



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2023/04.05.22.00-TDI

ANÁLISE MULTI-MODELOS DO PAPEL DA UMIDADE DO SOLO NOS PADRÕES DE SECA DA AMÉRICA DO SUL

Giovana Deponte Galetti

Dissertação de Mestrado do
Curso de Pós-Graduação em
Meteorologia, orientada pelos
Dr. Luis Gustavo Goncalves De
Goncalves, aprovada em 17 de
março de 2023.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/48RK8BB>>

INPE
São José dos Campos
2023

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2023/04.05.22.00-TDI

ANÁLISE MULTI-MODELOS DO PAPEL DA UMIDADE DO SOLO NOS PADRÕES DE SECA DA AMÉRICA DO SUL

Giovana Deponte Galetti

Dissertação de Mestrado do
Curso de Pós-Graduação em
Meteorologia, orientada pelos
Dr. Luis Gustavo Goncalves De
Goncalves, aprovada em 17 de
março de 2023.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/48RK8BB>>

INPE
São José dos Campos
2023

Dados Internacionais de Catalogação na Publicação (CIP)

Galetti, Giovana Deponte.

G132a Análise multi-modelos do papel da umidade do solo nos padrões de seca da América do Sul / Giovana Deponte Galetti. – São José dos Campos : INPE, 2023.

xxxii + 118 p. ; (sid.inpe.br/mtc-m21d/2023/04.05.22.00-TDI)

Dissertação (Mestrado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2023.

Orientador : Dr. Luis Gustavo Goncalves De Goncalves.

1. Umidade do solo. 2. Secas. 3. Modelos de superfície. I. Título.

CDU 551.577.38:631.432.2



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÃO



INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS
Serviço de Pós-Graduação - SEPGR

DEFESA FINAL DE DISSERTAÇÃO DE GIOVANA DEPONTE GALETTI
BANCA Nº 035/2023, REGISTRO 272839/2020

No dia 17 de março de 2023, as 10h, em formato online (pela internet), o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Meteorologia. O trabalho precisa da incorporação das correções sugeridas pela Banca e revisão final pelo(s) orientador(es).

Título: "Análise multi-modelos do papel da umidade do solo nos padrões de seca da América do Sul"

Membros da Banca:

Dr. Julio Pablo Reyes Fernandez – Presidente – INPE

Dr. Luis Gustavo Goncalves De Goncalves – Orientador – INPE

Dr. Paulo Yoshio Kubota – Membro Interno – INPE

Dr. Heliofabio Barros Gomes – Membro Externo – Universidade Federal de Alagoas / ICAT/UFAL



Documento assinado eletronicamente por **Julio Pablo Reyes Fernandez, Tecnologista**, em 17/03/2023, às 15:52 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **LUIS GUSTAVO GONÇALVES DE GONÇALVES (E), Usuário Externo**, em 20/03/2023, às 08:48 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **HELIOFABIO BARROS GOMES (E), Usuário Externo**, em 21/03/2023, às 17:32 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Paulo Yoshio Kubota, Pesquisador**, em 22/03/2023, às 10:09 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <https://sei.mcti.gov.br/verifica.html>, informando o código verificador **10929087** e o código CRC **B2A4C9F6**.

“É muito melhor lançar-se em busca de conquistas grandiosas, mesmo expondo-se ao fracasso, do que alinhar-se com os pobres de espírito, que nem gozam muito nem sofrem muito, porque vivem numa penumbra cinzenta, onde não conhecem nem vitória, nem derrota”.

THEODORE ROOSEVELT

A meus pais João Fernando Galetti Junior e Sonia Aparecida Deponte Galetti, à minha irmã Marcela Deponte Galetti, ao meu namorado Vitor Mora Fossatto e amigos que fizeram parte desta caminhada.

AGRADECIMENTOS

Primeiramente agradecer à Deus, meus pais e minha irmã que nunca duvidaram da minha capacidade quando eu mesma duvidei. Sempre lembrando da minha força, capacidade e trajetória que me trouxe até aqui. Deixo os meus mais sinceros agradecimento por todo apoio nesta caminhada.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES).

Ao meu orientador Luis Gustavo Gonçalves de Goç Alves por todo os ensinamentos compartilhados e ajuda. E também aos meus colegas do grupo de trabalho que me ajudaram tanto.

Aos amigos que eu fiz ao longo da vida acadêmica e aqueles conquistei durante a trajetória do mestrado, o meu mais sincero obrigado. Enfrentar o mestrado em meio a uma pandemia foi realmente desafiador, mas na companhia de vocês o processo ficou mais tranquilo e divertido.

Ao meu namorado, que sempre me apoiou e confiou na minha capacidade, me ajudando, dando apoio e segurando minha mão nos momentos mais difíceis.

Obrigada a todos que continuaram do meu lado nesse processo.

RESUMO

Considerada como uma importante variável para o ciclo de água e energia, a Umidade do Solo (US) desempenha um papel fundamental nas interações entre a superfície terrestre e a atmosfera. O objetivo dessa dissertação foi realizar uma análise multimodelos do papel da US nos padrões de secas da América do Sul assim como verificar a sensibilidade destes modelos com a adição da forçante de radiação. Os objetivos específicos foram (a) analisar os padrões de US e sua relação com as forçantes atmosféricas, sendo elas o *Global Data Assimilation System* (GDAS), o *Multi-satellite Retrievals for GPM* (MERGE) e *Clouds and the Earth's Radiant Energy System* (CERES) durante os últimos 20 anos sobre a América do Sul utilizando as simulações multimodelos do *South American Land Data Assimilation System* (SALDAS); (b) avaliar a destreza das simulações do SALDAS durante o período de estudo com relação à referências de modelagem *offline*, modelagem acoplada e observação de satélite: *Global Land Data Assimilation* (GLDAS), Reanálise do *ECMWF Reanalysis v5* (ERA-5) e *European Space Agency Climate Change Initiative* (ESA-CCI) respectivamente; (c) Analisar a destreza dos modelos de superfície para os eventos de seca ocorridos durante este período. Para gerar os campos de US foram utilizados três modelos de superfície, sendo eles o *National Oceanic and Atmospheric Administration- Multiparameterization* (Noah-MP), *Catchment Land Surface Model* (CLSM-F2.5) e o *Integrated Biosphere Simulator* (IBIS) que foram forçados com diferentes dados de entrada (GDAS, MERGE e CERES). Os resultados foram comparados com o ERA-5, ESA-CCI e GLDAS, para avaliar a destreza do SALDAS através de estatísticas como: coeficiente de correlação de Pearson, raiz quadrada do erro médio, desvio das médias, desvio padrão e foi feito o diagrama de Taylor. Para fazer a comparação com os eventos de seca, foram utilizados os dados de SPI-1 disponibilizados pelo Centro de Previsão do Tempo e Estudos Climáticos do Instituto Nacional de Pesquisas Espaciais (CPTEC/INPE). Como resultados, foram obtidos que os diferentes modelos respondem de forma bem diversa à variações nos campos de radiação e precipitação, mas de forma geral a inclusão do CERES e MERGE trouxeram impactos positivos nas simulações numéricas. Quanto às comparações com as bases de dados de referência, os modelos numéricos apresentaram boa performance, principalmente quando comparados com o GLDAS. Em relação às secas, houve boa destreza dos modelos em estimar os padrões de seca nos diversos eventos estudados neste trabalho, incluindo período, intensidade e extensão.

Palavras-chave: Umidade do solo. Secas. Modelos de Superfície.

