $\pm 0,06 \text{ m}^3.\text{m}^{-3}$, enquanto que para os orgânicos podem chegar a $\pm 0,05 \text{ m}^3.\text{m}^{-3}$.

Os dados são coletados pela APAC em intervalos horários. Para fins de comparação, a média diária para cada estação foi calculada. Para a comparação do SWI calculado pelo filtro exponencial, foram utilizadas apenas as medições realizadas em 20 e 40 cm.

Para a conversão da umidade do solo obtida em Volts para uma unidade volumétrica, foram utilizadas as equações polinomial e linear, disponibilizadas para solos orgânicos e minerais, aplicadas em cada estação. Diante da ausência de definição do tipo do solo no momento da instalação da sonda, a equação escolhida para cada estação foi aquela que apresentou maior correlação estatística na análise realizada por Souza (2019).

As equações polinomiais definidas no manual para solos orgânicos (Eq. 1) e minerais (Eq. 2) são:

$$\theta_{min} = -0,057 - 0,66V + 8,00V^2 - 27,91V^3 + 49,23V^4 - 42,46V^5 + 14,47V^6 \quad (1)$$

$$\theta_{org} = -0,023 - 0,72V + 8,72V^2 - 30,44V^3 + 53,71V^4 - 46,32V^5 + 15,78 \quad (2)$$

Onde θ_{min} e θ_{org} representam a umidade do solo em $\text{m}^3.\text{m}^{-3}$ para solos minerais e orgânicos, respectivamente, e V é a umidade do solo coletada pela sonda em volts.

Similarmente, as equações lineares para solos minerais (Eq. 3) e solos orgânicos (Eq. 4) estão descritas abaixo:

$$\theta_{min} = 0,528V - 0,146 m^3 \cdot m^{-3} \quad (3)$$

$$\theta_{org} = 0,575V - 0,121 m^3 \cdot m^{-3} \quad (4)$$

Onde V é o valor de umidade do solo medido pela sonda em volts.

3.2.2 CEMADEN

Em 2015, o CEMADEN instalou estações de medição *in situ* de umidade do solo no semiárido brasileiro. As estações possuem sensores de umidade do solo (modelo EC-5, da Decagon Devices), com precisão de $\pm 0,03 m^3 \cdot m^{-3}$ e podem ser do tipo Acqua, onde os sensores estão instalados nas profundidades de 10 e 20 cm, ou agro, com aferição nas profundidades de 10, 20, 30 e 40 cm. Ambas monitoram ainda a precipitação, e as do tipo Agro adicionalmente fornecem dados de temperatura do solo e do ar, umidade relativa, velocidade do vento e radiação solar (ZERI *et al.*, 2018). Para Pernambuco, foram disponibilizados dados de 77 estações.

Apesar de fornecer os dados em intervalos horários, a média diária para cada estação do CEMADEN foi calculada com o objetivo de permitir a comparação com o SWI do filtro exponencial. Para as estações Acqua foram selecionados apenas os dados referentes à profundidade de 20 cm, e para as estações Agro considerou-se as profundidades de 20 e 40 cm – dado que a rede da APAC não coleta dados em 30 cm, estes não foram considerados. Considerando os critérios de representatividade de dados e consistência, 44 estações Acqua e 2 estações Agro foram utilizadas no estudo.

3.2.3 Consistência dos dados das estações *in situ*

Uma análise de consistência foi realizada com objetivo de garantir que não haveria impacto na aplicação do filtro exponencial, visto que são utilizados como insumos as estimativas do satélite e o tempo decorrido entre uma estimativa e a anterior, bem como os dados *in situ* são utilizados nos cálculos de correlação.

Após a seleção inicial das estações do CEMADEN e da APAC com percentual de dados maior que 30% considerando o total de dias do período de coleta, a análise foi feita para comparar os dados *in situ* com as estimativas de umidade do solo do SMOS e desconsiderar valores negativos ou incompatíveis com a realidade da região.

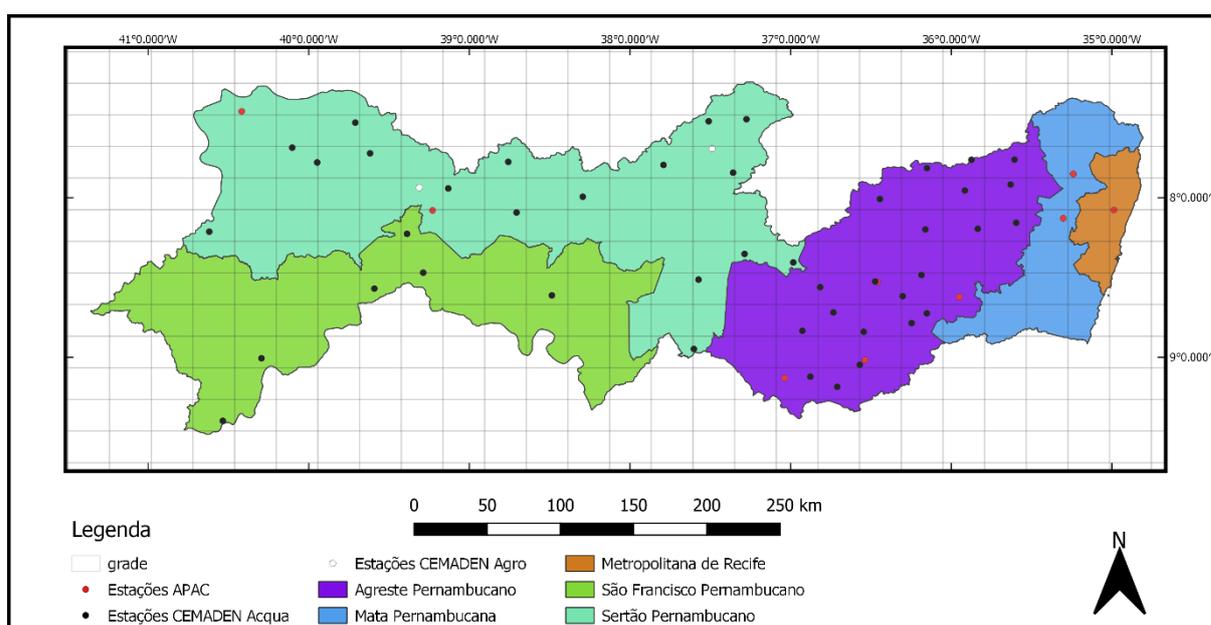
A identificação de valores discrepantes foi possível a partir do cálculo da correlação entre os dados.

O percentual de 30% considerado foi estipulado tomando como base estações pré-selecionadas de forma amostral, porém foi necessária uma análise individual para garantir que os dados estariam concentrados em um período específico, e não dispersos na faixa temporal disponibilizada pelas redes de monitoramento. Nesse contexto, estações que apresentavam longos períodos de falha foram desconsideradas. Nos casos em que apenas um período da base de dados apresentava valores discrepantes o mesmo foi removido da análise, considerando apenas um período de dados consecutivos e de no mínimo um ano, período selecionado para permitir a observação das variações anuais da umidade do solo.

3.3 DADOS SMOS

Para o presente estudo foram utilizados dados de umidade do solo ($m^3.m^{-3}$) referentes ao produto do SMOS nível L3, v003, na resolução espacial de 25 km e resolução temporal de um dia, disponibilizado gratuitamente pelo SMOS Barcelona Expert Center (SMOS BEC) em seu portal (<http://bec.icm.csic.es/data/data-access/>). A Figura 5 relaciona a grade do SMOS com as estações *in situ* da APAC e CEMADEN nas 5 mesorregiões de Pernambuco.

Figura 5 – Distribuição espacial das estações *in situ* e grade do satélite SMOS



Fonte: A autora (2021)

Para a extração dos dados de umidade do solo do SMOS o primeiro passo foi identificar o centro de pixel mais próximo da coordenada de cada estação. Em seguida, foi utilizada uma rotina em Matlab para processar a base histórica. Considerando que os dados do satélite SMOS são fornecidos em duas órbitas, ascendente e descendente, os valores de umidade do solo considerados foram obtidos a partir da união das órbitas, de modo a obter apenas uma medição diária. Conforme descrito por Souza *et al.* (2018), a união das órbitas deriva de três possíveis cenários: quando o dado foi coletado por ambas, a umidade do solo considerada é a média desses valores; quando em apenas uma das órbitas foi registrado um dado, este foi considerado; e, por fim, quando nenhuma das órbitas apresentou valor, caracterizando uma falha.

Algumas estações estavam localizadas em um mesmo pixel do SMOS, porém as análises foram conduzidas individualmente. Considerou-se o período entre 2015 a 2019, equivalente aos dados de observação das redes de monitoramento da APAC e CEMADEN.

3.4 APLICAÇÃO DO FILTRO EXPONENCIAL

De forma resumida, o filtro exponencial fundamenta-se na suposição de um equilíbrio hidrológico dentro do perfil do solo que viabiliza a mensuração da umidade do solo na zona de raiz utilizando apenas medições feitas na superfície (TOBIN *et al.*, 2017).

Para a concepção do filtro exponencial, proposto por Wagner, Lemoine e Rott (1999), um modelo de balanço hídrico simples entre duas camadas foi considerado, onde a primeira representa a porção superior do solo (w_g) detectada por sensoriamento remoto e amplamente afetada pela precipitação, evaporação e escoamento superficial, e a segunda (w_2), sem contato com a superfície. Nessa camada, o teor de água varia lentamente, dada a limitação imposta pelo volume de água que pode ser trocado com a camada superior. Assumindo que o fluxo de água entre essas duas camadas é proporcional à diferença no teor de umidade do solo entre as duas camadas, a Equação 5 é utilizada para estabelecer a conexão entre elas:

$$L \frac{dw_2(t)}{dt} = C[w_g(t) - w_2(t)] \quad (5)$$

Sendo L a profundidade da segunda camada, t o tempo e C coeficiente de pseudodifusividade que depende das propriedades do solo, constante. Considerando $T=L/C$, a integral da Equação 1 é apresentada na Equação 6:

$$w_2(t) = \frac{1}{T} \int_{-\infty}^t w_g(\tau) \exp \left[\frac{1-\tau}{T} \right] d\tau \quad (6)$$

T, medido em dias, representa uma escala de tempo da variação do teor de água no solo. De maneira geral, este é um parâmetro que substitui os processos hidrológicos, pedológicos e ecológicos envolvidos na relação entre a umidade do solo com a profundidade e em sua dinâmica temporal, tais como espessura da camada do solo, evaporação, textura e densidade (ALBERGEL *et al.*, 2008; GAO *et al.*, 2017; WAGNER; LEMOINE; ROTT, 1999).

Apesar de processos como a transpiração não serem considerados no balanço e da suposição de uma condutividade hidráulica constante, o modelo é útil para estimar o teor de umidade do solo do perfil.

A Equação 7 define o chamado *Soil Water Index* (SWI) (WAGNER; LEMOINE; ROTT, 1999):

$$SWI(t_n) = \frac{\sum_i^n m_s(t_i) e^{-\frac{(t_n-t_i)}{T}}}{\sum_i^n e^{-\frac{(t_n-t_i)}{T}}} \quad (7)$$

Onde $m_s(t_i)$ é a umidade do solo estimada por sensoriamento remoto no tempo t_i . Esta versão forneceu uma estimativa de um índice de umidade do solo, o SWI, dentro da zona radicular, e forneceu um preditor da umidade do solo na zona de raiz no tempo (t_n) (TOBIN *et al.*, 2017). Nesse sentido, t_i representa o tempo inicial da análise, quando foi obtido o dado via sensoriamento remoto, e t_n um tempo posterior, quando é calculado o teor de umidade do solo na subsuperfície.

O SWI é considerado devido à grande variabilidade das características do solo dentro da área de abrangência do satélite, que podem não ser representadas de forma precisa, por isso, a faixa dinâmica relativa da umidade do solo na zona da raiz é representada (STEFAN *et al.*, 2021). Trata-se de um indicador de tendência que varia de 0 a 1 (ALBERGEL *et al.*, 2008).

Ainda segundo Wagner, Lemoine e Rott (1999), o valor de T é determinado a partir do cálculo da correlação entre o SWI e as medições *in situ* para as camadas 0-20 cm e 0-100 cm, limitado entre 0 e 100 dias. Para os autores, um valor de T entre 15 e 30 dias fornece uma estimativa satisfatória, porém outros valores de T podem apresentar bons resultados. O objetivo é identificar o valor de T que resulta na maior

correlação dos dados *in situ* e o SWI calculado. Sendo assim, a precisão varia em função de T, e cada local possui um T ótimo.

Segundo Albergel *et al.* (2008), o T ótimo varia com a profundidade do solo, mas não foi observada ligação entre esse parâmetro e as profundidades do solo e do clima. Para Ford, Harris e Quiring (2014), a precisão das estimativas de umidade do solo da zona de raiz são muito sensíveis ao parâmetro T quando as condições de umidade do solo próximas à superfície são extremamente secas ou úmidas.

Wagner, Lemoine e Rott (1999) desenvolveram o Filtro Exponencial, e Albergel *et al.* (2008) refinaram a abordagem com uma versão recursiva, capaz de fornecer uma estimativa de um índice de umidade do solo, o SWI, dentro da zona radicular. A forma recursiva foi definida por Stroud (1999), e está menos suscetível à perda de dados, além de facilitar a implementação do Filtro. Aplicada à umidade do solo, a forma recursiva é apresentada na Equação 8:

$$SWI_n = SWI_{n-1} + K_n(m_s(t_n) - SWI_{n-1}) \quad (8)$$

O fator de ganho K varia entre 0 e 1, e seu valor no tempo t_n é dado pela Equação 9:

$$K_n = \frac{K_{n-1}}{K_{n-1} + e^{\frac{-(t_n - t_{n-1})}{T}}} \quad (9)$$

Para a inicialização do filtro exponencial, adota-se $K_1 = 1$ e $SWI_1 = m_s(t_1)$. Nesse contexto, os produtos do SMOS correspondem aos valores de m_s .

De forma geral, a forma recursiva melhor se adapta ao cenário dos dados, visto que a atualização do SWI_n depende apenas da disponibilidade de um novo dado de satélite m_s e do intervalo de tempo desde a observação anterior (ALBERGEL *et al.*, 2008).

O filtro exponencial em sua forma recursiva foi aplicado para cada uma das estações da rede de monitoramento da APAC e do CEMADEN – para cada coordenada geográfica, os respectivos dados do SMOS para o mesmo período foram extraídos. Estes, por sua vez, foram utilizados para o cálculo do SWI para cada dia do período de análise. Para as estações do CEMADEN do tipo Acqua, o filtro foi aplicado à profundidade de 20 cm. Para as estações do tipo Agro e para as estações da APAC, a aplicação aconteceu nas profundidades de 20 e 40 cm.

3.4.1 Análises estatísticas

O coeficiente de correlação de Pearson estabelece a distribuição de um sistema probabilístico, a qual representa o nível de relação entre duas variáveis (HELSEL; HIRSCH, 2002). O cálculo do coeficiente é dado pela Equação 10:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (10)$$

Onde x e y correspondem aos diferentes dados que serão comparados e n é o número de valores da série temporal. O coeficiente de correlação de Pearson varia de -1 a 1, sendo esses valores extremos indicativos de uma correlação perfeita, enquanto o valor zero indica a ausência de relação linear entre as variáveis (FILHO; SILVA JÚNIOR, 2009). Quanto mais próximo da unidade, seja ela positiva ou negativa, maior é a correlação entre os dados.

O Root Mean Square Error (RMSE) é utilizado para a comparação entre os dados observados e estimados a partir do cálculo da diferença entre esses valores. Trata-se de uma medida do desvio médio padrão e, portanto, mede a acurácia entre os valores observados e medidos pelos satélites (Equação 11):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}} \quad (11)$$

Para o RMSE, a proximidade de zero evidencia uma maior acurácia entre os dados.

A análise do desempenho do filtro exponencial foi realizada a partir da comparação entre os valores de SWI e os dados *in situ* da respectiva estação do CEMADEN ou APAC. Para cada estação, o valor final do parâmetro T do filtro exponencial foi aquele em que o maior valor do coeficiente de correlação de Pearson (r) com os dados *in situ* foi encontrado, bem como o menor RMSE.

3.4.2 Comparação do filtro exponencial com os dados das estações *in situ*

Para cada estação da APAC e do CEMADEN, os dados do pixel do SMOS correspondente foram extraídos. Considerando que o intervalo de dados das estações *in situ* é inferior ao do SMOS, os dados foram equiparados para um mesmo período –

de 2015 a 2019 para a maior parte das estações, com exceção daquelas com falhas ou discrepâncias identificadas.

O SWI diário foi calculado a partir do valor de umidade do solo estimada por sensoriamento remoto. Para avaliar a comparação entre os dados observados *in situ*, correspondente às 55 estações de umidade do solo da APAC e do CEMADEN, e o SWI calculado através das estimativas do SMOS, cujos dados correspondem ao pixel que engloba cada estação, foram realizadas as análises estatísticas pelo coeficiente de correlação r de Pearson e RMSE.

A análise de desempenho foi realizada para a profundidade de 20 cm, comum à todas as estações *in situ*, e para a profundidade de 40 cm, comum às estações da APAC e CEMADEN do tipo Agro.

Os valores de umidade do solo medidos pelo SMOS, sem a aplicação do filtro, foram comparados com os dados das redes *in situ* nas profundidades de 20 e 40 cm para avaliar os cenários e a efetividade de sua aplicação. Considerando a abrangência da cobertura espacial dos satélites, e a necessidade de entender o comportamento do perfil de solo principalmente para a aplicação de modelos hidrológicos, tal análise busca avaliar se de fato a aplicação do filtro apresenta benefícios em relação aos dados originais.

Como os satélites que operam na banda L registram a umidade do solo nos primeiros centímetros do solo, não foi realizada neste trabalho a comparação entre os dados do SMOS e os registros das redes de observação da APAC e CEMADEN na profundidade de 10 cm – a validação desses dados foi realizada por Souza (2019), utilizando 116 estações.

3.4.3 Comparação do filtro exponencial com o GLDAS-Noah e GLDAS-CLSM

Com o objetivo de analisar o desempenho de modelos globais de umidade do solo, as análises estatísticas também foram utilizadas na comparação desses dados com a umidade do solo capturada pelo SMOS e com os valores de SWI do filtro exponencial. O uso de diferentes fontes com dados de umidade do solo tem sido uma alternativa explorada com sucesso a exemplo de Zeri et al. (2021).

Neste trabalho, foi utilizado o GLDAS em sua versão número 2 (GLDAS-2). Essa versão possui três componentes: GLDAS-2.0, GLDAS-2.1 e GLDAS-2.2. Para a

comparação, foram escolhidos dois componentes. O primeiro, GLDAS Noah Land Surface Model L4 mensal com resolução de 0.25x0.25 graus V2.1 (GLDAS_NOAH025_M), foi gerado a partir da simulação com saída mensal dos dados GLDAS-2.1 Noah simulados com o Noah Model 3.6 no modelo Land Information System (LIS) Versão 7 (BEAUDOING; RODELL, 2020). Foram consideradas apenas as duas camadas superiores. O segundo é o GLDAS Catchment Land Surface Model L4 diário com resolução de 0.25x0.25 graus (GLDAS_CLSM025_DA1_D), simulado com o Catchment-F2.5 no LIS versão 7 e processado para dados mensais (LI *et al.*, 2020).

Três análises distintas foram realizadas: a comparação entre os dados do SMOS e os produtos dos dois modelos referentes aos primeiros centímetros de solo, correspondentes aos perfis de 0 a 10 cm de profundidade no modelo Noah e 0 a 2 cm do modelo Catchment; comparação entre o SWI e os produtos de umidade do solo do perfil de 10 a 40 cm do modelo Noah; e comparação entre o SWI e os produtos da zona de raiz do modelo Catchment (0 – 100 cm). A coordenada de centro de pixel do SMOS referente a cada estação *in situ* já havia sido identificada. A partir delas foi identificado o centro de pixel mais próximo correspondente a cada um dos dois modelos.

O intervalo de tempo considerado na análise compreende o período entre 2015 e 2019. Para a comparação, a média mensal da umidade do solo foi calculada para as estações *in situ* e para os dados do SMOS.

4 RESULTADOS E DISCUSSÃO

Nesse capítulo são apresentados e discutidos os resultados encontrados na pesquisa, separados em duas etapas. As análises referentes à primeira etapa foram realizadas a partir das comparações realizadas entre o SWI, calculado pelo filtro exponencial aplicado aos dados de umidade do solo do SMOS, e as estações *in situ* das redes de observação da APAC e CEMADEN. A segunda etapa se refere à comparação entre o SWI e os produtos de umidade do solo dos modelos GLDAS Noah e Catchment (CLSM). Em ambas as etapas, as análises incluem ainda a comparação entre os dados do SMOS antes da aplicação do filtro e os mesmos produtos, com o objetivo de avaliar a efetividade da aplicação do filtro exponencial. Considerando as profundidades de 20 e 40 cm das medições das estações *in situ*, as análises foram realizadas separadamente para cada uma delas.

4.1 COMPARAÇÃO ENTRE O FILTRO EXPONENCIAL, SMOS E ESTAÇÕES *IN SITU*

Para a análise e validação do filtro exponencial aplicado aos dados do SMOS, a abordagem pixel-estação, conforme descrita por Souza *et al.* (2018), foi utilizada: para cada estação *in situ* da APAC e do CEMADEN, os dados do SMOS do respectivo pixel foram obtidos e utilizados para o cálculo do SWI do filtro exponencial. O SWI calculado é então comparado com as observações *in situ* de umidade do solo a 20 e 40 cm e, para cada uma das estações, o parâmetro T foi encontrado a partir da aplicação do coeficiente de correlação de Pearson e do RMSE entre esses valores *in situ* – o T ótimo é aquele em que é obtida a maior correlação e o menor RMSE. Foi considerado um intervalo de tempo diário. Conforme indicado por Albergel *et al.* (2008), as observações locais de umidade do solo em profundidades variando de 20 cm a 50 cm estão significativamente correlacionadas à umidade do solo da zona da raiz integrada ao longo de todo o perfil.

As estatísticas foram utilizadas também na comparação entre os dados do SMOS sem a aplicação do filtro e as estações *in situ*, com o objetivo de comparar cenários e avaliar a performance da aplicação do filtro exponencial para os dados do estado de Pernambuco. Para uma melhor organização e visualização da análise, as estações foram agrupadas por mesorregiões: Metropolitana de Recife, Mata, Agreste,

Sertão do São Francisco e Sertão Pernambucano, e para as diferentes profundidades da observação *in situ*: US2 e US3, correspondendo à profundidade de 20 e 40 cm, respectivamente.

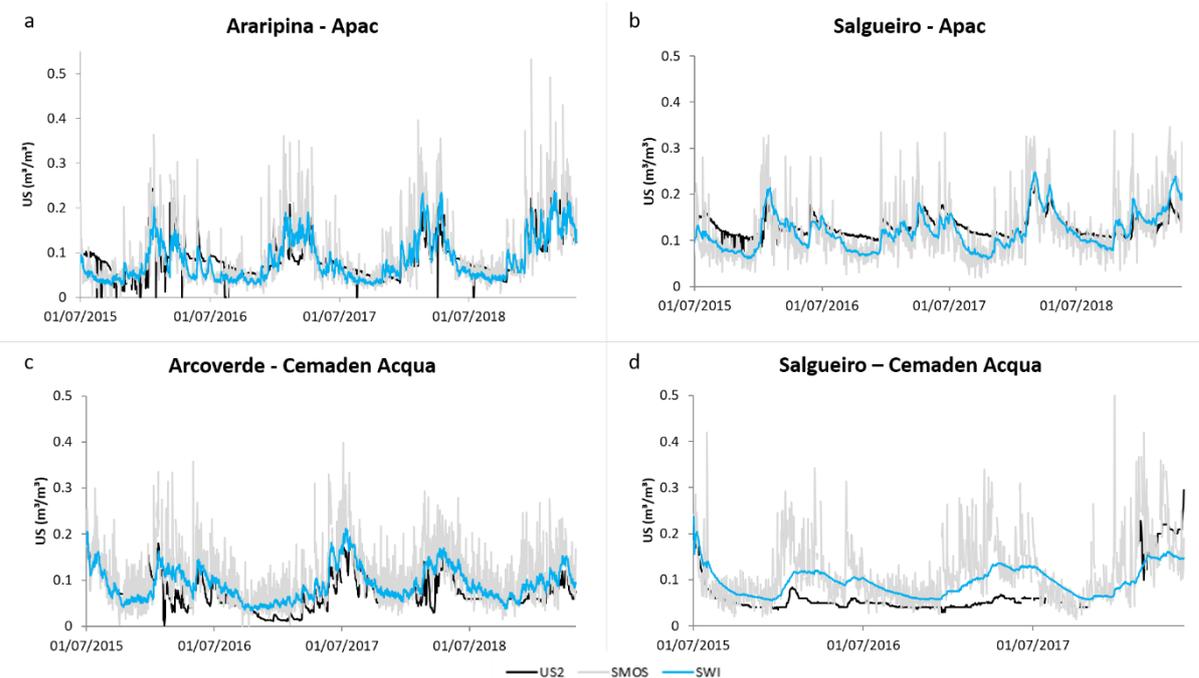
4.1.1 Comparação entre SWI, SMOS e US2

Para a mesorregião do Sertão Pernambucano, 21 estações foram analisadas. Para a estação Araripina, o coeficiente r de Pearson entre a estação *in situ* e o SWI foi de 0,82 e RMSE de 0,03, com T igual a 5,4 dias (Figura 6a). Sem a aplicação do filtro, a correlação do SMOS com a mesma estação foi de 0,72 e RMSE de 0,062 – um r 14% menor e RMSE 50% maior. Similarmente, a estação Salgueiro (APAC) apresentou correlação r de 0,78 na comparação com o SWI (Figura 6b), contra um r de 0,52 na comparação apenas com o SMOS, um incremento de 51%.

Já para a estação Salgueiro da rede de observação do CEMADEN (Acqua), o coeficiente de correlação entre US2 e SWI chegou a 0,71 (Figura 6d), 65% maior em relação ao r obtido na comparação entre o SMOS e US2, 0,43, e o RMSE foi 45% menor no primeiro cenário em comparação com o segundo, chegando a 0,047. Na estação Arcoverde, o coeficiente r entre os dados *in situ* e o SWI foi de 0,75 (Figura 6c), contra 0,59 sem sua aplicação, refletindo um incremento de 27% no cenário de aplicação do filtro.

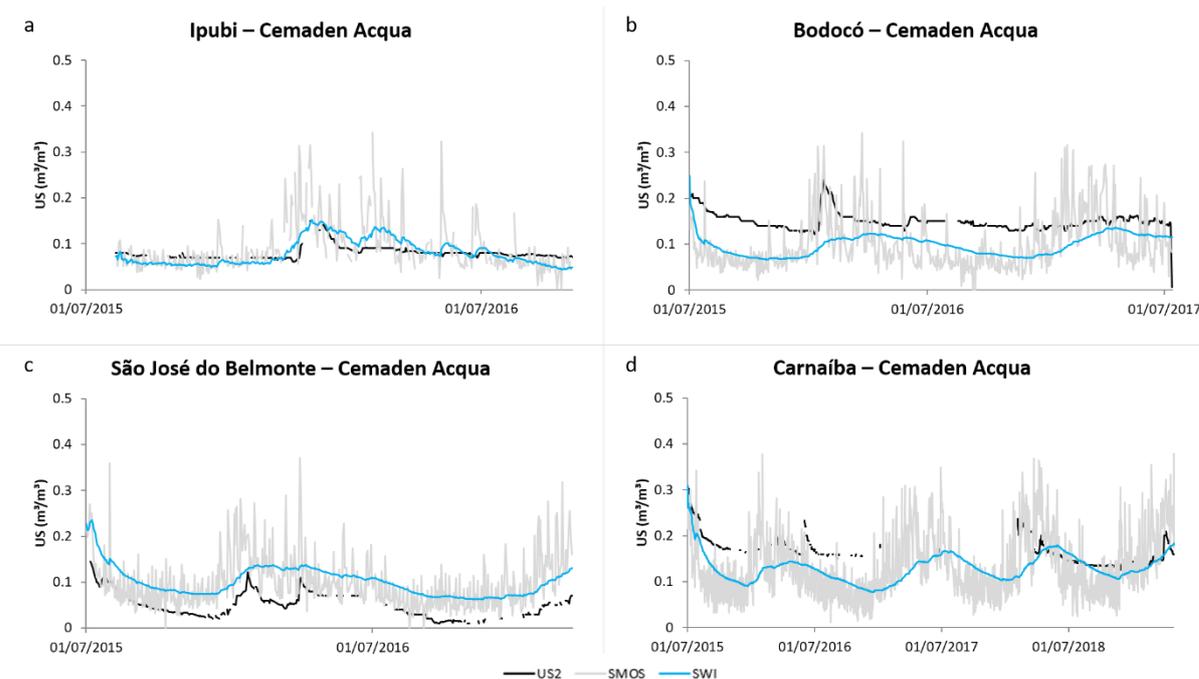
Os maiores incrementos no coeficiente de correlação r foram observados para as estações Ipubi, Bodocó, São José do Belmonte e Carnaíba (Figura 7): 117%, 208%, 102% e 112%, respectivamente. Na estação Ipubi, a correlação aumentou de 0,36, usando dados do SMOS na comparação com US2, para 0,78 usando o SWI do SMOS com o US2, cenário este que também resultou em uma redução de 67% no RMSE, saindo de 0,058 para 0,019. Para São José do Belmonte, os coeficientes r encontrados foram de 0,45 para 0,91 para o primeiro e segundo cenários, respectivamente, mostrando ainda redução do RMSE de 0,072 para 0,039. Para as quatro estações, a redução média do RMSE foi de 47% após a aplicação do filtro exponencial.

Figura 6 – Comparação da umidade do solo obtida *in situ*, pelo satélite SMOS e SWI para as estações Araripina-APAC (a); Salgueiro – APAC (b); Arcoverde – Acqua (c); e Salgueiro – Acqua (d)



Fonte: A autora (2021)

Figura 7 – Comparação da umidade do solo obtida *in situ*, pelo satélite SMOS e SWI para as estações Ipubi - Acqua (a); Bodocó - Acqua (b); São José do Belmonte – Acqua; e Carnaíba – Acqua (d)



Fonte: A autora (2021)

A Tabela 1 mostra o resumo dos resultados para as demais estações do Sertão Pernambucano. Para todas elas, as correlações r entre os dados de umidade do solo *in situ* e o SWI do SMOS foram superiores aos valores da correlação r calculados entre US2 e o SMOS sem a aplicação do filtro. Similarmente, os valores de RMSE calculados para o primeiro caso foram inferiores aos obtidos no segundo. Considerando todas as estações, a correlação média foi de 0,66 e o RMSE médio de 0,054 na comparação do SWI do SMOS com US2. Utilizando apenas o SMOS, sem o filtro, a correlação e o RMSE médios foram de 0,47 e 0,077, respectivamente.

Tabela 1 – Visão geral dos resultados de T, r e RMSE obtidos para a Mesorregião do Sertão Pernambucano

Município	Lat	Long	Rede	SWI e US2			SMOS e US2	
				T	r	RMSE	r	RMSE
Araripina	-7.46	-40.42	APAC	5.42	0.82	0.029	0.72	0.062
Arcoverde	-8.41	-36.98	CE Acqua	8.52	0.75	0.034	0.59	0.066
Bodocó	-7.78	-39.95	CE Acqua	100.00	0.42	0.056	0.14	0.077
Carnaíba	-7.79	-37.79	CE Acqua	100.00	0.57	0.038	0.27	0.076
Exu	-7.53	-39.71	CE Acqua	6.25	0.76	0.036	0.59	0.057
Granito	-7.72	-39.62	CE Acqua	4.29	0.35	0.093	0.30	0.099
Ibimirim	-8.51	-37.57	CE Acqua	6.91	0.70	0.043	0.42	0.061
Iguaraci	-7.84	-37.36	CE Acqua	73.65	0.40	0.102	0.25	0.120
Ingazeira	-7.69	-37.49	CE Agro	3.88	0.73	0.068	0.63	0.080
Ipubi	-7.69	-40.10	CE Acqua	17.95	0.78	0.019	0.36	0.058
Manari	-8.95	-37.60	CE Acqua	18.97	0.72	0.045	0.53	0.069
Mirandiba	-8.09	-38.71	CE Acqua	70.21	0.36	0.120	0.21	0.130
Salgueiro	-8.08	-39.23	APAC	12.86	0.78	0.028	0.52	0.052
Salgueiro	-7.94	-39.13	CE Acqua	51.86	0.71	0.047	0.43	0.085
Santa Filomena	-8.21	-40.62	CE Acqua	5.36	0.87	0.048	0.72	0.055
São José do Belmonte	-7.77	-38.76	CE Acqua	52.11	0.91	0.039	0.45	0.072
São José do Egito	-7.51	-37.27	CE Acqua	4.75	0.74	0.050	0.67	0.078
Serra Talhada	-7.99	-38.29	CE Acqua	4.72	0.82	0.040	0.68	0.054
Serrita	-7.94	-39.31	CE Agro	4.37	0.76	0.060	0.68	0.077
Sertania 2	-8.35	-37.29	CE Acqua	13.01	0.35	0.073	0.22	0.094
Tabira	-7.52	-37.51	CE Acqua	10.59	0.63	0.064	0.47	0.093

O T ótimo variou entre 3,9 e 100 dias – nos critérios para obtenção desse parâmetro, definiu-se um intervalo possível entre 0 e 100 dias. A definição da limitação acima foi baseada na análise realizada por Wagner, Lemoine e Rott (1999), com o objetivo de analisar o impacto dos valores de T no coeficiente de correlação e RMSE. Os autores variaram o parâmetro entre 0 e 100 e observaram que a correlação

máxima foi obtida para T igual a 15 para a camada de 0-20 cm e T igual a 20 dias para a camada 0-100 cm. Para o RMSE, observou-se que os números mais altos foram obtidos para os menores valores de T e decresceram conforme o parâmetro T foi sendo elevado, até atingir a correlação máxima – a partir daí, permaneceu sem grandes alterações. Segundo os autores, tais resultados mostram que a escolha de T entre cerca de 15 dias e 30 dias é a melhor opção, ainda que alguns outros valores de T tenham melhor desempenho; valores mais altos de T não devem ser usados porque mesmo que os valores médios de SWI reflitam as condições climáticas, as informações sobre as mudanças temporais de umidade do solo são impactadas.

No estudo conduzido por Calvet (2008), para cada estação, as observações da umidade do solo a uma profundidade de 5 cm foram utilizadas para calcular o SWI, o qual foi comparado com as observações de umidade do solo a 30 cm. Foram assumidos valores de T até 40 dias. Os valores de T ótimo variaram de 1 a 23 dias, com média de 6 dias. Com o objetivo de testar a sensibilidade do filtro exponencial por meio de mudanças no parâmetro T, o valor médio foi definido para todas as estações, e foi observado uma baixa sensibilidade a essas mudanças nas estatísticas calculadas.

Nesse contexto, foi realizada análise da variação da correlação e do RMSE adotando três diferentes valores de T: valor de 8,5 dias, definido a partir da média dos valores de T obtidos e menores que 20 dias; igual a 14 dias, conforme encontrado por Calvet (2008); e igual a 20 dias, de acordo com as definições de Wagner, Lemoine e Rott (1999). Adicionalmente, para as estações onde o T encontrado foi superior a 20 dias, foi simulado o cenário de um T limite de 40 dias, com o objetivo de entender se haveria mudanças significativas nas estatísticas. O resultado está apresentado na Tabela 2.

Em média, a correlação r para os valores de T igual a 8,5, 14 e 20 dias foi de 0,62, 0,62 e 0,61, e o RMSE 0,056, 0,055 e 0,055, respectivamente. De maneira geral, o melhor resultado foi obtido para o T de 8,5 dias, dado que a comparação entre as correlações do SWI e US2 versus a do SMOS e US2 mostrou apenas incrementos – evidenciando o benefício da aplicação do filtro exponencial. Para T=14 e T=20, algumas estações não apresentaram incremento na correlação ou ainda foi observada redução em comparação ao cenário do SMOS (São José do Egito e Serrita). O RMSE, por sua vez, não apresentou variações consideráveis em nenhum dos três cenários.

Para o quarto cenário, T=40, considerando esse valor para as estações onde o T foi superior à 40 e mantendo os demais valores de T ótimos, a correlação média foi de 0,66, similar ao cenário original (considerando todos os T ótimos). O RMSE também foi o mesmo, igual a 0,054.