MULTI-MODEL ANALYSIS OF THE ROLE OF SOIL MOISTURE IN DROUGHT PATTERNS IN SOUTH AMERICA

ABSTRACT

Considered as an important variable for the water and energy cycle, Soil Moisture (SM) makes a fundamental role in the interactions between the Earth's surface and the atmosphere. The aim of this dissertation was to perform a multi-model analysis of the role of US in drought patterns in South America as well as to verify the sensitivity of these models with the addition of radiation forcing. The specific objectives were (a) to analyze the SM patterns and their relationship with atmospheric forcings, namely the Global Data Assimilation System (GDAS), the Multi-satellite Retrievals for GPM (MERGE) and Clouds and the Earth's Radiant Energy System (CERES) over the last 20 years over South America using the multi-model simulations of the South American Land Data Assimilation System (SALDAS); (b) evaluate the ability of the SALDAS simulations during the study period with respect to off-line modeling, coupled modeling and satellite observation references: Global Land Data Assimilation (GLDAS), ECMWF Reanalysis v5 (ERA-5) and European Space Agency Climate Change Initiative (ESA-CCI) respectively; (c) Analyze the ability of surface models for drought events that occurred during this period. To generate the US fields, three surface models were used, namely the National Oceanic and Atmospheric Administration-Multiparameterization (Noah-MP), Catchment Land Surface Model (CLSM-F2.5) and the Integrated Biosphere Simulator (IBIS) that were forced with different input data (GDAS, MERGE and CERES). The results were compared with the ERA-5, ESA-CCI and GLDAS, to evaluate the skill of SALDAS through statistics such as: Pearson's correlation coefficient, square root of the mean error, mean deviation, standard deviation and the diagram was made from Taylor. To make the comparison with drought events, SPI-1 data provided by the Center for Weather Forecast and Climatic Studies of the National Institute for Space Research (CPTEC/INPE) were used. As a result, it was obtained that the different models respond very differently to variations in the radiation and precipitation fields, but in general the inclusion of CERES and MERGE brought positive impacts in the numerical simulations. As for comparisons with the reference databases, the numerical models performed well, especially when compared with the GLDAS. With regard to droughts, the models were good at estimating drought patterns in the different events studied in this work, including period, intensity and extension.

Keywords: Soil Moisture. Droughts. Land Surface Model.

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 <i>Feedback</i> entre US, precipitação e FCL. O símbolo P representa a precipitação, η a US e λE o FCL.	6
2.2 <i>Feedback</i> entre a US, a evapotranspiração e a temperatura.	7
2.3 Caracterização Esquemática das ZS e ZNS no subsolo	10
3.1 Características do LIS.	24
3.2 Esquema representando os processos físicos simulados pelo NOAH-MP.	26
3.3 Instrumentos de micro-ondas usados para a geração de produtos de dados de US.	32
3.4 Esquematisação dos experimentos realizados no estudo.	36
4.1 Diferença entre a radiação incidente na superfície (Experimento A e B), comparando os três modelos (Noah-MP, CLSM e IBIS).	39
4.2 Correlação dos dados obtidos pelos três modelos, em relação aos dados do ERA5, utilizando as forçantes meteorológicas GDAS e MERGE.	41
4.3 Correlação dos dados obtidos pelos três modelos, em relação aos dados do ERA5, utilizando as três forçantes meteorológicas.	42
4.4 Correlação dos dados obtidos pelos três modelos, em relação aos dados do ESA-CCI, utilizando as duas forçantes meteorológicas (GDAS e MERGE).	44
4.5 Correlação dos dados obtidos pelos três modelos, em relação aos dados do ESA-CCI, utilizando as três forçantes meteorológicas.	45
4.6 Correlação dos dados obtidos pelos três modelos, em relação aos dados do GLDAS, utilizando as duas forçantes meteorológicas.	46
4.7 Correlação dos dados obtidos pelos três modelos, em relação aos dados do GLDAS, utilizando as três forçantes meteorológicas.	47
4.8 RMSE dos dados obtido pelos três modelos, em relação aos dados do ERA5, utilizando as duas forçantes meteorológicas.	48
4.9 RMSE dos dados obtidos pelos três modelos, em relação aos dados do ERA5, utilizando as três forçantes meteorológicas.	49
4.10 RMSE dos dados obtidos pelos três modelos, em relação aos dados do ESA-CCI, utilizando as forçantes meteorológicas GDAS e MERGE.	50
4.11 RMSE dos dados obtidos pelos três modelos, em relação aos dados do ESA-CCI, utilizando as três forçantes meteorológicas.	51
4.12 RMSE dos dados obtidos pelos três modelos, em relação aos dados do GLDAS, utilizando as duas forçantes meteorológicas (GDAS e MERGE).	52

4.13	RMSE dos dados obtido pelos três modelos, em relação aos dados do GLDAS, utilizando as três forçantes meteorológicas.	52
4.14	MBE dos dados obtidos pelos três modelos, em relação aos dados do ERA5, utilizando as forçantes meteorológicas GDAS e MERGE.	53
4.15	MBE dos dados obtidos pelos três modelos, em relação aos dados do ERA5, utilizando as três forçantes meteorológicas.	54
4.16	MBE dos dados obtidos pelos três modelos, em relação aos dados do ESA-CCI, utilizando as duas forçantes meteorológicas (GDAS e MERGE).	55
4.17	MBE dos dados obtidos pelos três modelos, em relação aos dados do ESA-CCI, utilizando as três forçantes meteorológicas.	56
4.18	MBE dos dados obtidos pelos três modelos, em relação aos dados do GLDAS, utilizando as duas forçantes meteorológicas (GDAS e MERGE).	57
4.19	MBE dos dados obtidos pelos três modelos, em relação aos dados do GLDAS, utilizando as três forçantes meteorológicas.	57
4.20	Desvio padrão dos modelos (Noah-MP, CLSM, IBIS e GLDAS) utilizando as duas forçantes meteorológicas GDAS e MERGE.	58
4.21	Desvio Padrão dos modelos (Noah-MP, CLSM, IBIS e GLDAS) utilizando as três forçantes meteorológicas.	59
4.22	Diagrama de Taylor para os modelos utilizando as forçantes GDAS, MERGE e CERES.	60
4.23	Diagrama de Taylor para os modelos utilizando as forçantes GDAS, MERGE e CERES.	64
4.24	Análise da seca de 2005 na região Amazônica obtida pelo SPI-1, Noah-MP, CLSM e IBIS.	66
4.25	Análise da seca de 2010 na região Amazônica obtida pelo SPI-1, Noah-MP, CLSM e IBIS.	67
4.26	Análise da seca de 2015 na região Amazônica obtida pelo SPI-1, Noah-MP, CLSM e IBIS.	68
4.27	Análise da seca de 2014 no Sistema Cantareira (SP) obtida pelo SPI-1, Noah-MP, CLSM e IBIS.	70
A.1	Diagrama de Taylor - ERA-5 - Região NE.	89
A.2	Diagrama de Taylor - ERA-5 - Região NO.	90
A.3	Diagrama de Taylor - ERA-5 - Região AM.	91
A.4	Diagrama de Taylor - ERA-5 - Região SU.	92
A.5	Diagrama de Taylor - ERA-5 - Região PA.	93
A.6	Diagrama de Taylor - ESA-CCI - Região NE.	94
A.7	Diagrama de Taylor - ESA-CCI - Região NO.	95
A.8	Diagrama de Taylor - ESA-CCI - Região AM.	96

A.9	Diagrama de Taylor - ESA-CCI - Região SU.	97
A.10	Diagrama de Taylor - ESA-CCI - Região PA.	98
A.11	Diagrama de Taylor - GLDAS- Região NE.	99
A.12	Diagrama de Taylor - GLDAS- Região NO.	100
A.13	Diagrama de Taylor - GLDAS- Região AM.	101
A.14	Diagrama de Taylor - GLDAS- Região SU.	102
A.15	Diagrama de Taylor - GLDAS- Região PA.	103
A.16	Diagrama de Taylor - ERA-5 - Região NE.	104
A.17	Diagrama de Taylor - ERA-5 - Região NO.	105
A.18	Diagrama de Taylor - ERA-5 - Região AM.	106
A.19	Diagrama de Taylor - ERA-5 - Região SU.	107
A.20	Diagrama de Taylor - ERA-5 - Região PA.	108
A.21	Diagrama de Taylor - ESA-CCI - Região NE.	109
A.22	Diagrama de Taylor - ESA-CCI - Região NO.	110
A.23	Diagrama de Taylor - ESA-CCI - Região AM.	111
A.24	Diagrama de Taylor - ESA-CCI - Região SU.	112
A.25	Diagrama de Taylor - ESA-CCI - Região PA.	113
A.26	Diagrama de Taylor - GLDAS- Região NE.	114
A.27	Diagrama de Taylor - GLDAS- Região NO.	115
A.28	Diagrama de Taylor - GLDAS- Região AM.	116
A.29	Diagrama de Taylor - GLDAS- Região SU.	117
A.30	Diagrama de Taylor - GLDAS- Região PA.	118

LISTA DE TABELAS

	<u>Pág.</u>
2.1 Categorias de classificação do Índice de Severidade de Seca de Palmer (PDSI).	15
2.2 Valores do SPI com as categorias de secas.	16
3.1 Valores correspondentes do SPI e do Percentil.	34

LISTA DE ABREVIATURAS E SIGLAS

4D-Var	–	<i>Four-Dimensional Variational Data Assimilation Technique</i>
AAS	–	Armazenamento de Água Subterrânea
AAT	–	Armazenamento de Água na Terra
AD	–	Assimilação de Dados
AEN	–	Água Equivalente da Neve
AMI-WS	–	<i>Active Microwave Instrument - Windscat</i>
AMS	–	<i>Microwave Scanning Radiometer</i>
AMSR-E	–	<i>Microwave Scanning Radiometer Earth observing system</i>
AS	–	América do Sul
ASCAT	–	<i>WindSat e Scatterometer</i>
CD	–	Constante Dielétrica
CERES	–	<i>Clouds and the Earth's Radiant Energy System</i>
CH	–	Ciclo Hidrológico
CI	–	Condições Iniciais
CLC	–	Camada Limite Convectiva
CLP	–	Camada Limite Planetária
CLSM-F2.5	–	<i>Catchment Land Surface Model Fortuna</i>
CLSM	–	<i>Catchment Land Surface Model</i>
CPTEC	–	Centro de Previsão do Tempo e Estudos Climáticos
DMSP	–	<i>Defense Meteorological Satellite Program</i>
ECMWF	–	<i>European Centre for Medium-Range Weather Forecasts</i>
ECV	–	<i>Essential Climate Variables</i>
EOS	–	<i>Earth Observation System</i>
ERA-5	–	<i>ECMWF Reanalysis v5</i>
ERS	–	<i>European Remote Sensing Satellite</i>
ESA	–	<i>European Space Agency</i>
ESA-CCI	–	<i>European Space Agency Climate Change Initiative</i>
FCL	–	Fluxo de Calor Latente
FCS	–	Fluxo de Calor Sensível
FE	–	Fração Evaporativa
FLDAS	–	<i>Famine Early Warning Systems Network- Land Data Assimilation System</i>
GDAS	–	<i>Global Data Assimilation System</i>
GFS	–	<i>Global Forecast System</i>
GLACE	–	<i>Global Land-Atmosphere Coupling Experiment</i>
GLDAS	–	<i>Global Land Data Assimilation</i>
GRACE	–	<i>Gravity Recovery and Climate Experiment</i>
GTS	–	<i>Global Telecommunications System</i>
IAF	–	Índice de Área Foliar
IBIS	–	<i>Integrated Biosphere Simulator</i>
ID	–	Interceptação do Dossel
JAEA	–	<i>Japan Aerospace Exploration Agency</i>

JPSS	–	<i>Joint Polar Satellite System</i>
KLDAS	–	<i>Korea Land Data Assimilation System</i>
LBA	–	<i>Large-scale Biosphere-Atmosphere Experiment in Amazonia</i>
LDAS	–	<i>Land Data Assimilation System</i>
LIS	–	<i>Land Information System</i>
LSM	–	<i>Land Surface Model</i>
MCGA	–	Modelo de Circulação Geral da Atmosfera
MERGE	–	<i>Multi-satellitE Retrievals for GPM</i>
METOP	–	<i>Meteorological Operational Satellite</i>
MIRAS	–	<i>Microwave Scanning Radiometer Earth observing system</i>
MODIS	–	<i>MODerate-resolution Imaging Spectroradiometer</i>
NASA	–	<i>National Aeronautics and Space Administration</i>
NCA	–	<i>National Climate Assessment</i>
NCEP	–	<i>National Center for Environmental Prediction</i>
NLDAS	–	<i>North American Land Data Assimilation System</i>
NOAA	–	<i>National Oceanic and Atmospheric Administration</i>
NOAH-MP	–	<i>NOAH- Multiparameterization</i>
ORT	–	Orçamento de Radiação na Terra
PDSI	–	<i>Palmer Drought Severity Index</i>
PNTC	–	Previsão Numérica de Tempo e Clima
r	–	Coefficiente de Correlação
RMSE	–	<i>Root-Mean-Square Error</i>
SALDAS	–	<i>South American Land Data Assimilation System</i>
SARR	–	<i>South America Regional Reanalysis</i>
SCAN	–	<i>Soil Climate Analysis Network</i>
SMAP	–	<i>Soil Moisture Active Passive</i>
SMDI	–	<i>Soil Moisture Deficit Index</i>
SMMR	–	<i>Scanning Multichannel Microwave Radiometer</i>
SMOS	–	<i>Soil Moisture and Ocean Salinity</i>
SPI	–	<i>Standardized Precipitation Index</i>
SR	–	Sensoriamento Remoto
SSM	–	<i>Special Sensor Microwave Imager</i>
SWSI	–	<i>Surface Water Supply Index</i>
TDR	–	Tempo de Domínio de Reflectometria
TMI	–	<i>Microwave Imager</i>
TRMM	–	<i>Tropical Rainfall Measuring Mission</i>
TS	–	/Temperatura Superficial
US	–	Umidade do Solo
USGS	–	<i>United States Geological Survey</i>
USZR	–	Umidade do Solo na Zona de Raiz
VIIRS	–	<i>Visible Infrared Imaging Radiometric Suite</i>
WLDAS	–	<i>Western Land Data Assimilation System</i>
WRF	–	<i>Weather Research and Forecasting</i>
ZNS	–	Zona Não Saturada
ZR	–	Zona de Raízes
ZS	–	Zona Saturada

- ZSup – Zona Superficial
- ZUS – Zona de Umidade do Solo

LISTA DE SÍMBOLOS

P	–	Precipitação
λE	–	Fluxo de Calor Latente
η	–	Umidade do Solo
r	–	Correlação de Pearson
x_i	–	Valor predito pelo modelo
x'	–	Média dos valores simulados
y_i	–	Valores observados
y'	–	Média dos valores observado
y_i	–	Valor da observação
\hat{y}_i	–	Variável simulada pelo modelo

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Objetivo	3
1.1.1 Objetivos específicos	3
2 REVISÃO BIBLIOGRÁFICA	5
2.1 Umidade do Solo	5
2.1.1 Perfil vertical de umidade no solo	8
2.1.2 Medidas de Umidade do Solo	10
2.2 Secas	13
2.3 Modelagem de superfície terrestre	17
2.3.1 <i>Land Surface Model</i>	17
2.3.2 <i>Land Information System</i>	20
2.4 <i>South American Land Data Assimilation System</i>	21
3 METODOLOGIA	23
3.1 Base de dados utilizadas	23
3.1.1 Sistema de Informação da Terra (LIS)	23
3.1.2 Modelos de superfície:	25
3.1.2.1 Noah-MP	25
3.1.2.2 CLSM-F2.5	26
3.1.2.3 IBIS	27
3.1.3 Forçantes meteorológicas	28
3.1.3.1 GDAS	28
3.1.3.2 MERGE	29
3.1.3.3 CERES	29
3.1.4 Dados de referência	30
3.1.4.1 GLDAS	30
3.1.4.2 Reanálise ERA-5	30
3.1.4.3 ESA-CCI	31
3.2 Percentil de Umidade do Solo	33
3.3 Standard Precipitation Index (SPI)	33
3.4 Descrição da metodologia	34
3.5 Análises estatísticas	37