Assim, entende-se que os valores de T podem ser limitados a 40, garantindo a manutenção das características de mudanças temporais da umidade do solo. Essa premissa foi considerada para todas as mesorregiões.

Tabela 2 – Análise da variação da correlação e do RMSE adotando diferentes valores de T para a Mesorregião do Sertão Pernambucano

Município	SWI e US2			T = 8.5		T = 14		T = 20		T = 40	
	T	r	rmse	r	rmse	r	rmse	r	rmse	r	rmse
Araripina	5.42	0.82	0.029	0.80	0.031	0.78	0.031	0.77	0.031	-	-
Arcoverde	8.52	0.75	0.034	0.75	0.034	0.74	0.034	0.74	0.034	-	-
Bodocó	100.00	0.42	0.056	0.33	0.062	0.38	0.060	0.40	0.059	0.42	0.057
Carnaíba	100.00	0.57	0.038	0.42	0.056	0.45	0.053	0.47	0.050	0.51	0.044
Exu	6.25	0.76	0.036	0.76	0.034	0.74	0.033	0.71	0.032	-	-
Granito	4.29	0.35	0.093	0.34	0.092	0.32	0.092	0.30	0.092	-	-
Ibimirim	6.91	0.70	0.043	0.70	0.043	0.67	0.043	0.63	0.043	-	-
Iguaraci	73.65	0.40	0.102	0.32	0.108	0.34	0.106	0.36	0.104	0.38	0.102
Ingazeira	3.88	0.73	0.068	0.71	0.066	0.69	0.065	0.67	0.064	-	-
Ipubi	17.95	0.78	0.019	0.72	0.023	0.77	0.020	0.78	0.019	-	-
Manari	18.97	0.72	0.045	0.70	0.047	0.72	0.046	0.72	0.045	-	-
Mirandiba	70.21	0.36	0.120	0.30	0.121	0.31	0.120	0.32	0.120	0.35	0.119
Salgueiro (APAC)	12.86	0.78	0.028	0.77	0.030	0.78	0.027	0.77	0.026	-	-
Salgueiro (Acqua)	51.86	0.71	0.047	0.60	0.054	0.63	0.052	0.66	0.050	0.71	0.048
Santa Filomena	5.36	0.87	0.048	0.86	0.047	0.82	0.047	0.78	0.047	-	-
São José do Belmonte	52.11	0.91	0.039	0.78	0.043	0.83	0.041	0.86	0.041	0.90	0.039
São José do Egito	4.75	0.74	0.050	0.73	0.049	0.69	0.050	0.65	0.051	-	-
Serra Talhada	4.72	0.82	0.040	0.80	0.039	0.77	0.039	0.74	0.040	-	-
Serrita	4.37	0.76	0.060	0.73	0.060	0.67	0.061	0.62	0.062	-	-
Sertania 2	13.01	0.35	0.073	0.35	0.073	0.35	0.073	0.34	0.073	-	-
Tabira	10.59	0.63	0.064	0.63	0.064	0.63	0.065	0.62	0.065	-	-

Para a mesorregião Sertão de São Francisco, a maior correlação r entre o SWI e dados da estação *in situ* foi obtida para estação Floresta (Figura 8a), local onde também foi observada a maior diferença entre correlações: o r entre SWI do SMOS e US2 foi de 0,67, enquanto para o SMOS e US2 o r obtido foi de 0,14 – um incremento de 477%. Para a estação Cabrobó (CEMADEN Acqua) (Figura 8b), o coeficiente r foi 37% maior para a comparação dos dados *in situ* com o SWI em relação à comparação

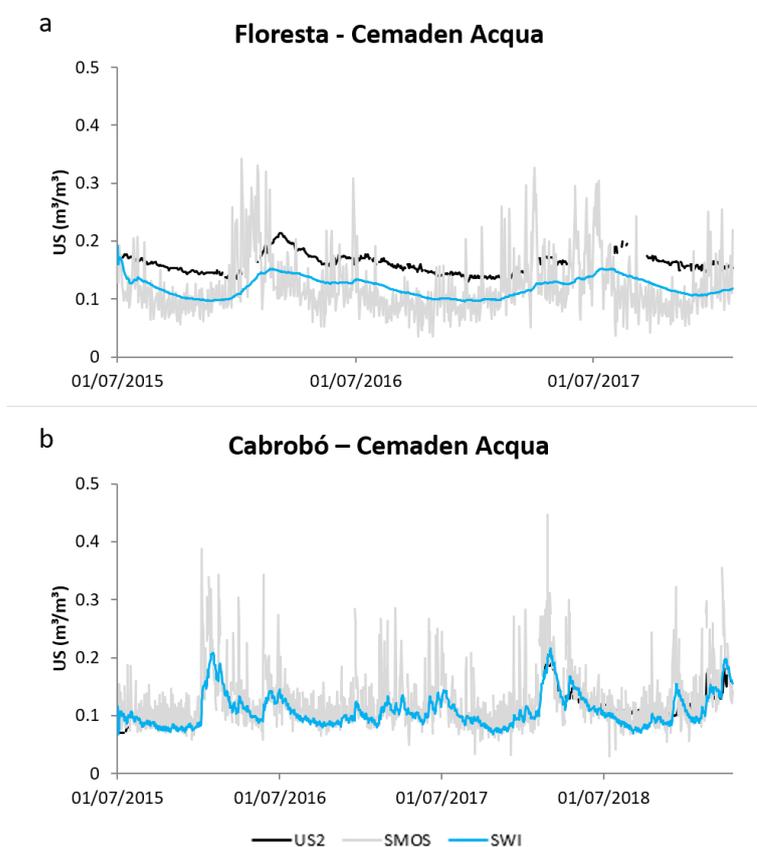
do US2 com os dados do SMOS. Além disso, a estação apresentou a maior redução de RMSE, 71%, saindo de 0,066 no segundo cenário para 0,019 no primeiro.

Desconsiderando o município de Floresta, o incremento médio na correlação na comparação entre US2 e SWI em relação ao cenário US2 e SMOS foi de 32%. Já para o RMSE, considerando todas as estações, a redução média observada foi de 36% no primeiro cenário em relação ao segundo. Os valores correspondentes estão detalhados na Tabela 3. Os valores de T ótimo variaram entre 5 e 40 dias.

Tabela 3 – Visão geral dos resultados de T, r e RMSE para o Sertão de São Francisco

Município	Lat	Long	Rede	SWI e US2			SMOS e US2	
				T	r	RMSE	R	RMSE
Cabrobó	-8.47	-39.29	CE Acqua	13.09	0.84	0.019	0.61	0.066
Floresta	-8.61	-38.49	CE Acqua	40.00	0.81	0.045	0.14	0.064
Orocó	-8.57	-39.59	CE Acqua	4.97	0.55	0.095	0.44	0.111
Petrolina1	-9.40	-40.53	CE Acqua	5.34	0.65	0.058	0.56	0.076
Petrolina3	-9.01	-40.29	CE Acqua	6.80	0.69	0.032	0.53	0.060
Terra Nova	-8.23	-39.39	CE Acqua	40.00	0.58	0.044	0.38	0.066

Figura 8 – Comparação da umidade do solo obtida *in situ*, pelo satélite SMOS e SWI para as estações Floresta - Acqua (a); e Cabrobó - Acqua (b)



Fonte: A autora (2021)

Para a mesorregião Metropolitana, apenas a estação São Lourenço da Mata foi analisada. O coeficiente r de correlação foi de 0,47 e 0,21, para a comparação dos dados *in situ* com o filtro exponencial e com o SMOS, respectivamente, evidenciando um incremento de 124% no cenário do SWI. Para o RMSE, houve uma redução de 18% após a aplicação do filtro.

Para a Zona da Mata Pernambucana, duas estações foram utilizadas na avaliação: Carpina e Vitória de Santo Antão. O r observado para a comparação entre filtro exponencial e dados *in situ* foi de 0,81 e 0,79, respectivamente; para SMOS e SWI, o coeficiente era de 0,61 e 0,62. O RMSE apresentou uma redução média de 22% no cenário do filtro exponencial.

Os dados das mesorregiões Metropolitana e Zona da Mata estão detalhados na Tabela 4.

Tabela 4 – Visão geral dos resultados de T, r e RMSE obtidos para as Mesorregiões Metropolitana do

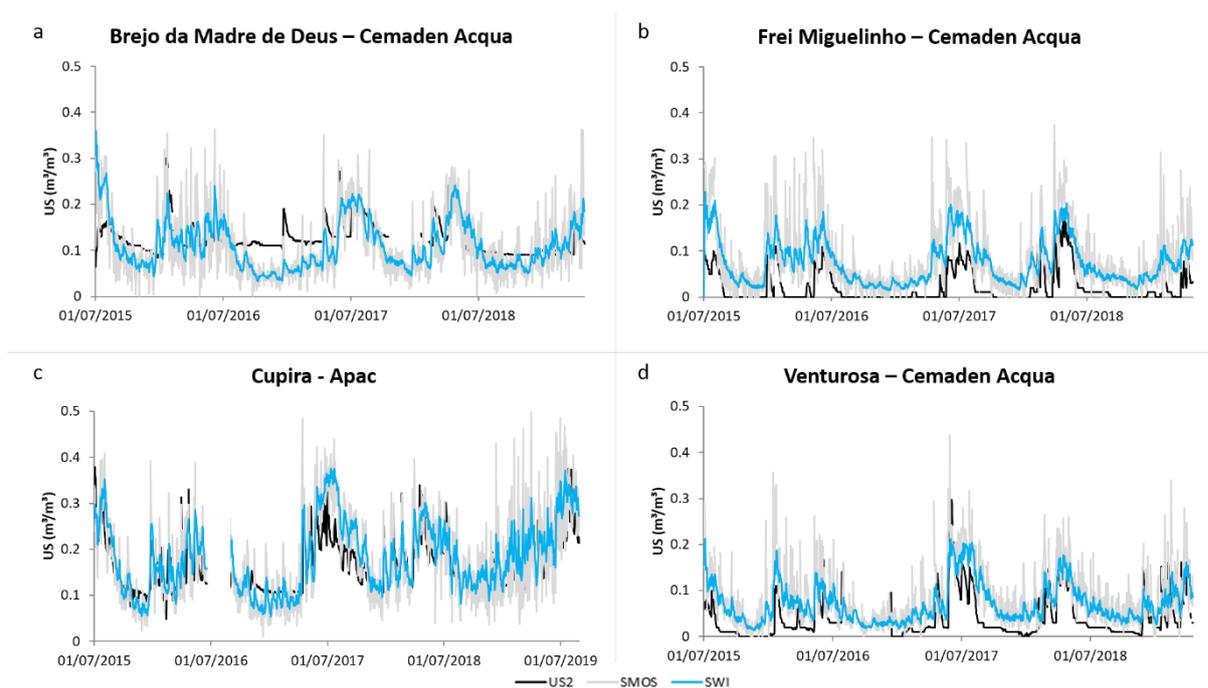
Município	Recife e Zona da Mata							
	Lat	Long	Rede	SWI e US2			SMOS e US2	
				T	r	RMSE	r	RMSE
São Lourenço da Mata	-8.08	-34.99	APAC	23.88	0.47	0.121	0.21	0.148
Carpina	-7.85	-35.24	APAC	8.66	0.81	0.056	0.61	0.069
Vitória de Santo Antão	-8.13	-35.30	APAC	6.99	0.79	0.046	0.62	0.062

A avaliação conduzida para as estações localizadas na mesorregião do Agreste Pernambucano mostrou performance similar às anteriores. O coeficiente r entre SWI e US2 observado na estação Brejo da Madre de Deus (Figura 9a) foi de 0,56 para a comparação entre o filtro exponencial e os dados *in situ*, um incremento de 30% em relação à comparação entre os dados do SMOS e os dados *in situ*, de 0,43. Comparando os dois cenários para a estação Frei Miguelinho (Figura 9b), a diferença entre os valores de r foi de 23% – uma correlação de 0,81 para o primeiro e 0,66 para o segundo cenário - e uma redução no RMSE de 26%, de 0,061 e 0,083 para o primeiro e segundo cenário, respectivamente.

Para a estação Cupira (Figura 9c), o incremento da correlação foi de 17%, saltando de 0,69, quando utilizado o SMOS, para 0,81 com o SWI. O RMSE, por sua vez, reduziu em 30% após a aplicação do filtro, chegando a 0,048. Já para a estação Venturosa (Figura 9d), os coeficientes de correlação foram de 0,64 para a comparação com o SMOS e 0,78 usando o filtro exponencial – um aumento de 22% - e redução do RMSE de 0,068 para 0,047.

De maneira geral, foi observado um incremento médio de 23% na correlação após a aplicação do filtro exponencial nos dados do SMOS, chegando a 61% em Vertente do Lério e 49% em Jurema, e uma redução média de 21% no RMSE, atingindo 45% em Taquaritinga do Norte e 43% em Iati. O parâmetro T ótimo foi de 7,36 dias em média. Desconsiderando a discrepância da estação Vertente do Lério, a média caiu para 6 dias.

Figura 9 – Comparação da umidade do solo obtida *in situ*, pelo satélite SMOS e SWI para as estações Brejo da Madre de Deus - Acqua (a); Frei Miguelinho - Acqua (b); Cupira – APAC (c); e Venturosa – Acqua (d)



Fonte: A autora (2021)

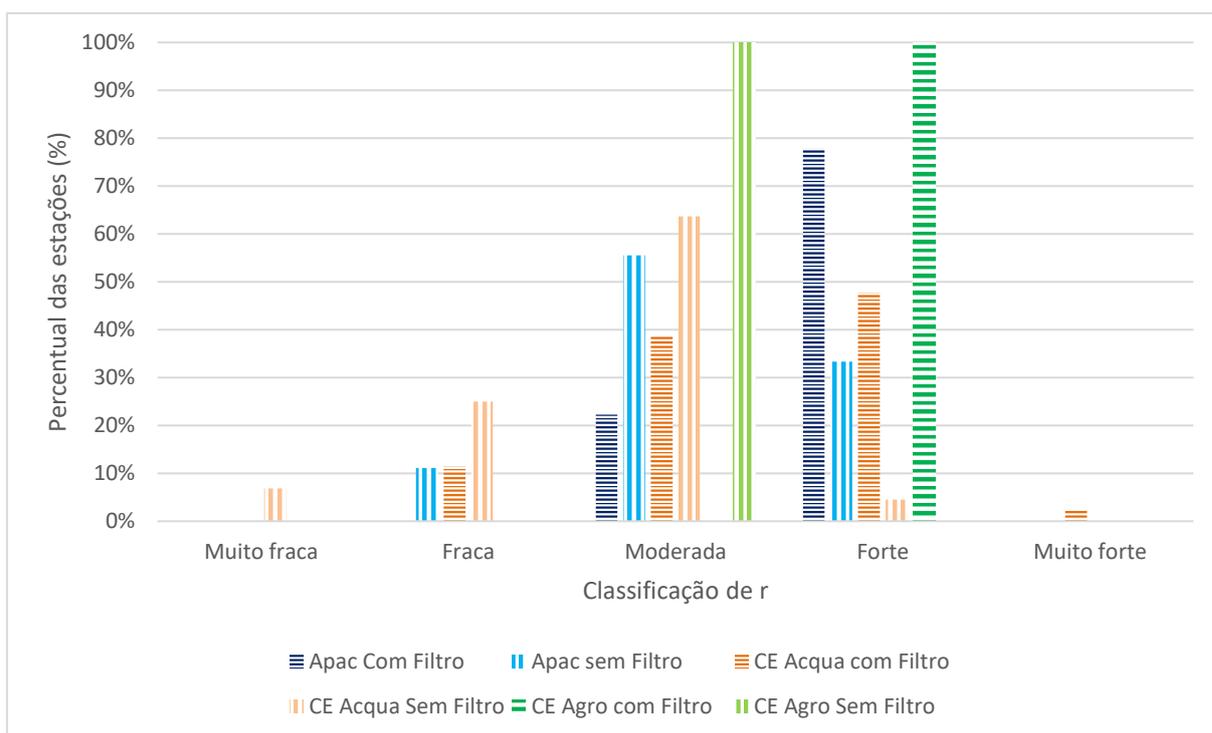
De forma geral, os diferentes valores de T impactam o comportamento da curva do SWI: à medida que aumenta o valor de T, diminui o valor do ganho Kn da Eq. 9, tornando-a menos derivativa, ou seja, formando linhas de SWI mais suaves no gráfico. O cálculo de T para cada estação é iterativo e, portanto, é difícil estabelecer uma relação matemática entre este parâmetro e os dados *in situ*. Entretanto, observa-se um padrão visual: estações *in situ* cujas medições apresentam menor perturbação temporal tendem a resultar em maiores valores de T.

Tabela 5 – Visão geral dos resultados de T, r e RMSE obtidos para o Agreste Pernambucano

Município	Lat	Long	Rede	SWI e US2			SMOS e US2	
				T	r	RMSE	r	RMSE
Águas belas	-9.13	-37.04	APAC	4.33	0.76	0.039	0.72	0.062
Altinho	-8.48	-36.19	CE Acqua	3.94	0.45	0.082	0.40	0.093
Bezerros	-8.19	-35.84	CE Acqua	5.69	0.64	0.056	0.51	0.079
Bom Conselho	-9.18	-36.71	CE Acqua	5.87	0.86	0.070	0.75	0.079
Brejão	-9.02	-36.54	APAC	5.25	0.84	0.136	0.75	0.141
Brejão	-9.05	-36.57	CE Acqua	6.76	0.81	0.078	0.68	0.090
Brejo da Madre de Deus	-8.20	-36.16	CE Acqua	5.51	0.56	0.047	0.43	0.064
Caetés	-8.72	-36.73	CE Acqua	3.14	0.41	0.090	0.36	0.095
Canhotinho	-8.79	-36.25	CE Acqua	12.63	0.45	0.088	0.34	0.100
Cupira	-8.62	-35.95	APAC	3.47	0.81	0.048	0.69	0.069
Frei Miguelinho	-7.95	-35.92	CE Acqua	7.43	0.81	0.061	0.66	0.083
Garanhuns	-8.84	-36.55	CE Acqua	6.42	0.76	0.051	0.65	0.069
Gravatá	-8.16	-35.60	CE Acqua	4.08	0.20	0.089	0.17	0.096
Iati	-9.12	-36.88	CE Acqua	6.20	0.63	0.032	0.46	0.056
Jatauba	-8.01	-36.44	CE Acqua	6.08	0.63	0.071	0.48	0.094
Jurema	-8.72	-36.15	CE Acqua	16.96	0.37	0.098	0.25	0.103
Lajedo	-8.62	-36.30	CE Acqua	3.81	0.45	0.086	0.41	0.099
Orobó	-7.76	-35.61	CE Acqua	5.58	0.73	0.076	0.62	0.086
Pedra	-8.83	-36.93	CE Acqua	4.85	0.75	0.048	0.65	0.060
Salgadinho	-7.92	-35.63	CE Acqua	3.41	0.40	0.088	0.35	0.096
São Bento do Uma	-8.53	-36.46	APAC	4.65	0.64	0.054	0.53	0.066
São Bento do Uma	-8.52	-36.47	CE Acqua	7.82	0.71	0.045	0.56	0.060
Taquaritinga do Norte	-7.81	-36.15	CE Acqua	5.04	0.70	0.038	0.59	0.069
Venturosa	-8.56	-36.82	CE Acqua	5.18	0.78	0.047	0.64	0.068
Vertente do Lério	-7.76	-35.87	CE Acqua	40.00	0.74	0.062	0.46	0.083

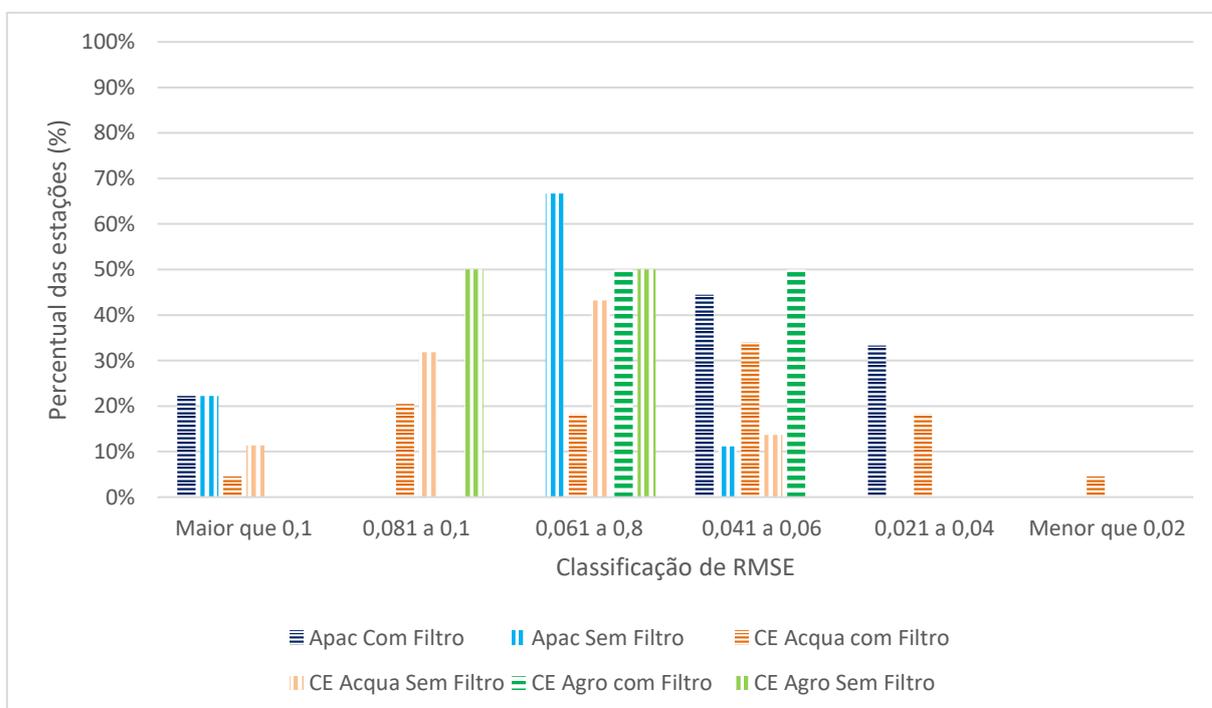
As figuras 10 e 11 abaixo sumarizam os resultados nas classificações da correlação r (correlação muito fraca: 0 - 0,19; fraca: 0,20 - 0,39; moderada: 0,40 – 0,69; forte: 0,70 – 0,89; muito forte: 0,90 – 1) e RMSE, respectivamente. Para a correlação, observa-se que para todas as estações houve incremento de classificação após a aplicação do filtro, fato que reflete na maior concentração de estações com correlação forte nesse cenário. Da mesma forma, para o RMSE, é possível notar uma maior preponderância de estações com aplicação do filtro mais à direita do gráfico, região que concentra os menores erros.

Figura 10 – Frequências de ocorrência do r de Pearson antes e depois aplicação do filtro



Fonte: A autora (2021)

Figura 11 – Frequências de ocorrência do RMSE antes e depois aplicação do filtro



Fonte: A autora (2021)

4.1.2 Comparação entre SWI do SMOS, SMOS e US3

Apenas 11 estações incluíam dados coletados na profundidade de 40 cm: Araripina, Salgueiro, Ingazeira e Serrita, da mesorregião do Sertão; São Lourenço da Mata, na região Metropolitana; Carpina e Vitória de Santo Antão, na Zona da Mata; e Águas belas, Brejão, Cupira e São Bento do Una no Agreste. Nessas estações, os mesmos cenários anteriores foram observados para a profundidade de 40 cm, e os números obtidos foram comparados com o cenário de 20 cm (Tabela 6).

Conforme esperado, dada a captura da umidade do solo nos primeiros centímetros do solo pelo SMOS, a comparação entre esses dados e US3 apresentou correlações menores do que na análise com US2 – 0,54 e 0,60, em média, respectivamente. Calculando as estatísticas na comparação entre o SWI e os dados *in situ*, observa-se que o cenário SWI e US3 apresentou maior incremento percentual na correlação em comparação com o cenário SWI e US2: em média, 41% no primeiro cenário e 30% no segundo. A correlação média, entretanto, foi maior no segundo cenário: 0,75 contra 0,71. O RMSE médio foi similar para os dois cenários, porém a maior redução percentual média foi observada no cenário com o US3, de 30%.

Tabela 6 – Visão geral dos resultados de T, r e RMSE e comparação com os dados do SMOS obtidos para todas as Mesorregiões de Pernambuco, nas profundidades de 40 e 20 cm

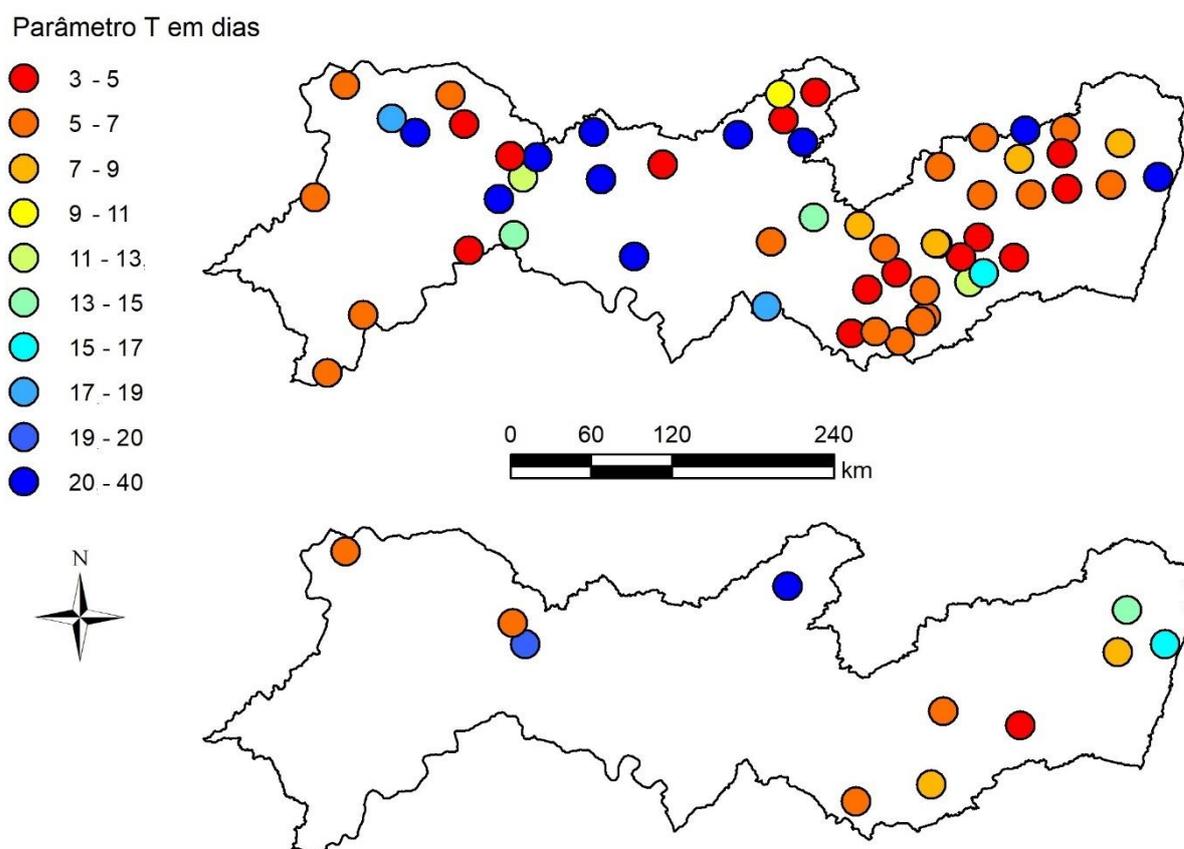
Município	Rede	SWI e US3			SMOS e US3		SWI e US2			SMOS e US2	
		T	r	RMSE	r	RMSE	T	r	RMSE	r	RMSE
Araripina	APAC	7.00	0.73	0.037	0.61	0.057	5.42	0.82	0.029	0.72	0.062
Salgueiro	APAC	20.00	0.67	0.029	0.29	0.057	12.86	0.78	0.028	0.52	0.052
Ingazeira	CE Agro	40.00	0.55	0.044	0.41	0.078	3.88	0.73	0.068	0.63	0.080
Serrita	CE Agro	6.86	0.73	0.060	0.57	0.078	4.37	0.76	0.060	0.68	0.077
São Lourenço da Mata	APAC	15.17	0.57	0.109	0.29	0.136	15.17	0.57	0.109	0.29	0.136
Carpina	APAC	13.63	0.82	0.045	0.61	0.090	13.63	0.82	0.045	0.61	0.090
Vitória de Santo Antão	APAC	7.37	0.78	0.049	0.58	0.066	7.37	0.78	0.049	0.58	0.066
Águas belas	APAC	5.68	0.77	0.039	0.69	0.063	5.68	0.77	0.039	0.69	0.063
Brejão	APAC	8.42	0.86	0.153	0.75	0.158	8.42	0.86	0.153	0.75	0.158
Cupira	APAC	3.23	0.77	0.053	0.66	0.071	3.23	0.77	0.053	0.66	0.071
São Bento do Una	APAC	5.24	0.61	0.071	0.49	0.082	5.24	0.61	0.071	0.49	0.082

Observa-se, portanto, que a aplicação do filtro também apresentou consideráveis benefícios no coeficiente r e no RMSE.

Na Figura 12 abaixo é possível observar a espacialização do parâmetro T no mapa do Estado. Para a profundidade de 20 cm, há uma tendência de valores mais

altos no Semiárido. Uma explicação razoável é que o baixo índice pluviométrico, associado à alta evapotranspiração da região, ocasiona baixa variabilidade na umidade das camadas mais profundas do solo, levando à menores perturbações nos dados *in situ* e, portanto, a valores maiores para o parâmetro T. É importante reforçar que o parâmetro T é calculado iterativamente para cada estação e profundidade.

Figura 12 – Espacialização do parâmetro T calculado para a profundidade de 20 cm (mapa superior) e 40 cm (mapa inferior)



Fonte: A autora (2021)

4.2 COMPARAÇÃO ENTRE O FILTRO EXPONENCIAL, SMOS E MODELOS DE SUPERFÍCIE TERRESTRE

Para a análise entre o SWI e os modelos Noah-LSM e Catchment-LSM, o resultado obtido pelo filtro exponencial para cada estação foi selecionado e comparado com os dados resultantes dos modelos. Para o Noah, os dados estão disponíveis de 0-10 cm (SM10) e 10-40 cm (SM1040). Para o Catchment, 0-2 cm (CLSMSUR) e 0-100 cm (CLSMRZ). Foi utilizado o SWI calculado para as

profundidades de 20 e 40 cm. No total, 4 comparações foram conduzidas para cada modelo: entre os dados do SMOS e as duas profundidades do modelo; SWI para 20 cm (SWI2) e maior profundidade dos modelos; e SWI para 40 cm (SWI3) e maior profundidade dos modelos. Novamente, visando facilitar a organização e visualização da análise, as estações foram agrupadas por mesorregiões: Zona da Mata, Agreste, Sertão do São Francisco e Sertão Pernambucano. Para a região Metropolitana, os dados do GLDAS não estavam disponíveis.

Considerando que o SMOS fornece a umidade do solo nos primeiros centímetros, espera-se que a comparação entre SMOS, SM10 e CLSMSUR forneça maiores correlações. Já o SWI representa a umidade do solo na subsuperfície (maiores profundidades) e, portanto, a expectativa é que a comparação com os dados dos modelos em suas maiores profundidades seja maior do que a comparação destes com os dados do SMOS.

Para o Sertão, as maiores correlações e os menores valores de RMSE foram encontrados para o modelo Noah LSM (Tabela 7), em relação ao Catchment (Tabela 8): em média, 0,87 para SMOS e SM10; 0,84 para SMOS e SM1040; 0,78 para SWI2 e SM1040; e 0,81 para SWI3 e SM1040. O RMSE médio obtido foi de 0,079, sendo o menor valor médio obtido para a comparação SMOS e SM10, 0,073, e o maior para SWI2 e SM1040, de 0,086. Analisando a performance para a profundidade SM1040, em 6 estações a correlação entre esse dado e o SWI2 foi maior do que a observada na comparação com SMOS: Araripina (Figuras 13a e 13b), Ingazeira, Serrita, Granito, Santa Filomena e Serra Talhada. Nas estações Exú (Figuras 14a e 14b), Ibimirim e Sertânia 2, por sua vez, a correlação do SWI2 e SM1040 foi maior do que a observada na comparação entre SMOS e SM10.

Tabela 7 – Valores de r e RMSE obtidos para a comparação do SMOS, SWI2, SWI3 e GLDAS-Noah para o Sertão Pernambucano

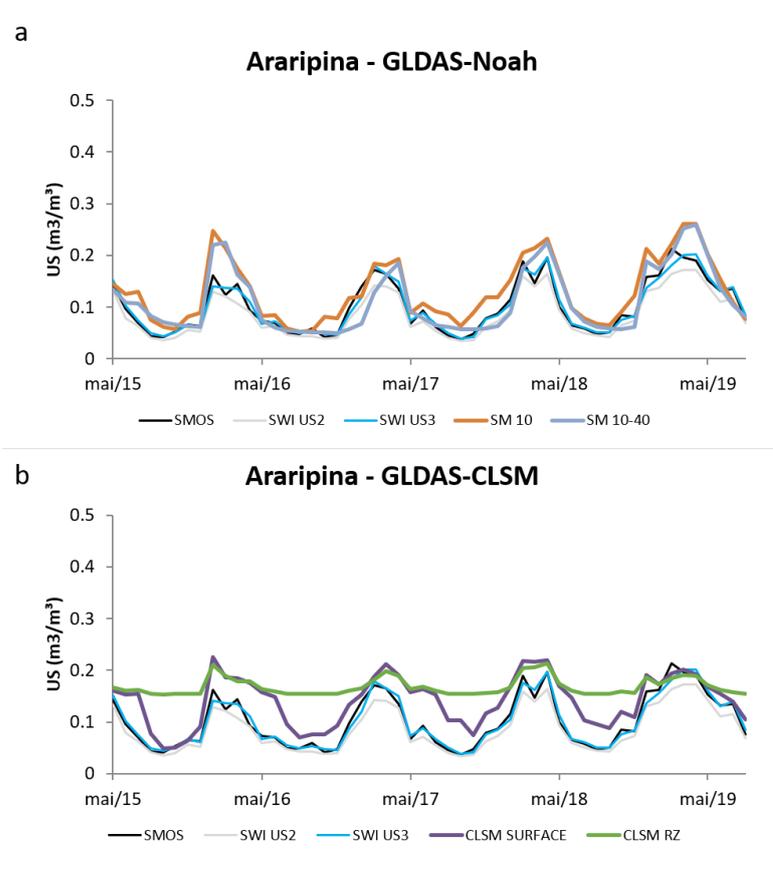
Estação	Rede	Noah LSM							
		SMOS - SM10		SMOS - SM1040		SWI2 - SM1040		SWI3 - SM1040	
		r	RMSE	R	RMSE	R	RMSE	R	RMSE
Araripina	APAC	0.92	0.037	0.86	0.033	0.90	0.039	0.90	0.030
Salgueiro	APAC	0.83	0.062	0.69	0.065	0.67	0.065	0.64	0.066
Ingazeira	CE Agro	0.93	0.084	0.89	0.099	0.91	0.099	0.85	0.103
Serrita	CE Agro	0.90	0.102	0.82	0.116	0.85	0.130	0.86	0.130
Arcoverde	CE Acqua	0.78	0.131	0.83	0.120	0.79	0.128	-	-
Bodocó	CE Acqua	0.90	0.042	0.72	0.044	0.51	0.051	-	-