3.5.1	Coeficiente de Correlação de Pearson	37
3.5.2	RMSE	37
3.5.3	MBE	38
3.5.4	Desvio padrão	38
4	RESULTADOS E DISCUSSÕES	39
4.1	Análise estatística dos padrões de US e sua relação com as forçantes atmosféricas (GDAS, MERGE e CERES)	39
4.2	Análise estatística dos padrões de US em comparação com a base de dados de referência	40
4.2.1	Correlação	41
4.2.1.1	ERA5	41
4.2.1.2	ESA-CCI	43
4.2.1.3	GLDAS	46
4.2.2	RMSE	48
4.2.2.1	ERA5	48
4.2.2.2	ESA-CCI	50
4.2.2.3	GLDAS	51
4.2.3	MBE	53
4.2.3.1	ERA5	53
4.2.3.2	ESA-CCI	55
4.2.3.3	GLDAS	56
4.2.4	Desvio padrão	58
4.3	Diagrama de Taylor	59
4.3.1	GDAS, MERGE e CERES	59
4.3.2	GDAS e MERGE	62
4.4	Estudos de caso de secas no Brasil	65
4.4.1	Região Amazônica	65
4.4.1.1	2005	66
4.4.1.2	2010	67
4.4.1.3	2015	68
4.4.1.4	São Paulo - 2014	68
5	CONCLUSÃO	73
5.1	Sugestões para trabalhos futuros	74
	REFERÊNCIAS BIBLIOGRÁFICAS	77
	APÊNDICE A- DIAGRAMA DE TAYLOR	89

A.1	Diagrama de Taylor para as rodadas dos modelos com GDAS e MERGE	89
A.2	Diagrama de Taylor para as rodadas dos modelos com GDAS, MERGE E CERES	104

1 INTRODUÇÃO

A umidade do solo (US) é definida como a quantidade de água contida no solo insaturado em uma base volumétrica ou gravimétrica (HILLEL et al., 1998). Segundo Maggioni e Houser (2017), a umidade da superfície e da zona radicular são variáveis-chave para o ciclo da água e energia, pois representam o armazenamento terrestre desses balanços, controlando efetivamente o equilíbrio entre os Fluxos de Calor Sensível (FCS) e Latente (FCL) na interface terra-atmosfera. Segundo Oki et al. (1999), a influência no balanço de energia na superfície da terra ocorre pois a disponibilidade de água exerce controle sobre a evapotranspiração e altera o albedo da superfície, além de afetar o escoamento superficial e a infiltração.

A água armazenada no solo é uma variável chave no sistema climático terrestre, pois possui grande relevância para os ciclos de água e energia, impactando também nas trocas de gases traços na terra, como por exemplo o dióxido de carbono. Por meio da partição da energia nos FCL e FCS, a US tem vários impactos nos processos climáticos, particularmente na temperatura do ar, estabilidade da camada limite e na precipitação (SENEVIRATNE et al., 2010) que serão melhor discutidos na Seção 2.2.

Segundo Entekhabi et al. (2010), a US é uma importante fonte de água para a atmosfera, de onde uma fração retorna à superfície na forma de precipitação, apresentando um processo de retroalimentação. Este processo é fundamental para a chuva em grandes bacias ou regiões centrais de continentes, como por exemplo a Bacia Amazônica. Além disso, quando há persistência de baixo teor de água no solo, a precipitação é reduzida, aumentando a probabilidade de ocorrência de seca. Os *feedbacks* entre a US e a precipitação são considerados importantes em muitas regiões para a previsão do tempo, conforme mostrado por Koster (1986). Outro aspecto importante desses *feedbacks* são os impactos que a variável em questão tem no início da convecção úmida local (TAYLOR, 2015), que varia regionalmente, dependendo da sensibilidade da evapotranspiração à US e da atmosfera à forçante do fluxo superficial (GUO et al., 2006).

Como o interesse dentro da comunidade científica no estudo das interações entre US e o clima aumentaram nas últimas décadas, a complexidade dos *feedbacks* envolvidos e a escassez de observações para caracterizar os processos relevantes também se tornaram cada vez mais aparentes. Algumas perspectivas promissoras estão se expandindo neste campo, tanto às ligadas à modelagem, validação e monitoramento dos processos relevantes, quanto ao desenvolvimento de aplicações como previsão de curto prazo e sazonal, além também de avaliações de secas (SENEVIRATNE et al.,

2010).

As secas podem ser caracterizadas pelo *déficit* das condições médias das variáveis do Ciclo Hidrológico (CH), ou seja, precipitação, US, água subterrânea, evapotranspiração e fluxo de rio (ANDERSON et al., 2013). Os eventos de secas podem ser divididos em quatro grupos (secas meteorológicas, agrícolas, hídricas e sócio-econômicas) e se diferem entre si com base em três características: intensidade, duração e extensão espaciais (WILHITE; GLANTZ, 1985). Há um total de 19.517 registros de episódios de secas e de estiagem no território brasileiro em um período de 1991 a 2012 segundo o Atlas Brasileiro de Desastres Naturais, causadas por diversos fatores meteorológicos e sociais, como por exemplo, períodos de *La Niña* que geralmente resultam em menos chuvas para as regiões central e sul do Brasil, bloqueios atmosféricos, características climáticas das regiões mais secas, entre outros fatores. De acordo com as características das secas, existem diferentes índices que são utilizados para caracterizá-las, os quais utilizam medições *in situ*, satélites ou uma combinação destes.

Uma problemática relacionada às medições *in situ* é a insuficiência de dados. Além de serem medições pontuais, não são capazes de fornecer informações em uma escala espacial abrangente. Uma forma de contornar esse problema é a utilização de medições realizadas por sensoriamento remoto (SR) e também por meio de *Land Surface Model* (LSM) que são modelos de superfície terrestre, que simulam numericamente a interação entre solo-vegetação-atmosfera (REICHLE et al., 2004). Os LSM são ferramentas importantes na produção de campos de US contínuos e espacialmente distribuídos, porém as previsões realizadas pelos LSM são afetadas pelas incertezas nas forçantes meteorológicas, parametrizações e formulações do próprio modelo (REICHLE et al., 2004). As observações por satélite representam impactos positivos significativos principalmente para as regiões que possuem grande escassez de dados ou para o caso de variáveis dificilmente observadas por medições *in situ*, como a US e temperatura superficial (SEHLER et al., 2019; CROW; WOOD, 2003; SCHMUGGE, 1983). Como apresentado no trabalho de (JUNG et al., 2020), as medições feitas pelo satélite ESA-CCI são capazes de capturar melhor o comportamento recente da US, no entanto, não é viável para detectar condições históricas de secas, e isso pode ser explicado pelo fato de que a qualidade dos dados do ESA-CCI estar relacionado com a qualidade dos dados utilizados em seu algoritmo.

Os LSM normalmente necessitam de três tipos de dados de entrada, sendo eles: condições iniciais (CI), condições de contorno e parametrizações que são funções do solo, vegetação, topografia e outras outras propriedades da superfície. Ao utilizar

essas entradas, os LSM resolvem as equações que governam o meio solo/vegetação, prevêm fluxos de superfície (FCS, FCL, CSL, escoamento, evaporação) e características do solo (umidade, temperatura, neve), fornecendo uma representação realista da transferência de massa, energia e momento entre uma superfície e a atmosfera (RODELL *et al.*, 2004). Alguns modelos mais modernos como o Noah- MP e o CLSM (um modelo de bacia de drenagem) possuem adicionalmente um módulo de água subterrânea, com 2 metros de profundidade no Noah-MP, de 1m no CLSM e 12m no IBIS o que auxilia nos cálculos do balanço hídrico.

A partir da forte relação entre precipitação e umidade do solo, demonstrada em diversos estudos científicos recentes, o foco do presente trabalho é entender os mecanismos e impactos da utilização da US no monitoramento das secas na AS, uma vez que as secas são caracterizadas como *déficit* das variáveis hidrometeorológicas. Esta verificação será feita através de uma avaliação multi-modelos onde será analisado o papel da US nos padrões de seca da AS.

1.1 Objetivo

O objetivo geral desta dissertação de mestrado é realizar uma análise multi-modelos do papel da US nos padrões de secas da América do Sul assim como verificar a sensibilidade destes modelos com a adição da forçante de radiação.

1.1.1 Objetivos específicos

- a) Analisar os padrões de US e sua relação com as forçantes atmosféricas (GDAS, MERGE e CERES) durante os últimos 20 anos (2000 a 2020) sobre a AS utilizando as simulações multimodelos do *South American Land Data Assimilation System* (SALDAS);
- b) Avaliar a destreza das simulações do SALDAS durante o período de estudo com relação à referências de modelagem *offline*, modelagem acoplada e observação de satélite: GLDAS, Reanálise ERA-5 e ESA CCI respectivamente;
- c) Analisar a destreza dos modelos de superfície para os eventos de seca ocorridos durante este período.