<i>Carnaíba</i>	CE Acqua	0.92	0.079	0.90	0.084	0.60	0.094	-	-
<i>Exu</i>	CE Acqua	0.85	0.111	0.88	0.050	0.88	0.050	-	-
<i>Granito</i>	CE Acqua	0.87	0.062	0.83	0.122	0.87	0.135	-	-
<i>Ibimirim</i>	CE Acqua	0.79	0.056	0.83	0.045	0.83	0.045	-	-
<i>Iguaraci</i>	CE Acqua	0.93	0.084	0.89	0.099	0.69	0.107	-	-
<i>Ipubi</i>	CE Acqua	0.93	0.047	0.85	0.053	0.85	0.064	-	-
<i>Manari</i>	CE Acqua	0.54	0.115	0.59	0.103	0.44	0.105	-	-
<i>Mirandiba</i>	CE Acqua	0.92	0.070	0.85	0.079	0.71	0.083	-	-
<i>Salgueiro</i>	CE Acqua	0.92	0.046	0.86	0.051	0.79	0.068	-	-
<i>Santa Filomena</i>	CE Acqua	0.93	0.084	0.91	0.083	0.93	0.082	-	-
<i>São José do Belmonte</i>	CE Acqua	0.87	0.042	0.85	0.041	0.73	0.060	-	-
<i>São José do Egito</i>	CE Acqua	0.94	0.080	0.93	0.091	0.93	0.108	-	-
<i>Serra Talhada</i>	CE Acqua	0.89	0.075	0.88	0.080	0.89	0.081	-	-
<i>Sertania 2</i>	CE Acqua	0.85	0.049	0.86	0.042	0.86	0.055	-	-
<i>Tabira</i>	CE Acqua	0.90	0.067	0.89	0.073	0.80	0.162	-	-

Tabela 8 – Valores de r e RMSE obtidos para a comparação do SMOS, SWI2, SWI3 e GLDAS-CLSM para o Sertão Pernambucano

Estação	Rede	CLSM							
		SMOS - CSLMSUR		SMOS – CLSMRZ		SWI2 – CLSMRZ		SWI3 - CLSMRZ	
		r	RMSE	R	RMSE	R	RMSE	R	RMSE
<i>Araripina</i>	APAC	0.85	0.048	0.83	0.077	0.85	0.087	0.84	0.076
<i>Salgueiro</i>	APAC	0.85	0.081	0.79	0.160	0.68	0.159	0.62	0.159
<i>Ingazeira</i>	CE Agro	0.89	0.066	0.90	0.103	0.90	0.102	0.75	0.102
<i>Serrita</i>	CE Agro	0.87	0.108	0.86	0.176	0.86	0.189	0.85	0.189
<i>Arcoverde</i>	CE Acqua	0.89	0.165	0.86	0.212	0.85	0.221	-	-
<i>Bodocó</i>	CE Acqua	0.85	0.107	0.76	0.182	0.37	0.183	-	-
<i>Carnaíba</i>	CE Acqua	0.88	0.066	0.88	0.100	0.47	0.100	-	-
<i>Exu</i>	CE Acqua	0.88	0.128	0.85	0.190	0.84	0.190	-	-
<i>Granito</i>	CE Acqua	0.86	0.124	0.82	0.188	0.83	0.199	-	-
<i>Ibimirim</i>	CE Acqua	0.77	0.046	0.70	0.049	0.80	0.047	-	-
<i>Iguaraci</i>	CE Acqua	0.80	0.037	0.90	0.103	0.58	0.102	-	-
<i>Ipubi</i>	CE Acqua	0.83	0.110	0.90	0.192	0.79	0.202	-	-
<i>Manari</i>	CE Acqua	0.77	0.175	0.92	0.211	0.89	0.210	-	-
<i>Mirandiba</i>	CE Acqua	0.86	0.090	0.81	0.153	0.52	0.153	-	-
<i>Salgueiro</i>	CE Acqua	0.87	0.060	0.84	0.110	0.59	0.125	-	-
<i>Santa Filomena</i>	CE Acqua	0.85	0.102	0.96	0.205	0.92	0.204	-	-
<i>São José do Belmonte</i>	CE Acqua	0.83	0.018	0.77	0.027	0.68	0.029	-	-
<i>São José do Egito</i>	CE Acqua	0.91	0.104	0.89	0.162	0.90	0.177	-	-
<i>Serra Talhada</i>	CE Acqua	0.89	0.080	0.87	0.142	0.85	0.142	-	-
<i>Sertania 2</i>	CE Acqua	0.86	0.026	0.80	0.029	0.90	0.037	-	-
<i>Tabira</i>	CE Acqua	0.90	0.096	0.86	0.151	0.70	0.227	-	-

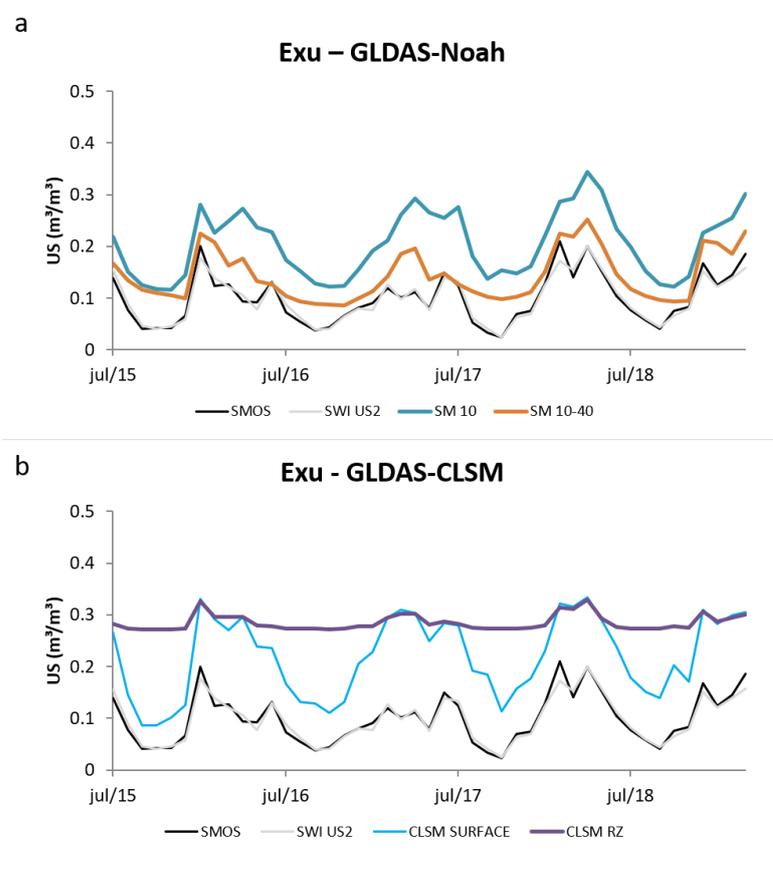
Figura 13 – Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 e 40 cm, GLDAS-Noah (a) e GLDAS-CLSM (b) para a estação Araripina (APAC)



Fonte: A autora (2021)

Para a região do Sertão de São Francisco, a correlação média obtida para as comparações foi similar para o modelo Noah LSM (Tabela 9) e Catchment (Tabela 10), igual a 0,78. O RMSE, por sua vez, foi 63% menor para o modelo Noah LSM. Apenas na estação Petrolina 1 (Figura 15) a correlação entre SWI2 e SM1040 foi maior do que a observada nos demais cenários. Na maioria das estações a correlação entre SMOS e SM10 foi a maior dentre os três cenários.

Figura 14 – Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 cm, GLDAS-Noah (a) e GLDAS-CLSM (b) para a estação Exu (CEMADEN Acqua)

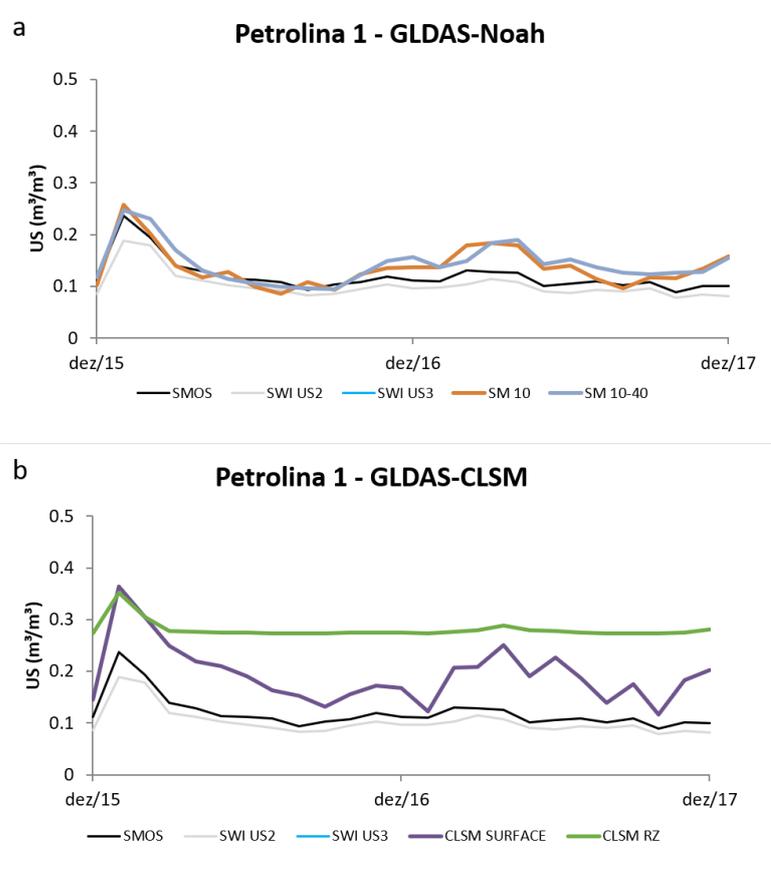


Fonte: A autora (2021)

Tabela 9 – Valores de r e RMSE obtidos para a comparação do SMOS, SWI2 e GLDAS-Noah para o Sertão de São Francisco

Estação	Rede	Noah LSM					
		SMOS - SM10		SMOS - SM1040		SWI2 - SM1040	
		r	RMSE	R	RMSE	R	RMSE
Cabrobó	CE Acqua	0.82	0.024	0.67	0.031	0.73	0.053
Floresta	CE Acqua	0.87	0.058	0.78	0.083	0.64	0.085
Orocó	CE Acqua	0.83	0.025	0.72	0.026	0.79	0.049
Petrolina1	CE Acqua	0.81	0.028	0.83	0.031	0.84	0.046
Petrolina3	CE Acqua	0.84	0.043	0.85	0.045	0.84	0.059
Terra Nova	CE Acqua	0.85	0.059	0.69	0.064	0.63	0.082

Figura 15 – Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 e 40 cm, GLDAS-Noah (a) e GLDAS-CLSM (b) para a estação Petrolina 1 (CEMADEN Acqua)



Fonte: A autora (2021)

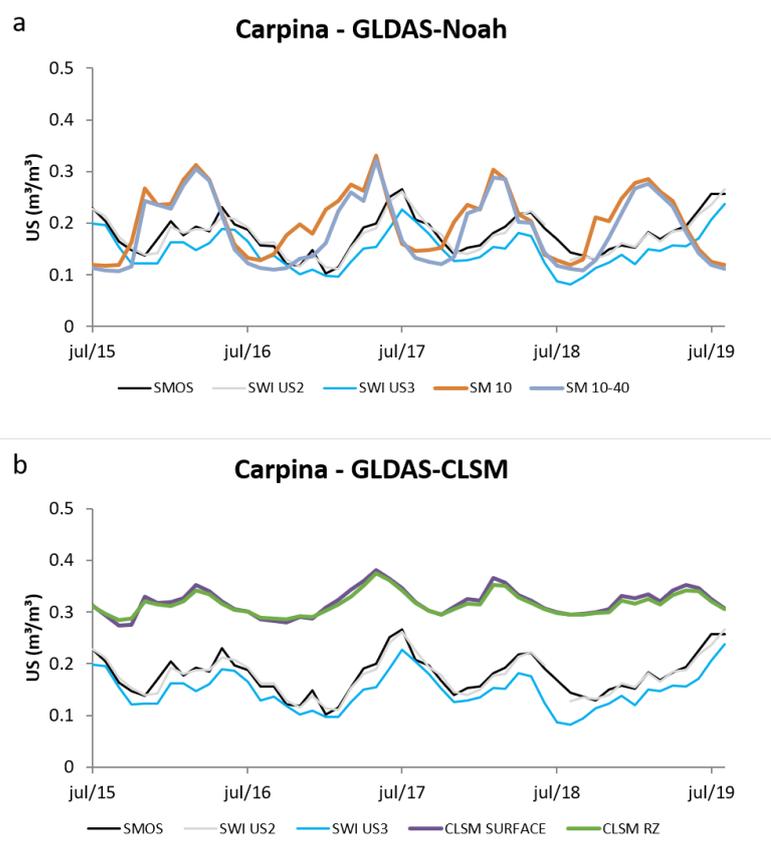
Tabela 10 – Valores de r e RMSE obtidos para a comparação do SMOS, SWI2 e GLDAS-CLSM para o Sertão de São Francisco

Estação	Rede	CLSM					
		SMOS - CSLMSUR		SMOS - CLSMRZ		SWI2 - CLSMRZ	
		R	RMSE	R	RMSE	R	RMSE
Cabrobó	CE Acqua	0.85	0.067	0.82	0.151	0.7	0.181
Floresta	CE Acqua	0.81	0.078	0.81	0.157	0.43	0.158
Orocó	CE Acqua	0.86	0.057	0.79	0.14	0.8	0.171
Petrolina1	CE Acqua	0.87	0.08	0.91	0.161	0.87	0.178
Petrolina3	CE Acqua	0.87	0.089	0.82	0.176	0.76	0.191
Terra Nova	CE Acqua	0.86	0.078	0.78	0.158	0.48	0.174

Para a Zona da Mata, as correlações foram baixas para os dois modelos, bem como o RMSE foi consideravelmente elevado. As maiores correlações foram observadas para o modelo CLSM (Tabela 11), onde em ambas as estações o maior r foi obtido na comparação SMOS-CLSMRZ, enquanto o RMSE foi menor para o

modelo Noah LSM (Tabela 12). Os resultados para a estação Carpina podem ser visualizados na Figura 16. Para essas estações, os maiores coeficientes r e menores RMSE foram encontrados para a comparação do SMOS com CLSMRZ e SM1040.

Figura 16 – Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 e 40 cm, GLDAS-Noah (a) e GLDAS-CLSM (b) para a estação Carpina (APAC)



Fonte: A autora (2021)

Tabela 11 – Valores de r e RMSE obtidos para a comparação do SMOS, SWI2, SWI3 e GLDAS-CLSM para a Zona da Mata

Estação	Rede	CLSM							
		SMOS - CSLMSUR		SMOS - CLSMRZ		SWI2 - CLSMRZ		SWI3 - CLSMRZ	
		R	RMSE	r	RMSE	r	RMSE	r	RMSE
Carpina	APAC	0.41	0.146	0.46	0.141	0.38	0.149	0.313	0.172
Vitória de Santo Antão	APAC	0.56	0.196	0.61	0.192	0.56	0.196	0.551	0.191

Tabela 12 – Valores de r e RMSE obtidos para a comparação do SMOS, SWI2, SWI3 e GLDAS-Noah para a Zona da Mata

Estação	Rede	Noah LSM							
		SMOS - SM10		SMOS - SM1040		SWI2 - SM1040		SWI3 - SM1040	
		R	RMSE	r	RMSE	r	RMSE	r	RMSE
<i>Carpina</i>	APAC	-0.16	0.080	0.06	0.073	-0.03	0.077	0.01	0.082
<i>Vitória de Santo Antão</i>	APAC	-0.04	0.100	0.17	0.085	0.16	0.088	0.12	0.086

Na mesorregião do Agreste, o modelo CLSM (Tabela 13) apresentou a melhor performance no coeficiente r em comparação com o modelo Noah LSM (Tabela 14), apesar de altos valores de RMSE – a maior correlação média foi observada na comparação entre SWI2 e CLSMRZ, 0,81, e também o maior RMSE, igual a 0,21.

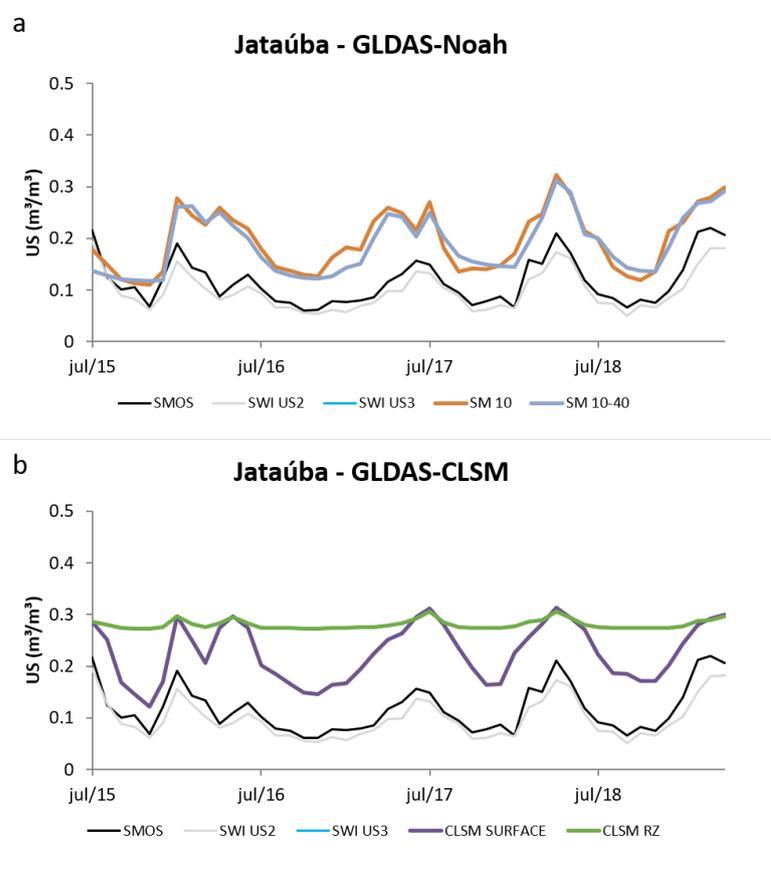
Para grande parte das estações, 16 das 25 no total, a correlação entre SWI2 e CLSMRZ foi maior do que a observada para SMOS e CLSMRZ. Para essas estações e adicionalmente para Orobó e São Bento do Una, a correlação entre SWI2 e CLSMRZ foi maior do que a comparação entre SMOS e CLSMSUR. Os resultados para as estações Jataúba, Venturosa e Salgadoinho estão apresentados nas Figuras 17, 18 e 19, respectivamente.

Tabela 13 – Valores de r e RMSE obtidos para a comparação do SMOS, SWI2, SWI3 e GLDAS-CLSM para o Agreste Pernambucano

Estação	Rede	CLSM							
		SMOS - CSLMSUR		SMOS - CLSMRZ		SWI2 - CLSMRZ		SWI3 - CLSMRZ	
		r	RMSE	r	RMSE	r	RMSE	r	RMSE
<i>Águas belas</i>	APAC	0.37	0.162	0.38	0.204	0.33	0.215	0.309	0.215
<i>Brejão</i>	APAC	0.55	0.190	0.63	0.189	0.58	0.189	0.550	0.189
<i>Cupira</i>	APAC	0.57	0.157	0.63	0.154	0.59	0.153	0.591	0.153
<i>São Bento do Una</i>	APAC	0.54	0.212	0.61	0.221	0.55	0.220	0.552	0.220
<i>Altinho</i>	CE Acqua	0.83	0.214	0.87	0.215	0.89	0.226	-	-
<i>Bezerros</i>	CE Acqua	0.84	0.185	0.94	0.196	0.95	0.210	-	-
<i>Bom Conselho</i>	CE Acqua	0.82	0.202	0.93	0.220	0.95	0.219	-	-
<i>Brejão</i>	CE Acqua	0.55	0.193	0.65	0.192	0.59	0.190	-	-
<i>Brejo da Madre de Deus</i>	CE Acqua	0.80	0.151	0.89	0.180	0.88	0.180	-	-
<i>Caetés</i>	CE Acqua	0.78	0.200	0.86	0.220	0.88	0.219	-	-
<i>Canhotinho</i>	CE Acqua	0.84	0.216	0.81	0.214	0.87	0.211	-	-
<i>Frei Miguelinho</i>	CE Acqua	0.80	0.188	0.92	0.205	0.94	0.217	-	-
<i>Gravatá</i>	CE Acqua	0.86	0.199	0.91	0.199	0.93	0.198	-	-
<i>Garanhuns</i>	CE Acqua	0.80	0.234	0.79	0.235	0.83	0.245	-	-
<i>Iati</i>	CE Acqua	0.38	0.161	0.43	0.205	0.95	0.213	-	-
<i>Jatauba</i>	CE Acqua	0.78	0.114	0.78	0.169	0.80	0.185	-	-
<i>Jurema</i>	CE Acqua	0.85	0.206	0.84	0.205	0.93	0.198	-	-
<i>Lajedo</i>	CE Acqua	0.83	0.214	0.87	0.215	0.89	0.226	-	-

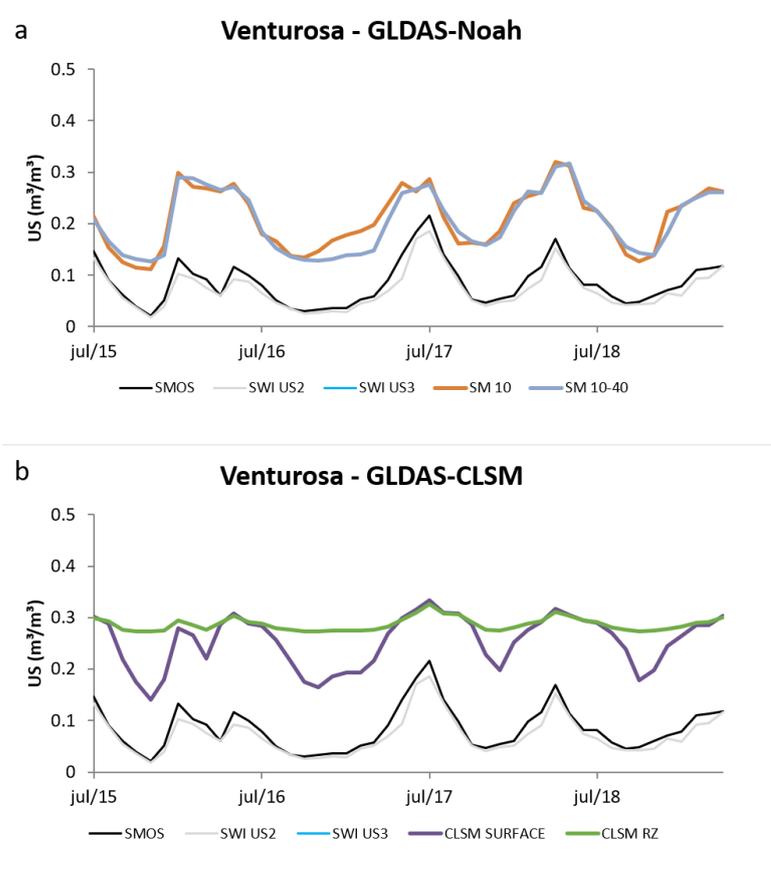
Orobó	CE Acqua	0.85	0.173	0.95	0.181	0.94	0.180	-	-
Pedra	CE Acqua	0.79	0.150	0.90	0.200	0.91	0.199	-	-
Salgadinho	CE Acqua	0.83	0.189	0.93	0.196	0.94	0.195	-	-
São Bento do Una	CE Acqua	0.54	0.214	0.62	0.224	0.55	0.226	-	-
Taquaritinga do Norte	CE Acqua	0.77	0.147	0.83	0.183	0.84	0.195	-	-
Venturosa	CE Acqua	0.81	0.172	0.90	0.205	0.91	0.216	-	-
Vertente do Lério	CE Acqua	0.82	0.190	0.94	0.208	0.74	0.203	-	-

Figura 17 – Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 e 40 cm, GLDAS-Noah (a) e GLDAS-CLSM (b) para a estação Jataúba (CEMADEN Acqua)



Fonte: A autora (2021)

Figura 18 – Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 e 40 cm, GLDAS-Noah e GLDAS-CLSM para a estação Venturosa (CEMADEN Acqua)



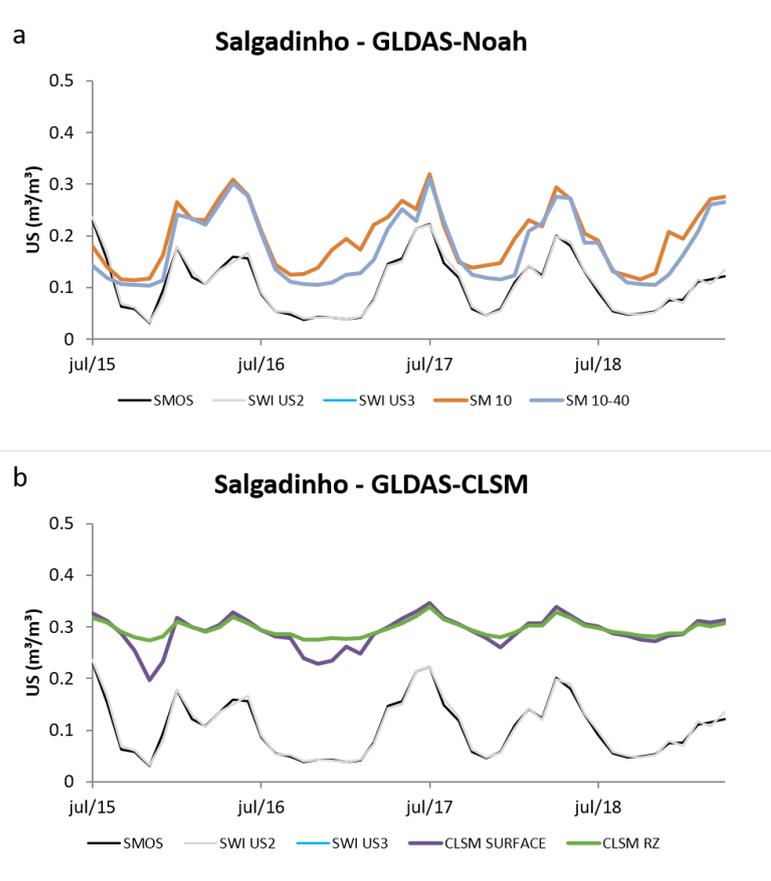
Fonte: A autora (2021)

Tabela 14 – Valores de r e RMSE obtidos para a comparação do SMOS, SWI2, SWI3 e GLDAS-Noah para o Agreste Pernambucano

Estação	Rede	Noah LSM							
		SMOS - SM10		SMOS - SM1040		SWI2 - SM1040		SWI3 - SM1040	
		r	RMSE	r	RMSE	r	RMSE	r	RMSE
Águas belas	APAC	-0.18	0.129	-0.05	0.118	-0.08	0.125	-0.10	0.125
Brejão	APAC	-0.39	0.120	-0.22	0.110	-0.27	0.111	-0.30	0.111
Cupira	APAC	-0.27	0.106	-0.07	0.099	-0.11	0.102	-0.11	0.101
São Bento do Una	APAC	-0.19	0.153	-0.05	0.147	-0.10	0.148	-0.11	0.148
Altinho	CE Acqua	0.62	0.129	0.68	0.119	0.66	0.130	-	-
Bezerros	CE Acqua	0.80	0.108	0.88	0.090	0.86	0.107	-	-
Bom Conselho	CE Acqua	0.66	0.118	0.73	0.098	0.71	0.098	-	-
Brejão	CE Acqua	-0.32	0.125	-0.14	0.113	-0.22	0.114	-	-
Brejo da Madre de Deus	CE Acqua	0.60	0.095	0.67	0.079	0.63	0.080	-	-
Caetés	CE Acqua	0.73	0.142	0.77	0.137	0.76	0.136	-	-
Canhotinho	CE Acqua	0.57	0.098	0.69	0.079	0.60	0.081	-	-
Frei Miguelinho	CE Acqua	0.76	0.130	0.75	0.117	0.77	0.130	-	-
Gravatá	CE Acqua	0.80	0.100	0.87	0.081	0.86	0.081	-	-

<i>Garanhuns</i>	CE Acqua	0.62	0.128	0.71	0.110	0.67	0.121	-	-
<i>Iati</i>	CE Acqua	-0.18	0.139	-0.02	0.128	0.67	0.118	-	-
<i>Jatauba</i>	CE Acqua	0.75	0.087	0.72	0.081	0.70	0.098	-	-
<i>Jurema</i>	CE Acqua	0.40	0.101	0.41	0.094	0.21	0.097	-	-
<i>Lajedo</i>	CE Acqua	0.62	0.129	0.68	0.119	0.66	0.130	-	-
<i>Orobó</i>	CE Acqua	0.76	0.087	0.79	0.069	0.77	0.069	-	-
<i>Pedra</i>	CE Acqua	0.78	0.119	0.79	0.114	0.78	0.114	-	-
<i>Salgadinho</i>	CE Acqua	0.75	0.102	0.76	0.083	0.76	0.083	-	-
<i>São Bento do Una</i>	CE Acqua	-0.05	0.160	0.11	0.154	-0.01	0.158	-	-
<i>Taquaritinga do Norte</i>	CE Acqua	0.65	0.105	0.62	0.095	0.61	0.107	-	-
<i>Venturosa</i>	CE Acqua	0.77	0.130	0.79	0.126	0.76	0.137	-	-
<i>Vertente do Lério</i>	CE Acqua	0.78	0.130	0.78	0.116	0.53	0.119	-	-

Figura 19 – Comparação da umidade do solo obtida pelo satélite SMOS, SWI para 20 e 40 cm, GLDAS-Noah e GLDAS-CLSM para a estação Salgadinho (CEMADEN Acqua)



Fonte: A autora (2021)

Considerando a diferença estrutural dos modelos – onde o CLSM não possui grades verticais de solo, enquanto o Noah possui 4 diferentes camadas de solo, ainda que aqui utilizadas apenas duas – diferentes comportamentos da umidade do solo foram identificados. No caso do CLSM, a representação da água subterrânea é dada

por meio da relação espacial entre a profundidade do lençol freático e as estatísticas de topografia dentro de uma bacia hidrográfica – a variável primária de umidade do solo é o déficit de captação, isto é, a quantidade média de água que teria que ser adicionada para levar a captação à saturação. (KOSTER *et al.*, 2000; EARTHDATA, 2021). Por esse motivo, nota-se que a curva do CLSM, especificamente da zona de raiz, é mais reta e localiza-se acima das demais – devido à capacidade de saturação dessa camada. Para o Noah, na camada de 10-40 cm, maiores variações são observadas dado o cenário estabelecido, onde um maior volume de água pode ser considerado fluindo para as camadas mais profundas, sem o limite do lençol freático existente no CLSM.

De maneira geral, os melhores resultados para o GLDAS-Noah foram observados para as mesorregiões do Sertão e Sertão de São Francisco. Para o Sertão, foram identificadas estações onde a correlação entre SWI e as maiores profundidades do modelo foram maiores do que quando os mesmos dados foram turcomparados com o SMOS. Já para a Zona da Mata e para o Agreste, o CLSM apresentou melhores correlações, com grande parte das estações apresentando melhores resultados na comparação do SWI e as maiores profundidades do modelo, em comparação com a utilização do SMOS.

Liu *et al.* (2019) compararam os dados de umidade do solo capturadas pelo ESA CCI SM, uma combinação de satélites, e do GLDAS-Noah para uma análise de seca global utilizando índices de seca ao longo de 25 anos e observaram diferenças consideráveis na duração da seca em regiões áridas, semiáridas e densamente vegetadas. No mesmo contexto, Zhang *et al.* (2021) compararam os mesmos conjuntos de dados e encontrou grandes discrepâncias nos padrões espaciais de duração da seca, severidade e tendências de frequência, especialmente em regiões áridas.

De acordo com Zawadzki e Kędzior (2016), os dados do SMOS apresentam maiores correlações com as taxas de precipitação em relação ao GLDAS-Noah. Apesar de os modelos de superfície do solo serem capazes de reproduzir a variabilidade sazonal da umidade do solo e suas anomalias, a capacidade de fornecer a umidade real do solo não é suficiente. Os autores realizaram um estudo comparativo de três conjuntos de dados de umidade de superfície do solo recuperados do CosmicRay Soil Moisture Observing System (COSMOS), baseado na medição de

nêutrons *in situ*, do SMOS e dados modelados do GLDAS, e usaram o filtro exponencial para obter estimativas da umidade na subsuperfície. Eles encontraram que o COSMOS e o SMOS apresentam com maior eficácia as mudanças temporais da umidade do solo, e isso ficou mais evidente quando a dinâmica da umidade da superfície do solo foi significativa.

Ainda segundo Zawadzki e Kędzior (2016), essa diferença entre as estimativas do SMOS e do GLDAS pode ser explicada porque o banco de dados do GLDAS fornece estimativas mais suaves da umidade do solo como resultado de cálculos em grande escala. Para o filtro exponencial, os valores calculados a partir do SMOS mostram uma correlação mais forte com os dados do COSMOS do que os do GLDAS. Entretanto, como a profundidade típica de penetração da radiação da banda L é de cerca de 5 cm, os dados GLDAS suavizados são mais apropriados para camadas de subsuperfície muito profundas porque consideram vários parâmetros de solo.

Considerando o exposto e os padrões indicados pela análise, observa-se padrões no resultado: nas regiões com menores índices pluviométricos e chuvas mais escassas, como no Sertão, o modelo GLDAS-Noah apresentou melhores resultados; para o Agreste e Zona da Mata, os melhores resultados foram obtidos para o GLDAS-CLSM. Importante mencionar que Souza et al. (2018) identificaram que a performance do SMOS também apresentou variação de acordo com as características climáticas da área de estudo, e os melhores resultados obtidos na comparação entre SMOS e estações *in situ* foram identificadas no semiárido. Além disso, o GLDAS-Noah fornece dados até 40 cm, enquanto o GLDAS-CLSM até 100 cm, e nas regiões semiáridas do nordeste brasileiro predominam os solos rasos, gerando maior compatibilidade na comparação no que diz respeito à profundidade da camada.

5 CONCLUSÕES E RECOMENDAÇÕES

Os resultados obtidos na primeira etapa do estudo, realizadas a partir das comparações entre o SWI aplicado aos dados de umidade do solo do SMOS, e as estações *in situ* das redes de observação da APAC e CEMADEN, mostraram que existe grande benefício na aplicação do filtro exponencial, refletindo em maiores valores de correlação de Pearson e menores valores de RMSE.

Para a avaliação pixel-estação na profundidade de 20 cm (US2), a correlação média para todas as mesorregiões de Pernambuco foi de 0,65 para a comparação entre SWI e US2, enquanto entre SMOS e US2 o coeficiente r foi de 0,49 – um incremento de 34%. Da mesma forma, o primeiro cenário apresentou um RMSE médio de 0,06, contra 0,08 para o segundo cenário. Para a comparação entre SWI e US3, a correlação média e RMSE foram de 0,71 e 0,06, enquanto que para SMOS e US3 foram de 0,54 e 0,08.

De maneira geral, o resultado foi muito próximo para todas as mesorregiões, sendo os maiores incrementos médios da correlação r observados na Região Metropolitana e no Sertão de São Francisco, onde também foi constatada a maior redução de RMSE. Desconsiderando a região Metropolitana por ser uma única estação, um sutil padrão para regiões semiáridas foi encontrado, dado que o Sertão Pernambucano também apresentou resultados consideráveis. Esse padrão se relaciona ao encontrado para o SMOS por Souza *et al.* (2018).

Para a profundidade de 40 cm (US3), o cenário de comparação com o SWI apresentou maior incremento percentual na correlação, em média 41%, em relação à comparação entre SWI e US2, bem como a maior redução percentual média no RMSE, de 30%.

Na segunda etapa, foi realizada a comparação entre o SWI e os produtos de umidade do solo dos modelos GLDAS-Noah e GLDAS-CLSM. Para o Sertão, as maiores correlações e os menores valores de RMSE foram encontrados para o modelo Noah LSM, porém a maior correlação foi observada para a comparação entre SMOS e SM10, primeira profundidade (até 10 cm) do GLDAS-Noah. Para a região do Sertão de São Francisco, o GLDAS-Noah apresentou os menores valores de RSME, porém em grande parte das estações a correlação entre SMOS e SM10 foi a maior dentre os três cenários. Para a Zona da Mata, as correlações foram baixas para os

dois modelos, e os maiores coeficientes r e menores RMSE foram observados na comparação entre SMOS com CLSMRZ e SM1040. Já na mesorregião do Agreste, para grande parte das estações a correlação entre SWI2 e CLSMRZ foi maior do que a observada para SMOS e CLSMRZ.

Observou-se que o GLDAS-Noah apresentou melhores correlações com o SWI nas regiões com menores índices pluviométricos e chuvas mais escassas, enquanto o GLDAS-CLSM apresentou melhores resultados no Agreste e Zona da Mata, porém, de maneira geral, não foi observado um padrão nos resultados. Não houve constatação de que a utilização do filtro exponencial apresentou melhores resultados na comparação com os modelos em contraste ao cenário do SMOS com os mesmos. Deve-se considerar, entretanto, a diferença estrutural dos modelos com relação à existência ou não de camadas verticais no solo – no caso do CLSM, a variável primária de umidade do solo é o déficit de captação.