2 REVISÃO BIBLIOGRÁFICA

2.1 Umidade do Solo

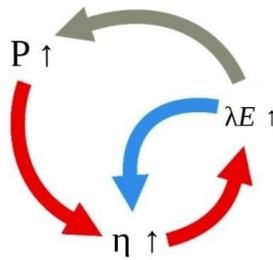
A US é uma variável importante no sistema terrestre e desempenha um papel significativo nas interações entre a superfície terrestre e a atmosfera (KOSTER; SUAREZ, ; HU et al., 2015). É geralmente definida como a água contida na camada insaturada do solo proveniente da chuva, do degelo ou da atração capilar da água subterrânea (PETROPOULOS et al., 2013), que é uma força de adesão das moléculas de água às superfícies das partículas do solo. Também pode ser definida como a água retida nos espaços entre as partículas do solo e, mesmo seu volume sendo pequeno quando comparado com outros componentes do ciclo hidrológico, esta variável é fundamental para processos biológicos e biogeoquímicos. Uma informação importante sobre essa variável é que o teor de US não possui distribuição homogênea nem verticalmente e nem horizontalmente, fazendo com que haja variações nos diferentes volumes de solo (SENEVIRATNE et al., 2010).

Dentre as variáveis que compõem as CI dos Modelos de Previsão Numérica, a US é importante por estar relacionada com a transferência de umidade superficial e de calor nos processos em superfície, possuindo expressiva influência na Temperatura da Superfície (TS) e também na altura da Camada Limite Planetária (CLP) (DY; FUNG, 2016). Segundo Basara e Crawford (2002), quando há um menor teor de US, há uma diminuição do FCL local e um aumento do FCS, resultando em uma CLP com maior profundidade. No estudo de Zhou e Geerts (2013) o período de solo úmido corresponde ao período de menor radiação líquida, FCS mais fraco, temperatura da Camada Limite Convectiva (CLC) mais baixa, perfil vertical mais estável, com uma CLC mais rasa e, conseqüentemente, uma CLP mais rasa também. Uma das influências dessa variável no balanço de energia na superfície terrestre se dá, também, pela alteração do albedo devido à falta de água que suprime a evapotranspiração, influenciando no CH (OKI et al., 1999). Um trabalho que estuda a relação entre o albedo e a CLP é o realizado por Eltahir (1998) constatou que nos primeiros 10 cm de profundidade do solo há uma grande influência no FCL e FCS, causando alterações na temperatura do solo, na TS e conseqüentemente na concentração do vapor da CLP.

A US é um modo de *feedback* para algumas variáveis hidrológicas (KOSTER, 1986) fazendo com que as interações com outras variáveis sejam fundamentais para compreender os mecanismos físicos da água global e das mudanças climáticas, sendo essencial para melhorar a precisão da previsão do clima (YANG et al., 2018), uma vez

que a compreensão deste *feedback* melhora a previsibilidade do sistema de superfície terrestre-atmosfera (DIRMEYER, 2000). O esquema apresentado na Figura 2.1 mostra o *feedback* negativo e positivo entre a precipitação (simbolizado por P) e a US (η). As setas em vermelho representam o *feedback* positivo, ou seja, um aumento na precipitação acarreta em um aumento na US levando a um aumento também do FCL (λE). A seta em azul representa o *feedback* negativo, onde o aumento do FCL acarreta em uma diminuição da US uma vez que há maior evapotranspiração da água no solo, resultando em menores quantidades de US. a seta em cinza indica que o impacto pode ser tanto positivo quanto negativo, ou seja um aumento da precipitação acarreta um aumento do FCL e λE a diminuição da precipitação acarreta na diminuição do FCL.

Figura 2.1 - *Feedback* entre US, precipitação e FCL. O símbolo P representa a precipitação, η a US e λE o FCL.

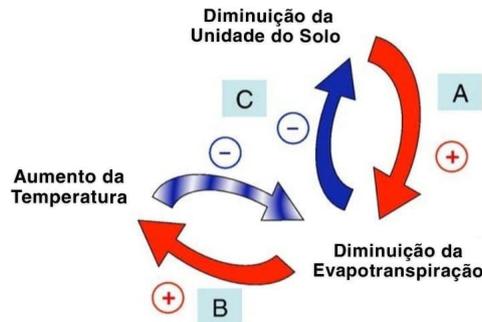


Fonte: Adaptado de Milovac (2017).

Na Figura 2.2 é apresentado o *feedback* entre a US, temperatura e a evapotranspiração. Semelhante ao apresentado na Figura 2.1, as setas que estão em vermelho representam o *feedback* positivo, a seta em azul representa *feedback* negativo e a seta azul tracejada indica a tendência de aumento da temperatura. O processo A mostrado na Figura 2.2 indica que a diminuição da US acarreta em uma diminuição da evapotranspiração pois quando há pouca água disponível no solo, haverá pouca água disponível para a evapotranspiração. O processo B indica que a diminuição da evapotranspiração acarreta em um aumento da temperatura do ar, ou seja, há uma diminuição do FCL e um aumento do FCS. Já o processo C indica que o aumento da temperatura leva a um maior *déficit* de pressão de vapor e demanda evaporativa causando um aumento potencial na evapotranspiração, acarretando, possivelmente,

em uma diminuição adicional da US (SENEVIRATNE et al., 2010).

Figura 2.2 - *Feedback* entre a US, a evapotranspiração e a temperatura.



Fonte: Adaptado de Seneviratne et al. (2010).

Para compreender a influência da US no balanço de energia superficial em ambientes semiáridos, Sellers e Dorman (1987) realizaram medições que abrangeram toda a temporada de monções de 2000 em três locais no Refúgio de Vida Selvagem *Sevilleta*, uma área protegida no Novo México. Dentre os resultados obtidos pelo estudo destaca-se: (1) as mudanças na Fração Evaporativa (FE) quando o solo está seco é tipicamente 0,1, demonstrando que apenas 10% da energia transferida da superfície para a atmosfera é via aquecimento latente; no entanto, quando o solo está úmido é 0,5, mostrando que a resposta do balanço de energia de superfície à precipitação, pelo menos em termos de aquecimento latente, é substancial e pode gerar um *feedback* para a atmosfera; (2) a radiação líquida e a energia disponível aumentam quando o solo está úmido, tanto em ambientes de grama como em arbustos; (3) as mudanças na FE e na radiação líquida após os eventos de chuva têm vida curta de alguns dias, logo, o *feedback* da precipitação com a US existirá quando as condições atmosféricas forem propícias à precipitação convectiva e permanecer por vários dias após um evento de chuva (SELLERS; DORMAN, 1987).

De acordo com Guo et al. (2006), o *Global Land-Atmosphere Coupling Experiment* (GLACE) é um experimento que tem como objetivo descrever o acoplamento entre a superfície e a atmosfera estudando como as anomalias no estado da superfície da terra (por exemplo, a US) pode afetar a geração de chuva e outros processos atmosféricos. O estudo contou com 12 Modelos de Circulação Global da Atmosfera

(MCGA) que realizaram diversos experimentos numéricos e foram posteriormente comparados por [Koster et al. \(2006\)](#). Na comparação feita por [Koster et al. \(2006\)](#) foi observado que a variabilidade da US é capaz de explicar cerca de 20% da variabilidade da precipitação em escala sinótica, além de garantir que, na natureza, as chuvas certamente afetam a US, que também afetam as chuvas.

A medição do conteúdo de água do solo e da zona não saturada é de suma importância para o monitoramento e modelagem numérica de tempo e clima, gestões de reservatórios, qualidade da água, horticultura, ecologia, engenharia civil e para outras áreas ambientais. Devido à sua importância e seus impactos demonstrados em vários estudos científicos, a US é uma componente fundamental que auxilia na previsão do tempo, mudanças climáticas, estimativas de rendimentos agrícolas e no fornecimento de alerta precoce para eventos de enchentes e de secas ([ENTEKHABI et al., 2010](#)).

O conteúdo de US influencia nas trocas de energia e de água entre a superfície e a atmosfera devido à evaporação e a transpiração das plantas, afetando importantes processos hidrológicos, como precipitação, vazão de rio, enchente e seca e, também, os sistemas climatológico e ecológicos. A água do solo controla forçantes e *feedbacks* entre a subsuperfície e a atmosfera, além de controlar a partição entre a evapotranspiração de um lado e o escoamento superficial e a infiltração do outro ([ZREDA et al., 2012](#)).

2.1.1 Perfil vertical de umidade no solo

A água presente abaixo da superfície da Terra, que preenche os poros, os espaços vazios das rochas sedimentares ou as fraturas, falhas e fissuras, estão submetidas a duas forças: gravidade e capilaridade ([ABAS, 2021](#)) A primeira é responsável por fazer as águas atingirem as regiões mais profundas do subsolo, chamadas de Zonas Saturadas (ZS); já a segunda força faz com que a água infiltrada fique retida nas regiões mais próximas da superfície do solo, na Zona Não Saturada (ZNS).

Os fatores que influenciam na permeabilidade da água são a porosidade do solo, inclinação do terreno, cobertura vegetal e também o tipo de regime climático predominante. Em relação à porosidade, por exemplo, podemos citar a presença de argila no solo que diminui a permeabilidade do mesmo, reduzindo a infiltração. Em relação a declinação, sabemos que quanto mais acentuada, maior é a capacidade da água de escoar superficialmente, diminuindo a infiltração. Além disso, terrenos que possuem maior cobertura da vegetação, são mais permeáveis que locais com solo exposto ou

desmatado. Com relação ao regime de precipitação, quando em maior intensidade, as chuvas fazem com que o solo fique saturado mais rapidamente quando comparado com chuvas de menor intensidade (ABAS, 2021).

A Figura 2.3 representa um esquema das ZS e ZNS no subsolo. De acordo com ABAS (2021) ZNS é a parte do solo que não está totalmente preenchida por água, onde a água presente fica distribuída uniformemente e onde há a presença de gases, principalmente o vapor d'água. É nesta zona que ocorre a transpiração pelas raízes das plantas e o fenômeno de filtração e de autodepuração da água (quando a água passa por processos de purificação). Essa zona fica localizada entre a superfície freática e a superfície do terreno.

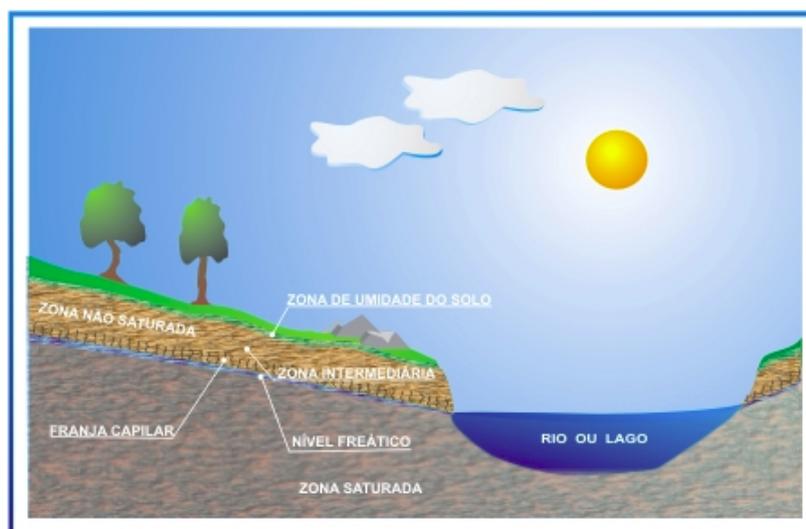
No interior dessa zona, é possível identificar três subcamadas. A primeira é chamada de Zona de Umidade do Solo (ZUS) ou Zona Superficial (ZSup) que situa-se entre os extremos radiculares da vegetação e a superfície do terreno e sua espessura varia de acordo com a cobertura vegetal, essa zona realiza trocas com a atmosfera e possui uma dinâmica mais rápida quando comparada com as outras camadas do solo.

A segunda camada é a Zona Intermediária (ZI) ou Zona de Raízes (ZR), que fica localizada entre o limite de ascensão capilar da água e o limite de alcance das raízes das plantas. Em regiões onde o nível freático está próximo à superfície, essa zona não existe pois a franja capilar consegue atingir a superfície do solo (ABAS, 2021).

A terceira subcamada é a Zona Capilar (ZC), que representa a parte que se estende da superfície até o limite da ascensão capilar da água, onde sua espessura depende, principalmente, da distribuição e do tamanho dos poros e a homogeneidade do terreno; aqui a umidade é maior pois a zona saturada fica localizada logo abaixo (ABAS, 2021). A franja capilar é um limite abaixo do qual o solo é considerado praticamente saturado, onde a água ascende por capilaridade (ABAS, 2021).

A ZS está localizada abaixo da ZNS. Essa região é caracterizada por apresentar poros ou fraturas de rocha que estão totalmente preenchidos por água, que corresponde ao que excede de água na ZNS e que se movem em velocidade baixa (ABAS, 2021). Uma parte da água que se encontra nesta zona irá desaguar em locais que formam as fontes, outra parte deságuam em rios, ou diretamente em lagos e oceanos.

Figura 2.3 - Caracterização Esquemática das ZS e ZNS no subsolo



Fonte: Borghetti et al. (2004).

2.1.2 Medidas de Umidade do Solo

A escassez de observações de US em escala regional e global é um fator que dificulta estudos aprofundados sobre essa variável e suas interações com a atmosfera. Algumas alternativas para medições do solo são através do SR, que fornece estimativas indiretas dessa variável. Por exemplo, o SR de ondas no espectro de microondas mostrado no trabalho de Engman e Chauhan (1995) ou ondas gravitacionais, como as utilizadas nas missões do *Gravity Recovery and Climate Experiment* -GRACE (em português, recuperação da gravidade e o experimento climático).

A determinação da US pode ocorrer através do conteúdo de água no solo ou do potencial de água no solo. No primeiro caso, a US é calculada pela razão da massa ou volume de água pela massa ou volume do total de solo, enquanto pelo potencial de água no solo a US é descrita pela energia da água no solo (MASKE, 2016).

As medições da US podem ser realizadas de forma direta ou indireta. Os métodos diretos consistem na remoção da água do solo por evaporação, lixiviação ou algum processo químico. Os métodos indiretos dependem do monitoramento de uma propriedade do solo que é uma função do teor de água. Esses métodos geralmente envolvem instrumentação colocada no solo ou sobre ele, ou também técnicas remotas envolvendo sensores montados em uma plataforma sobre o solo ou em aeronaves e

satélites (SMITH, 2000).

O método termogravimétrico é a única medição direta da US. Essa medição também é chamada de técnica termostato-peso, que consiste em retirar uma amostra do solo para seja realizada uma pesagem antes e depois do processo de secagem em estufa, onde o mesmo é submetido à temperaturas elevadas para que a água seja evaporada até que não haja mais a perda de peso. A diferença na massa fornece a umidade total do solo na amostra, que é convertida em unidades volumétricas usando a densidade do solo (unidade de medida: m^3/m^3) (ROBOCK et al., 2000).

O método gravimétrico é simples e de baixa tecnologia, o que o torna uma excelente técnica para registros climatológicos homogêneos longos. No entanto, é trabalhoso e destrutivo para o local, necessitando de uma mão de obra significativa para a extração das amostras e das medições laboratoriais, resultando em uma resolução temporal grosseira das redes de medição a longo prazo; essa medição é em grama por grama (g/g) de solo seco em estufa (ROBINSON et al., 2008). Essa metodologia ainda é utilizada como medidas de referência para calibrar outros métodos de medição da US, uma vez que todas as outras abordagens são indiretas (SENEVIRATNE et al., 2010). Devido os pontos negativos, novos métodos eletrônicos estão sendo introduzidos, que requerem calibração e que são classificados como indiretos.