5.1 TRABALHOS FUTUROS

Para futuros trabalhos, recomenda-se uma análise mais aprofundada acerca da utilização do filtro exponencial em diferentes regiões climáticas e com diferentes tipos de solo no Brasil, de forma a explorar limitações de sua aplicação, especialmente em locais com menor número de séries de umidade do solo obtidas *in situ* disponíveis, ou com grande número de falhas na série temporal. Para os valores de T , avaliar o comportamento da precipitação nas estações onde o parâmetro foi elevado e verificar se as estações *in situ* de fato estão representando a variabilidade temporal da umidade.

Em paralelo, acerca dos modelos GLDAS-Noah e GLDAS-CLSM, estudos mais aprofundados devem ser realizados com o objetivo de avaliar o quanto de fato são capazes de mensurar as mudanças temporais na umidade do solo, especialmente em locais com dinâmicas de variabilidade climática e de precipitação altas.

Complementarmente, o SWI pode ser comparado aos dados do produto de umidade do solo da superfície e da zona de raiz gerados a partir de dados do satélite SMAP, L4 (L4_SM), gerado a partir da assimilação de observações da TB da banda L do SMAP no modelo de superfície Catchment.

REFERÊNCIAS

- AL BITAR, A.; LEROUX, D.; KERR, Y. H.; MERLIN, O.; RICHAUME, P.; SAHOO, A.; WOOD, E. F. Evaluation of SMOS soil moisture products over continental U.S. Using the SCAN/SNOTEL network. **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n. 5 PART 1, p. 1572–1586, 2012. Disponível em: <https://doi.org/10.1109/TGRS.2012.2186581>.
- ALBERGEL, C.; RÜDIGER, C.; PELLARIN, T.; CALVET, J. C.; FRITZ, N.; FROISSARD, F.; SUQUIA, D.; PETITPA, A.; PIGUET, B.; MARTIN, E. From near-surface to root-zone soil moisture using an exponential filter: An assessment of the method based on in-situ observations and model simulations. **Hydrology and Earth System Sciences**, v. 12, n. 6, p. 1323–1337, 2008. Disponível em: <https://doi.org/10.5194/hess-12-1323-2008>.
- ALVALÁ, R. C. S.; CUNHA, A. P. M. A.; BRITO, S. S. B.; MARCELO, E. Drought monitoring in the Brazilian Semiarid region. **Anais da Academia Brasileira de Ciências**, v. 91, p. 1–15, 2019. Disponível em: <https://doi.org/10.1590/0001-3765201720170209>.
- ASFORA, M. C.; LIMA, M.; LACERDA, M. R. S. Diagnóstico da seca 2011-2016 em Pernambuco: impactos e políticas de mitigação. **Parcerias Estratégicas**, v. 22, n. 44, p. 247–273, 2017.
- BALDWIN, D.; MANFREDA, S.; KELLER, K.; SMITHWICK, E. A. H. Predicting root zone soil moisture with soil properties and satellite near-surface moisture data across the conterminous United States. **Journal of Hydrology**, 546, 393-404, 2017. Disponível em: <https://doi.org/10.1016/j.jhydrol.2017.01.020>.
- BARRÉ, H. M. J. P.; DUESMANN, B.; KERR, Y. H. SMOS: The mission and the system. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 3, p. 587–593, 2008. Disponível em: <https://doi.org/10.1109/TGRS.2008.916264>.
- BEAUDOING, H.; RODELL, M. GLDAS Noah Land Surface Model L4 monthly 0.25 x 0.25 degree V2.1, Greenbelt, Maryland, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC). **NASA/GSFC/HSL**, 2020. Disponível em: https://disc.gsfc.nasa.gov/datasets/GLDAS_NOAH025_M_2.1/summary.
- BECK, H. E.; PAN, M.; MIRALLES, D. G.; REICHLER, R. H.; DORIGO, W. A.; HAHN, S.; SHEFFIELD, J.; KARTHIKEYAN, L.; BALSAMO, G.; PARINUSSA, R. M.; VAN DIJK, A. I. J. M.; DU, J.; KIMBALL, J. S.; VERGOPOLAN, N.; WOOD, E. F. Evaluation of 18 satellite- And model-based soil moisture products using *in situ* measurements from 826 sensors. **Hydrology and Earth System Sciences**, v. 25, n. 1, p. 17–40, 2021. Disponível em: <https://doi.org/10.5194/hess-25-17-2021>.
- BIRCHER, S.; SKOU, N.; JENSEN, K. H.; WALKER, J. P.; RASMUSSEN, L. A soil moisture and temperature network for SMOS validation in Western Denmark. **Hydrology and Earth System Sciences**, v. 16, n. 5, p. 1445–1463, 2012. Disponível em: <https://doi.org/10.5194/hess-16-1445-2012>.

BOLTEN, J. D.; CROW, W. T.; ZHAN, X.; JACKSON, T. J.; REYNOLDS, C. A.; BOLTEN, J. D.; CROW, W. T.; JACKSON, T. J. Evaluating the Utility of Remotely Sensed Soil Moisture Retrievals for Operational Agricultural Drought Monitoring. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 3, n. 1, p. 57, 2010. Disponível em: <http://ieeexplore.ieee.org>.

BROCCA, L.; MELONE, F.; MORAMARCO, T.; WAGNER, W.; NAEIMI, V.; BARTALIS, Z.; HASENAUER, S. Improving runoff prediction through the assimilation of the ASCAT soil moisture product. **Hydrology and Earth System Sciences**, v. 14, n. 10, p. 1881–1893, 2010. Disponível em: <https://doi.org/10.5194/hess-14-1881-2010>.

CALVET, J. C. An evaluation of ASCAT surface soil moisture products with in-situ observations in southwestern France. **Hydrology and Earth System Sciences Discussions**, v. 5, n. 4, p. 2221–2250, 2008. Disponível em: <https://doi.org/10.5194/hessd-5-2221-2008>.

CEBALLOS, A.; SCIPAL, K.; WAGNER, W.; MARTÍNEZ-FERNÁNDEZ, J. Validation of ERS scatterometer-derived soil moisture data in the central part of the Duero Basin, Spain. **Hydrological Processes**, v. 19, n. 8, p. 1549–1566, 2005. Disponível em: <https://doi.org/10.1002/hyp.5585>.

CHAKRABARTI, S.; BONGIOVANNI, T.; JUDGE, J.; ZOTARELLI, L.; BAYER, C. Assimilation of SMOS soil moisture for quantifying drought impacts on crop yield in agricultural regions. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 9, p. 3867–3879, 2014. Disponível em: <https://doi.org/10.1109/JSTARS.2014.2315999>.

CHAN, S. K.; BINDLISH, R.; O'NEILL, P. E.; NJOKU, E.; JACKSON, T.; COLLIANDER, A.;...& KERR, Y. Assessment of the SMAP Passive Soil Moisture Product. **IEEE Transactions on Geoscience and Remote Sensing**, v. 54, n. 8, p. 4994-5007, 2016. Disponível em: <https://doi.org/10.1109/TGRS.2016.2561938>.

CROW, W. T.; RYU, D. A new data assimilation approach for improving runoff prediction using remotely-sensed soil moisture retrievals. **Hydrology and Earth System Sciences**, v. 13, n. 1, p. 1-16, 2009. Disponível em: <https://doi.org/10.5194/hess-13-1-2009>.

CUI, C.; XU, J.; ZENG, J.; CHEN K.; BAI X.; LU H.; CHEN Q.; ZHAO T. Soil moisture mapping from satellites: An intercomparison of SMAP, SMOS, FY3B, AMSR2, and ESA CCI over two dense network regions at different spatial scales. **Remote Sensing**, v. 10, n. 1, p. 33, 2018 Disponível em: <https://doi.org/10.3390/rs10010033>.

DAI, A. Drought under global warming: A review. **Wiley Interdisciplinary Reviews: Climate Change**, v. 2, n. 1, p. 45–65, 2011. Disponível em: <https://doi.org/10.1002/wcc.81>.

DE JEU, R. A. M.; HOLMES, T. R. H.; PARINUSSA, R. M.; OWE, M. A spatially coherent global soil moisture product with improved temporal resolution. **Journal of Hydrology**, v. 516, p. 284-296, 2014. Disponível em: <https://doi.org/10.1016/j.jhydrol.2014.02.015>.

DE SOUZA, J. G. N. Avaliação do Modelo de reanálise GLDAS/NOAH e obtenção de fluxos de energia a partir do SEBS, em Minas Gerais. **Dissertação de Mestrado – Universidade Federal de Lavras**, 2015.

DIRMEYER, P. A.; GAO, X. ; ZHAO, M.; GUO, Z.; OKI, T.; HANASAKI, N.. GSWP-2: Multimodel analysis and implications for our perception of the land surface. **Bulletin of the American Meteorological Society**, v. 87, n. 10, p. 1381–1397, 2006. Disponível em: <https://doi.org/10.1175/BAMS-87-10-1381>.

DORIGO, W. A.; WAGNER, W.; HOHENSINN, R.; HAHN, S.; PAULIK, C.; XAVER, A.; GRUBER, A.; DRUSCH, M.; MECKLENBURG, S.; VAN OEVELEN, P.; ROBOCK, A.; JACKSON, T. The International Soil Moisture Network: A data hosting facility for global *in situ* soil moisture measurements. **Hydrology and Earth System Sciences**, v. 15, n. 5, p. 1675–1698, 2011. Disponível em: <https://doi.org/10.5194/hess-15-1675-2011>.

DUMEDAH, G.; WALKER, J. P.; MERLIN, O. Root-zone soil moisture estimation from assimilation of downscaled Soil Moisture and Ocean Salinity data. **Advances in Water Resources**, v. 84, p. 14–22, 2015. Disponível em: <https://doi.org/10.1016/j.advwatres.2015.07.021>.

EARTHDATA. GLDAS LSM Description. Disponível em: <https://disc.gsfc.nasa.gov/information/documents?title=GLDAS%20LSM%20Description>. Acesso em: 24/08/2021.

EK, M. B.; MITCHELL, K. E.; LIN, Y.; ROGERS, E.; GRUNMANN, P.; KOREN, V.; GAYNO, G.; TARPLEY, J. D. Implementation of Noah land surface model advances in the National Centers for Environmental Prediction operational mesoscale Eta model. **Journal of Geophysical Research: Atmospheres**, v. 108, n. 22, p. 1–16, 2003. Disponível em: <https://doi.org/10.1029/2002jd003296>.

ESCORIHUELA, M. J.; CHANZY, A.; WIGNERON, J. P.; KERR, Y. H. Effective soil moisture sampling depth of L-band radiometry: A case study. **Remote Sensing of Environment**, v. 114, n. 5, p. 995–1001, 2010. Disponível em: <https://doi.org/10.1016/j.rse.2009.12.011>.

FANG, H.; BEAUDOING, H. K.; RODELL, M.; TENG, W. L.; VOLLMER, B. E. Global Land Data Assimilation System (GLDAS) products, services and application from NASA Hydrology Data and Information Services Center (HDISC). **American Society for Photogrammetry and Remote Sensing Annual Conference 2009**, ASPRS 2009, v. 1, p. 151–159, 2009.

FERNANDES, D. S. Índices para a Quantificação da Seca. **Embrapa Arroz e Feijão**, p. 48, 2009. Disponível em: <http://ainfo.cnptia.embrapa.br/digital/bitstream/CNPAF-2010/29786/1/doc-244.pdf>.

FILHO, D. B. F.; SILVA JÚNIOR, J. A. Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r). **Revista Política Hoje**, v. 18, n. 1, p. 115-146, 2009.

FORD, T. W.; HARRIS, E.; QUIRING, S. M. Estimating root zone soil moisture using near-surface observations from SMOS. **Hydrology and Earth System Sciences**, v. 18, n. 1, p. 139–154, 2014. Disponível em: <https://doi.org/10.5194/hess-18-139-2014>.

GAO, X.; ZHAO, X.; BROCCA, L.; HUO, G.; LV, T.; WU, P. Depth scaling of soil moisture content from surface to profile: multistation testing of observation operators. **Hydrology and Earth System Sciences Discussions**, n. July, p. 1–25, 2017. Disponível em: <https://doi.org/10.5194/hess-2017-292>.

GETIRANA, A. Extreme Water Deficit in Brazil Detected from Space. **Journal of Hydrometeorology**, v. 17, n. 2, p. 591-599, 2016. Disponível em: <https://doi.org/10.1175/JHM-D-15-0096.1>.

GONZÁLEZ-ZAMORA, Á.; SÁNCHEZ, N.; MARTÍNEZ-FERNÁNDEZ, J.; GUMUZZIO, Á.; PILES, M; OLMEDO, E. Long-term SMOS soil moisture products: A comprehensive evaluation across scales and methods in the Duero Basin (Spain). **Physics and Chemistry of the Earth, Parts A/B/C**, v. 83, p. 123-136, 2015. Disponível em: <https://doi.org/10.1016/j.pce.2015.05.009>.

HAO, Z.; SINGH, V. P.; XIA, Y. Seasonal Drought Prediction: Advances, Challenges, and Future Prospects. **Reviews of Geophysics**, v. 56, n. 1, p. 108–141, 2018. Disponível em: <https://doi.org/10.1002/2016RG000549>.

HEIM, R. R. A review of twentieth-century drought indices used in the United States. **Bulletin of the American Meteorological Society**, v. 83, n. 8, p. 1149–1165, 2002. Disponível em: <https://doi.org/10.1175/1520-0477-83.8.1149>.

HELSEL, D. R.; HIRSCH, R. M. *Statistical Methods in Water Resources*. 2002.

HU, W.; SI, B. C. Can soil water measurements at a certain depth be used to estimate mean soil water content of a soil profile at a point or at a hillslope scale? **Journal of Hydrology**, v. 516, p. 67–75, 2014. Disponível em: <https://doi.org/10.1016/j.jhydrol.2014.01.053>.

JACQUETTE, E.; AL BITAR, A.; MIALON, A.; KERR, Y.; QUESNEY, A.; CABOT, F.; RICHAUME, P. SMOS CATDS level 3 global products over land. In: **Remote Sensing for Agriculture, Ecosystems, and Hydrology XII. International Society for Optics and Photonics**, 2010. p. 78240K. Disponível em: <https://doi.org/10.1117/12.865093>.

KERR, Y. 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. Disponível em: <https://doi.org/10.1109/JPROC.2010.2043032>.

KERR, Y. H. Soil moisture from space: Where are we? **Hydrogeology Journal**, v. 15, n. 1, p. 117–120, 2007. Disponível em: <https://doi.org/10.1007/s10040-006-0095-3>.

KERR, Y. H.; WALDTEUFEL, P.; RICHAUME, P.; WIGNERON, J. P.; FERRAZZOLI, P.; MAHMOODI, A.; BITAR, A. A.; CABOT, F.; GRUHIER, C.; JUGLEA, S. E.; LEROUX, D.; MIALON, A.; DELWART, S. The SMOS Soil Moisture Retrieval Algorithm. **IEEE transactions on geoscience and remote sensing**, v. 50, n. 5, p. 1384-1403, 2012. Disponível em: <https://doi.org/10.1109/TGRS.2012.2184548>.

KERR, Y. H.; WALDTEUFEL, P.; WIGNERON, J. P.; MARTINUZZI, J. M.; FONT, J.; BERGER, M. Soil moisture retrieval from space: The Soil Moisture and Ocean Salinity

(SMOS) mission. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 8, p. 1729–1735, 2001. Disponível em: <https://doi.org/10.1109/36.942551>.

KOSTER, R.D.; SUAREZ, M.J.; DUCHARNE, A.; STIEGLITZ, M.; KUMAR, P. A catchment-based approach to modeling land surface processes in a general circulation model: 1. Model structure. **Journal of Geophysical Research: Atmospheres**, 105(D20), 24809-24822, 2000. Disponível em: <https://doi.org/10.1029/2000JD900327>.

KUMAR, S. V.; DIRMEYER, P. A.; PETERS-LIDARD, C. D.; BINDLISH, R.; BOLTEN, J. Information theoretic evaluation of satellite soil moisture retrievals. **Remote sensing of environment**, v. 204, p. 392-400, 2018. Disponível em: <https://doi.org/10.1016/j.rse.2017.10.016>.

LACAVA, T.; MATGEN, P.; BROCCA, L.; BITTELLI, M.; PERGOLA, N.; MORAMARCO, T.; TRAMUTOLI, V. A first assessment of the SMOS soil moisture product with *in situ* and modeled data in Italy and Luxembourg. **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n. 5 PART 1, p. 1612–1622, 2012. Disponível em: <https://doi.org/10.1109/TGRS.2012.2186819>.

LAZAROVITCH, N.; VANDERBORGHT, J.; JIN, Y.; VAN GENUCHTEN, M. T. The root zone: soil physics and beyond. **Vadose zone journal**, 17(1), 1-6, 2018. Disponível em: <https://doi.org/10.2136/vzj2018.01.0002>.

LI, B. et al. Global GRACE Data Assimilation for Groundwater and Drought Monitoring: Advances and Challenges. **Water Resources Research**, v. 55, n. 9, p. 7564–7586, 2019. Disponível em: <https://doi.org/10.1029/2018WR024618>.

LI, B., H. BEAUDOING, H.; RODELL, M. GLDAS Catchment Land Surface Model L4 daily 0.25 x 0.25 degree GRACE-DA1 V2.2, Greenbelt, Maryland, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC). **NASA/GSFC/HSL**, 2020. Disponível em: https://disc.gsfc.nasa.gov/datasets/GLDAS_CLSM025_D_2.0/summary.

LIMA, M.; ALVES, B. Vulnerabilidade, impactos e adaptação à mudança do clima no setor agropecuário e solos agrícolas. **Embrapa Agrobiologia-Artigo em periódico indexado (ALICE)**, 2008.

LIU, Y.; LIU, Y.; WANG, W. Inter-comparison of satellite-retrieved and Global Land Data Assimilation System-simulated soil moisture datasets for global drought analysis. **Remote Sensing of Environment**, v. 220, n. January, p. 1–18, 2019. Disponível em: <https://doi.org/10.1016/j.rse.2018.10.026>.