Sobre os métodos indiretos das medições de US, as mais comuns são aquelas baseadas no tempo de domínio de reflectometria (TDR) ou em medições de capacitância no solo. A abordagem TDR é uma técnica de radar aplicada no solo e é usada para determinar a permissividade relativa do solo (TOPP; REYNOLDS, 1998). As medições de capacitância no solo, são dispositivos que conseguem determinar a capacitância aparente de uma sonda colocada no solo ou próximo a ele, pois a US é uma variável que muda com a constante dielétrica da água. O método de capacitância e o TDR são duas técnicas eletromagnéticas amplamente utilizadas para estimativa do conteúdo de água do solo (BLONQUIST-JUNIOR et al., 2005). Ambos os métodos são dependentes das propriedades do sinal eletromagnético no conteúdo volumétrico de água que decorre da alta permissividade da água em comparação com os minerais sólidos do solo e do ar (YE et al., 2013). Dada a forte heterogeneidade espacial das propriedades de US, é atraente para algumas aplicações escolher sensores um pouco menos precisos, porém mais baratos, a fim de aumentar a extensão espacial (SENEVIRATNE et al., 2010).

As medições por sondas de nêutrons, embora sejam bastante precisas, não são frequentemente utilizadas como os métodos citados anteriormente devido aos riscos à

saúde associados aos elementos radioativos usados como fonte para os nêutrons (ROBINSON et al., 2008). Outras técnicas de medição indireta de US incluem medições de resistência elétrica, sensores de pulso de calor, sensores de fibra óptica e *scanners* de raios gama (SENEVIRATNE et al., 2010). O método de observação de US por raios cósmicos, o COSMOS (em inglês, *Cosmic-ray Soil Moisture Observing System*), é uma rede nacional projetada para melhorar a previsão hidrometeorológica (ZREDA et al., 2012). Essa rede é em escala continental e consiste em instrumentos que fornecem estimativas de US média em escala intermediária medindo os nêutrons de raios cósmicos acima da superfície da Terra (ZREDA et al., 2008). A sonda detecta todo o hidrogênio presente no volume de suporte, incluindo a água ou neve na vegetação e na superfície do solo e água nos minerais presentes nos solos (FRANZ et al., 2012; DESILETS et al., 2010).

O desenvolvimento de tecnologias que visam obter estimativas precisas e representativas da US em escalas locais, regionais e globais é impulsionado pelo problema das medições pontuais não serem capazes de representar uma região abrangente, isso porque, segundo Zreda et al. (2012), essa variável é espacialmente heterogênea ao longo de uma faixa espacial, impedindo uma avaliação significativa da US que seja representativa da área a partir de um único ponto. O SR é um método indireto promissor para inferir a US por meio de emissões de microondas da superfície da terra (SCHMUGGE, 1983). A detecção por satélites de microondas fornece valores integrados de US próximo à superfície ao longo de centenas a milhares de quilômetros quadrados (NJOKU; ENTEKHABI, 1996).

Os métodos de SR incluem sensores de microondas passivo e/ou ativo (radiômetros) e medições associadas a perturbações no campo gravitacional terrestre (SENEVIRATNE et al., 2010). O SR de microondas ativo utiliza uma fonte artificial de radiação que é detectada após ser refletida do alvo, como por exemplo o radar. Os métodos passivos são aqueles que a radiação eletromagnética é emitida da superfície.

Dentre os satélites e sensores de microondas, podemos citar como o primeiro padrão global do produto de US do *Microwave Scanning Radiometer* (AMSR-E, em português, radiômetro de varredura de microondas avançado) segundo Njoku et al. (2003). Houveram duas missões dedicadas à US obtida por satélites na banda L, uma sobre a US e salinidade do oceano (*Soil Moisture and Ocean Salinity*-SMOS) e a US (em inglês, *Soil Moisture Active Passive*-SMAP) (ENTEKHABI et al., 2010). Segundo Wigneron et al. (2017) as duas missões citadas anteriormente foram as mais promissoras devido à maior capacidade dos satélites em penetrar na vegetação na

faixa L quando comparada à banda C ou X.

O Programa da *European Space Agency* (ESA) gerou um produto de US diário global com resolução espacial de $0,25^\circ \times 0,25^\circ$. Segundo Liu et al. (2012) para longos períodos de observação, combinando produtos de microondas passivos e ativos, que é chamado de *Climate Change Initiative* ESA (ESA CCI) (MA et al., 2019).

A estimativa de US por SR é possibilitada por características como a Constante Dielétrica (CD) e a cobertura do solo. A CD é uma propriedade elétrica da matéria que consiste na resposta de um meio a um campo elétrico aplicado. A grande diferença entre a CD da água doce e do solo seco faz com que seja possível mensurar a emissividade das condições secas e úmidas do solo (OWE et al., 1999). De acordo com Topp (2003), a presença de vegetação reduz a sensibilidade ao conteúdo de água no solo e os limites de resolução da profundidade para sensores de microondas passivos e ativos são semelhantes, porém com resolução espacial maior nos sensores passivos.

As medições de recuperação de gravidade são possíveis devido às derivações do campo gravitacional da terra com resolução temporal aproximadamente mensal (WAHR et al., 2006). O GRACE possui informação completa do solo, principalmente em relação à seca. Variações sazonais no armazenamento de água terrestre (US, água subterrânea, neve, água superficial e cobertura de gelo) resultam em variações do campo gravitacional da Terra, que podem ser medidos com o GRACE (SENEVIRATNE et al., 2010).

As medições de US feitas por satélites tem suas vantagens mas também possuem algumas limitações. Dentre elas pode-se citar: profundidade de penetração vertical rasa (milímetros a centímetros), capacidade limitada de penetrar objetos como a vegetação ou neve, sensibilidade à superfície rugosa, cobertura temporal descontínua e o alto custo das missões de satélite (ZREDA et al., 2012). Entretanto, ainda é uma metodologia que produz avanços na obtenção de dados observacionais com amplitude espaço-temporal.

2.2 Secas

As definições de secas podem variar em termos de disponibilidade hídrica ou com relação à perspectiva disciplinar da seca que se tem como interesse. No geral, as secas se originam de uma deficiência de precipitação que resulta na escassez de água no solo impactando, assim, em atividades como por exemplo o crescimento de plantas ou para algum grupo específico socioeconômico como os agricultores, indústrias e a

população urbana.

Wilhite e Glantz (1985) mostraram que as secas podem ser divididas em quatro grupos: meteorológicas, agrícolas, hídricas e socioeconômicas. As secas meteorológicas referem-se ao *déficit* de precipitação, ou seja, quando os dados de precipitação ficam abaixo dos dados climatológicos. As definições dessa seca levam em consideração a especificidade da região uma vez que as condições atmosféricas que resultam nos *déficit* de precipitação são dependentes do regime climático (WILHITE, 2000). A seca agrícola refere-se à insuficiência da água disponível no solo para suprir as demandas das plantas; este tipo de seca está relacionado com as características das vegetações e das culturas. As secas hidrológicas estão associadas ao estado de armazenamento da água no solo; segundo(WILHITE, 2000), esta seca consiste na deficiência do volume de água disponível, incluindo o lençol freático, reservatórios e rios. Já a seca socioeconômica refere-se à seca que ocorre quando a escassez de água afeta a população e suas atividades tanto individuais quanto coletivas (MONACELLI et al., 2005).

Além da divisão por impactos mencionada, de acordo com Wilhite (2000) as secas se diferem entre si em três características, sendo elas: intensidade, duração e características espaciais. Em relação à intensidade, é considerado o grau do *déficit* de precipitação ou então a gravidade dos impactos associados à escassez de água. Sobre a duração, as secas geralmente requerem um mínimo de dois a três meses para se estabelecerem, mas podem apresentar durabilidade de meses ou anos. Em relação às características espaciais, as áreas afetadas por secas evoluem gradualmente e as regiões de intensidade máxima mudam de estação para estação, além disso, países maiores, como Brasil, China, Índia, Estados Unidos ou Austrália, a seca raramente, ou nunca, afetaria todo o país (WILHITE, 2000).

A gravidade e severidade da seca é de difícil determinação pois depende não apenas da duração, intensidade e extensão geográfica do episódio específico de seca, mas também das demandas feitas pelas atividades humanas e pela vegetação no abastecimento de água de uma região (WILHITE; GLANTZ, 1985). Ainda segundo o autor, as secas severas ocorrem devido a uma combinação de fatores como: anomalias nas variáveis hidrológicas, temperatura, condições do ecossistema terrestre e de atividades humanas.