LIU, Y. Y.; PARINUSSA, R. M.; DORIGO, W. A.; DE JEU, R. A. M.; WAGNER, W.; DIJK, A. I. J. M. V.; MCCABE, M. F. Developing an improved soil moisture dataset by blending passive and active microwave satellite-based retrievals. **Hydrology and Earth System Sciences**, v. 15, n. 2, p. 425-436, 2011. Disponível em: <https://doi.org/10.5194/hess-15-425-2011>.

MANFREDA, S.; BROCCA, L.; MORAMARCO, T.; MELONE, F.; SHEFFIELD, J. A physically based approach for the estimation of root-zone soil moisture from surface

measurements. **Hydrology and Earth System Sciences**, v. 18, n. 3, p. 1199–1212, 2014. Disponível em: <https://doi.org/10.5194/hess-18-1199-2014>.

MANFREDA, S.; MCCABE, M. F.; FIORENTINO, M.; RODRÍGUEZ-ITURBE, I.; WOOD, E. F. Scaling characteristics of spatial patterns of soil moisture from distributed modelling. **Advances in Water Resources**, v. 30, n. 10, p. 2145–2150, 2007. Disponível em: <https://doi.org/10.1016/j.advwatres.2006.07.009>.

MARENGO, J. A.; CUNHA, A. P.; ALVES, L. M. A seca de 2012-15 no semiárido do Nordeste do Brasil no contexto histórico. **Climanálise**, v. 3, n. 1, p. 1-6, 2016.

MARENGO, J. A.; ALVES, L. M.; ALVALA, R. C. S.; 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, n. 2, p. 1973–1985, 2018. Disponível em: <https://doi.org/10.1590/0001-3765201720170206>.

MARENGO, J. A.; TORRES, R. R.; ALVES, L. M. Drought in Northeast Brazil—past, present, and future. **Theoretical and Applied Climatology**, v. 129, n. 3, p. 1189-1200, 2017. Disponível em: <https://doi.org/10.1007/s00704-016-1840-8>.

MARTINEZ-FERNANDEZ, J.; SANCHEZ, N.; GONZALEZ-ZAMORA, A.; GUMUZZIO-SUCH, A.; HERRERO-JIMENEZ, C. M. Feasibility of the SMOS soil moisture for agricultural drought monitoring: Assessment with the Soil Water Deficit Index. In: **2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**. IEEE, 2015. p. 976-979. Disponível em: <https://doi.org/10.1109/IGARSS.2015.7325931>.

MCMULLAN, K. D.; BROWN, M. A.; MARTÍN-NEIRA, M.; RITS, W.; EKHOLM, S.; MARTI, J.; LEMANCZYK, J. SMOS: The payload. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 3, p. 594–605, 2008. Disponível em: <https://doi.org/10.1109/TGRS.2007.914809>.

MENEZES, J. A. L.; SANTOS, T. E. M.; MONTENEGRO, A. A. A.; SILVA, J. R. L. Comportamento temporal da umidade do solo sob Caatinga e solo descoberto na Bacia Experimental do Jatobá, Pernambuco. **Water Resources and Irrigation Management**, v. 2, n. 1, p. 45–51, 2013.

MISHRA, A. K.; SINGH, V. P. A review of drought concepts. **Journal of Hydrology**, v. 391, n. 1–2, p. 202–216, 2010. Disponível em: <https://doi.org/10.1016/j.jhydrol.2010.07.012>.

MISHRA, V.; ELLENBURG, W. L.; MARKERT, K. N.; LIMAYE, A. S. Performance evaluation of soil moisture profile estimation through entropy-based and exponential filter models. **Hydrological Sciences Journal**, v. 65, n. 6, p. 1036–1048, 2020. Disponível em: <https://doi.org/10.1080/02626667.2020.1730846>.

MISHRA, V.; SHAH, R.; THRASHER, B. Soil moisture droughts under the retrospective and projected climate in India. **Journal of Hydrometeorology**, v. 15, n. 6, p. 2267–2292, 2014. Disponível em: <https://doi.org/10.1175/JHM-D-13-0177.1>.

MITCHELL, K. The community Noah land surface model (LSM). **User's Guide Public Release Version**, v. 2, n. 1, 2005.

MOHANTY, B. P.; COSH, M. H.; LAKSHMI, V.; MONTZKA, C. Soil Moisture Remote Sensing: State-of-the-Science. **Vadose Zone Journal**, v. 16, n. 1, p. 1-9, 2017. Disponível em: <https://doi.org/10.2136/vzj2016.10.0105>.

NARASIMHAN, B.; SRINIVASAN, R. Development and evaluation of Soil Moisture Deficit Index (SMDI) and Evapotranspiration Deficit Index (ETDI) for agricultural drought monitoring. **Agricultural and Forest Meteorology**, v. 133, n. 1–4, p. 69–88, 2005. Disponível em: <https://doi.org/10.1016/j.agrformet.2005.07.012>.

NÓBREGA, R. S.; FARIAS, R. F. L.; SANTOS, C. A. C. Variabilidade temporal e espacial da precipitação pluviométrica em Pernambuco através de índices de extremos climáticos. **Revista brasileira de meteorologia**, v. 30, n. 2, p. 171–180, 2015.

PAN, M.; SAHOO, A. K.; WOOD, E. F. Improving soil moisture retrievals from a physically-based radiative transfer model. **Remote Sensing of Environment**, v. 140, p. 130–140, 2014. Disponível em: <https://doi.org/10.1016/j.rse.2013.08.020>.

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, n. 6, p. 377, 2017. Disponível em: <https://doi.org/10.3390/w9060377>.

PETROPOULOS, G. P.; IRELAND, G.; BARRETT, B. Surface soil moisture retrievals from remote sensing: Current status, products & future trends. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 83, p. 36-56, 2015. Disponível em: <https://doi.org/10.1016/j.pce.2015.02.009>.

REICHLE, R. H. et al. Assessment of the SMAP Level-4 surface and root-zone soil moisture product using *in situ* measurements. **Journal of Hydrometeorology**, v. 18, n. 10, p. 2621–2645, 2017. Disponível em: <https://doi.org/10.1175/JHM-D-17-0063.1>.

ROBINSON, D. A.; CAMPBELL, C. S.; HOPMANS, J. W.; HORNBUCKLE, B. K.; JONES, S. B.; KNIGHT, R.; OGDEN, F.; SELKER, J.; WENDROTH, O. Soil Moisture Measurement for Ecological and Hydrological Watershed-Scale Observatories: A Review. **Vadose Zone Journal**, v. 7, n. 1, p. 358–389, 2008. Disponível em: <https://doi.org/10.2136/vzj2007.0143>.

ROBOCK, A.; VINNIKOV, K. Y.; SRINIVASAN, G.; ENTIN, J. K.; HOLLINGER, S. E.; SPERANSKAYA, N. A.; LIU, S.; NAMKHAL, A. The Global Soil Moisture Data Bank. **Bulletin of the American Meteorological Society**, v. 81, n. 6, p. 1281–1299, 2000. Disponível em: [https://doi.org/10.1175/1520-0477\(2000\)081<1281:TGSMDB>2.3.CO;2](https://doi.org/10.1175/1520-0477(2000)081<1281:TGSMDB>2.3.CO;2).

RODELL, M.; HOUSER, P. R.; JAMBOR, U.; GOTTSCHALCK, J.; MITCHELL, K.; MENG, C. J.; ARSENAULT, K.; COSGROVE, B.; RADA KOVICH, J.; BOSILOVICH, M.; ENTIN, J. K.; WALKER, J. P.; LOHMANN, D.; TOLL, D. The Global Land Data Assimilation System. **Bulletin of the American Meteorological Society**, v. 85, n. 3, p. 381–394, 2004. Disponível em: <https://doi.org/10.1175/BAMS-85-3-381>.

ROSSATO, L. Estimativa da umidade superficial do solo a partir de sensoriamento remoto por micro-ondas passiva sobre a América do Sul. **Tese de Doutorado - Instituto Nacional de Pesquisas Espaciais**, São José dos Campos, São Paulo, Brasil, 2010.

RUOSTEENOJA, K.; MARKKANEN, T.; VENÄLÄINEN, A.; RÄISÄNEN, P.; PELTOLA, H. Seasonal soil moisture and drought occurrence in Europe in CMIP5 projections for the 21st century. **Climate Dynamics**, v. 50, n. 3–4, p. 1177–1192, 2018.

SABATER, J. M.; JARLAN, L.; CALVET, J. C.; BOUYSSSEL, F.; DE ROSNAY, P. From near-surface to root-zone soil moisture using different assimilation techniques. **Journal of Hydrometeorology**, v. 8, n. 2, p. 194–206, 2007. Disponível em: <https://doi.org/10.1175/JHM571.1>.

SAHOO, S.; CHAKRABORTY, S.; PHAM, Q. B.; SHARIFI, E.; SAMMEN, S. S.; VOJTEK, M.; VOJTEKOVÁ, J.; ELKHRACHY, I.; COSTACHE, R.; LINH, N. T. T. Recognition of district-wise groundwater stress zones using the GLDAS-2 catchment land surface model during lean season in the Indian state of West Bengal. **Acta Geophysica**, v. 69, n. 1, p. 175–198, 2021.

SMOS-BEC. SMOS-BEC Land Products Description, v. 1.0, 2018.

SOUZA, A. G. S. S. Índice de seca no Estado de Pernambuco utilizando dados de umidade do solo do Satélite SMOS. **Tese de Doutorado – Universidade Federal de Pernambuco**, 2019.

SOUZA, A. G. S. S.; RIBEIRO NETO, A.; ROSSATO, L.; ALVALÁ, R. C. S.; SOUZA, L. L. Use of SMOS L3 Soil Moisture Data: Validation and Drought Assessment for Pernambuco State, Northeast Brazil. **Remote Sensing**, v. 10, n. 8, p. 1314, 2018. Disponível em: <https://doi.org/10.3390/rs10081314>.

SOUZA, A.G.S.S.; RIBEIRO NETO, A.; SOUZA, L.L. Avaliação da seca no Estado de Pernambuco utilizando o Índice da Condição da Vegetação (VCI), umidade do solo do satélite SMOS e precipitação. In: **XIX Simpósio Brasileiro de Sensoriamento Remoto, 2019**, Santos, Anais [...]. Santos - SP, 2019.

SOUZA, A. G. S. S.; RIBEIRO NETO, A.; SOUZA, L. L. Soil moisture-based index for agricultural drought assessment: SMADI application in Pernambuco State-Brazil. **Remote Sensing of Environment**, v. 252, p. 112124, 2021. Disponível em: <https://doi.org/10.1016/j.rse.2020.112124>.

STEFAN, V. G.; INDRIIO, G.; ESCORIHUELA, M. J.; QUINTANA-SEGUÍ, P.; VILLAR, J. M. High-resolution smap-derived root-zone soil moisture using an exponential filter model calibrated per land cover type. **Remote Sensing**, v. 13, n. 6, 2021. Disponível em: <https://doi.org/10.3390/rs13061112>.

STROUD, P. A recursive exponential filter for time-sensitive data. **Los Alamos National Laboratory**, Tech. Rep. LAUR-99-5573, v. 131, 1999. Disponível em: <http://public.lanl.gov/stroud/ExpFilter/ExpFilter995573.pdf>.

SVOBODA, M.; LECOMTE, D.; HAYES, M.; HEIM, R.; GLEASON, K.; ANGEL, J.; RIPPEY, B.; TINKER, R.; PALECKI, M.; STOOKSBURY, D. The drought monitor. **Bulletin of the American Meteorological Society**, v. 83, n. 8, p. 1181–1190, 2002.

TIMM, A. U. Estimativa dos fluxos de energia superficiais utilizando o modelo de superfície NOAA modificado para culturas alagadas. **Tese de Doutorado – Universidade Federal de Santa Maria**, p. 121–124, 2011.

TOBIN, K. J.; TORRES, R.; CROW, W. T.; BENNETT, M. E. Multi-decadal analysis of root-zone soil moisture applying the exponential filter across CONUS. **Hydrology and Earth System Sciences Discussions**, p. 1–33, 2017. Disponível em: <https://doi.org/10.5194/hess-2017-118>.

VAN LOON, A. F.; VAN LANEN, H. A. J. Making the distinction between water scarcity and drought using an observation-modeling framework. **Water Resources Research**, v. 49, n. 3, p. 1483–1502, 2013.

VAN LOON, A. F.; STAHL, K.; DI BALDASSARRE, G.; CLARK, J.; RANGE-CROFT, S.; WANDERS, N.; GLEESON, T.; VAN DIJK, A. I. J. M.; TALLAKSEN, L. M.; HANNAFORD, J. Drought in a human-modified world: reframing drought definitions, understanding, and analysis approaches. **Hydrology and Earth System Sciences**, v. 20, n. 9, p. 3631–3650, 2016.

VEREECKEN, H.; HUISMAN, J. A.; PACHEPSKY, Y.; MONTZKA, C.; VAN DER KRUK, J.; BOGENA, H.; WEIHERMÜLLER, L.; HERBST, M.; MARTINEZ, G.; VANDERBORGHT, J. On the spatio-temporal dynamics of soil moisture at the field scale. **Journal of Hydrology**, v. 516, n. August, p. 76–96, 2014. Disponível em: <https://doi.org/10.1016/j.jhydrol.2013.11.061>.

WAGNER, W.; LEMOINE, G.; ROTT, H. A method for estimating soil moisture from ERS Scatterometer and soil data. **Remote Sensing of Environment**, v. 70, n. 2, p. 191–207, 1999. Disponível em: [https://doi.org/10.1016/S0034-4257\(99\)00036-X](https://doi.org/10.1016/S0034-4257(99)00036-X).

WANG, A.; LETTENMAIER, D. P.; SHEFFIELD, J. Soil moisture drought in China, 1950–2006. **Journal of Climate**, v. 24, n. 13, p. 3257–3271, 2011. Disponível em: <https://doi.org/10.1175/2011JCLI3733.1>.

WANG, W.; ERTSEN, M. W.; SVOBODA, M. D.; HAFEEZ, M. Propagation of drought: From meteorological drought to agricultural and hydrological drought. **Advances in Meteorology**, v. 2016, n. 4, 2016. Disponível em: <https://doi.org/10.1155/2016/6547209>.

WEI, M. Soil moisture: Report of a workshop held in Tiburon, California, 25–27 January 1994. **NASA Headquarters**, 1995.

WIGNERON, J. P.; WALDTEUFEL, P.; CHANZY, A.; CALVET, J. C.; KERR, Y. Two-dimensional microwave interferometer retrieval capabilities over land surfaces (SMOS Mission). **Remote Sensing of Environment**, v. 73, n. 3, p. 270–282, 2000. Disponível em: [https://doi.org/10.1016/S0034-4257\(00\)00103-6](https://doi.org/10.1016/S0034-4257(00)00103-6).

WILHITE, D. A.; SVOBODA, M. D.; HAYES, M. J. Understanding the complex impacts of drought: A key to enhancing drought mitigation and preparedness. **Water Resources Management**, v. 21, n. 5, p. 763–774, 2007. Disponível em: <https://doi.org/10.1007/s11269-006-9076-5>.

WILLIAMS, M.; RICHARDSON, A. D.; REICHSTEIN, M.; STOY, P. C.; PEYLIN, P.; VERBEECK, H.; CARVALHAIS, N.; JUNG, M.; HOLLINGER, D. Y.; KATTGE, J.; LEUNING, R.; LUO, Y.; TOMELLERI, E.; TRUDINGER, C. M.; WANG, Y. P. Improving land surface models with FLUXNET data. **Biogeosciences**, v. 6, n. 7, p. 1341–1359, 2009. Disponível em: <https://doi.org/10.5194/bg-6-1341-2009>.

WU, J.; MIAO, C.; ZHENG, H.; DUAN, Q.; LEI, X.; LI, H. Meteorological and Hydrological Drought on the Loess Plateau, China: Evolutionary Characteristics, Impact, and Propagation. **Journal of Geophysical Research: Atmospheres**, v. 123, n. 20, p. 11,569–11,584, 2018. Disponível em: <https://doi.org/10.1029/2018JD029145>.

XU, C.; QU, J. J.; HAO, X.; COSH, M. H.; PRUEGER, J. H.; ZHU, Z.; GUTENBERG, L. Downscaling of surface soil moisture retrieval by combining MODIS/Landsat and *in situ* measurements. **Remote Sensing**, v. 10, n. 2, 2018. Disponível em: <https://doi.org/10.3390/rs10020210>.

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. Disponível em: <https://doi.org/10.5194/hess-16-3199-2012>.

YE, X.; LI, X.; XU, C. Y.; ZHANG, Q. Similarity, difference and correlation of meteorological and hydrological drought indices in a humid climate region - The Poyang Lake catchment in China. **Hydrology Research**, v. 47, n. 6, p. 1211–1223, 2016. Disponível em: <https://doi.org/10.2166/nh.2016.214>.

ZAWADZKI, J.; KĘDZIOR, M. Soil moisture variability over Odra watershed: Comparison between SMOS and GLDAS data. **International Journal of Applied Earth Observation and Geoinformation**, v. 45, p. 110–124, 2016. Disponível em: <https://doi.org/10.1016/j.jag.2015.03.005>.

ZERI, M. et al. Importance of including soil moisture in drought monitoring over the Brazilian semiarid region: An evaluation using the JULES model, in situ observations, and remote sensing. *Climate Resilience and Sustainability*, 2021. Disponível em: <https://doi.org/10.1002/cli2.7>

ZERI, M. et al. Tools for communicating agricultural drought over the Brazilian semiarid using the soil moisture index. **Water**, v. 10, n. 10, p. 1421, 2018. Disponível em: <https://doi.org/10.3390/w10101421>.

ZHANG, D.; TANG, R.; ZHAO, W.; TANG, B.; WU, H.; SHAO, K.; LI, Z. L. Surface soil water content estimation from thermal remote sensing based on the temporal variation of land surface temperature. **Remote Sensing**, v. 6, n. 4, p. 3170–3187, 2014. Disponível em: <https://doi.org/10.3390/rs6043170>.

ZHANG, G.; SU, X.; AYANTOBO, O. O; FENG, K. Drought monitoring and evaluation using ESA CCI and GLDAS-Noah soil moisture datasets across China. **Theoretical and Applied Climatology**, v. 144, n. 3, p. 1407–1418, 2021.

ZINK, M.; SAMANIEGO, L.; KUMAR, R.; THOBER, S.; MAI, J.; SCHAFER, D.; MARX, A. The German drought monitor. **Environmental Research Letters**, v. 11, n. 7, 2016. Disponível em: <https://doi.org/10.1088/1748-9326/11/7/074002>.