Diversos indicadores são utilizados para conseguir padronizar, comparar e quantificar as secas em escala espacial e temporal. Os índices mais utilizados são: *Palmer Drought Severity Index* (PDSI) , *Surface Water Supply Index* (SWSI), *Standardized Precipitation Index* (SPI) e percentis de US. Segundo Blain e Brunini (2005), o

PDSI tem como parâmetros o Balanço Hídrico climatológico de [Thornthwaite et al. \(1959\)](#). Segundo [Alley \(1984\)](#), o PDSI aborda duas das características mais elusivas da seca, que são a intensidade e a duração. [Palmer \(1965\)](#) classificou 11 faixas de classificação de eventos, como é demonstrado na [Tabela 2.1](#) abaixo:

Tabela 2.1 - Categorias de classificação do Índice de Severidade de Seca de Palmer (PDSI).

PDSI	Categoria
$\geq 4,00$	Extremamente Úmido
3,00 a 3,99	Muito Úmido
2,00 a 2,99	Moderadamente Úmido
1,00 a 1,99	Ligeiramente Úmido
0,50 a 0,99	Úmido Incipiente
0,49 a -0,49	Próximo ao Normal
-0,50 a -0,99	Seca Incipiente
-1,00 a -1,99	Ligeiramente Seco
2,00 a -2,99	Moderadamente Seco
-3,00 a -3,99	Muito Seco
$\leq -4,00$	Extremamente Seco

Fonte: Adaptado [Palmer \(1965\)](#).

O SPI foi desenvolvido por [McKee et al. \(1993\)](#), onde afirmam que a precipitação padronizada é simplesmente a diferença da precipitação em relação à média de um período de tempo especificado, dividida pelo desvio padrão, onde a média e o desvio padrão são determinados a partir de registros anteriores. Uma característica importante deste método é o fato de se aproximar a uma distribuição gama. Segundo os autores, a desvantagem desse método é que a precipitação geralmente não é distribuída normalmente por períodos cumulativos de 12 meses ou menos, mas isso pode ser superado aplicando uma transformação à distribuição. Ainda no estudo de [McKee et al. \(1993\)](#), utilizando o índice, é possível ter uma definição funcional e quantitativa de seca estabelecida para cada escala de tempo e, que um evento de seca é definido como um período em que o SPI é continuamente negativo atingindo um valor de -1,0 ou inferior. Para os autores a intensidade da seca é definida arbitrariamente para valores do SPI com as categorias apresentadas na [Tabela 3.1](#) abaixo.

Tabela 2.2 - Valores do SPI com as categorias de secas.

Valores SPI	Categorias de Seca
0 a -0.99	Seca Incipiente
-1,00 a -1,49	Seca Moderada
-1,50 a -1,99	Seca Severa
≤ -2.00	Seca Extrema

Fonte: Adaptado McKee et al. (1993).

Alguns índices também foram desenvolvidos com um olhar voltado para a US. Narasimhan e Srinivasan (2005) desenvolveram um índice de seca chamado *Soil Moisture Deficit Index* (SMDI) com base no *déficit* semanal de US. Esse índice foi calculado para quatro diferentes níveis utilizando a água do solo disponível em todo o perfil de solo e, em seguida, a água do solo disponível nos 2 pés superiores (SMDI-2), 4 pés (SMDI-4) e 6 pés (SMDI-6). O estudo utilizou o SDMI para os 4 níveis obtendo uma correlação (r) positiva com os PDSI e com os valores do SPI para as bacias hidrográficas analisadas. Além disso, foi apresentado um alto valor de r entre o SMDI-2 e o SPI-1, indicando que o SMDI-2 é um bom indicador de condições de seca de curto prazo, importante para o monitoramento da seca agrícola.

No trabalho de Zhao et al. (2020) são descritos métodos utilizados para coletar e controlar a qualidade das medições de US de várias redes de informação, convertendo o conteúdo volumétrico de água em percentis de US e interpolando esses dados para uma grade de 4 km sobre os Estados Unidos. Eles analisaram a precisão de três métodos de interpolação, ponderação do inverso da distância, krigagem comum e krigagem de regressão, para produzir a distribuição espacial de percentis de US, fornecendo dados dessa variável quase em tempo real. Os resultados são importantes para o desenvolvimento de produtos operacionais de US, como o Monitor de Secas dos Estados Unidos (ZHAO et al., 2020). Segundo Wang et al. (2011), os percentis de US são utilizados para aplicações em casos de eventos de seca, sendo caracterizado por percentis abaixo de 20.

Devido aos prejuízos que são causados pelas secas, relacionados tanto à economia, quanto à população, o monitoramento desses eventos é importante para elaboração de medidas mitigadoras visando reduzir os impactos causados em diversos segmentos da sociedade. Segundo NYS et al. (2016), as secas estão presentes em todas as regiões do Brasil, de norte a sul e de leste a oeste, afetando a produção agrícola e

o abastecimento de água. De acordo com o Atlas Brasileiro de Desastres Naturais, no período de 1991 a 2012 houveram 19.517 registros oficiais de episódios de secas e de estiagem. Essa quantia representa cerca de 48% do total de ocorrências de desastres no Brasil durante o período analisado. A região Nordeste é a mais afetada por esse tipo de desastre, com quase 60% dos registros, acompanhado pelos estados da Região Sul com 27% dos registros de ocorrência. É na região Nordeste que a seca se manifesta com maior frequência e que apresenta impactos mais acentuados (NYS et al., 2016).

2.3 Modelagem de superfície terrestre

2.3.1 *Land Surface Model*

De acordo com Rodell et al. (2005) os *Land Surface Model* (LSM) são capazes de gerar estimativas de variáveis como a US, evapotranspiração, temperatura da superfície, e também fluxos terrestres de água e energia de forma que essas estimativas sejam espacial e temporalmente contínuas e fisicamente consistentes. São consideradas ferramentas para estudar os ciclos de água e energia e são importantes para as previsões de tempo e clima (RODELL et al., 2005).

Um fator limitante da precisão dos modelos de superfície são as CI fornecidas e os processos físicos que são representados nos modelos. Quanto melhores as CI, melhor são as representações dos estados da superfície no instante em que as simulações começam e, assim, há aperfeiçoamento na descrição dos campos das variáveis prognósticas. Dentre as CI é possível incluir variáveis como a temperatura e o conteúdo de água de cada camada do solo, o conteúdo de calor, conteúdo de água no dossel, profundidade, densidade e também o armazenamento de água líquida da neve.

Dentre os LSM atualmente em uso pela comunidade científica, o presente estudo utilizará o modelo Noah-MP, o CLSM e o IBIS. O modelo de superfície da terra Noah é usado tanto na previsão do tempo de curto prazo, quanto em previsões climáticas intra-sazonais a interanuais e para redução da escala de projeções do Global Climate Model (GCM) (YANG et al., 2011).

O trabalho de Niu et al. (2011), descreve os objetivos dos esforços da comunidade científica em melhorar o LSM Noah. A primeira parte mostra que o Noah-MP apresenta melhorias aparentes na reprodução dos fluxos e na temperatura da superfície durante os períodos secos, melhorias também na água equivalente da neve, profundidade da neve e no escoamento. De acordo com os autores, o modelo melhora

as simulações equivalentes da água da neve devido a simulações mais precisas das variações diurnas da temperatura da camada de neve, fator crítico para calcular a energia disponível para o derretimento. Neste trabalho se concluiu que o Noah-MP é uma ferramenta de pesquisa eficaz pela qual os resultados da modelagem para um determinado processo podem ser interpretados por meio de vários esquemas de parametrização opcionais na mesma estrutura do modelo.

O trabalho de [Yang et al. \(2011\)](#) tem como foco avaliação de conjuntos com dados de longo prazo em escala regional (bacias hidrográficas) e global, como continuação ao estudo de [Niu et al. \(2011\)](#). No trabalho foi avaliado o desempenho do modelo em relação a vários satélites e observações terrestres sobre bacias hidrográficas globais por meio de seis experimentos que imitam uma transição do LSM Noah original para a versão totalmente aumentada. O trabalho demonstrou melhoria na modelagem do escoamento, US, neve e temperatura da superfície, apesar do aumento considerável no tempo computacional pela versão totalmente aumentada do Noah-MP em comparação com o Noah original. Além disso, foi mostrado que o modelo de vegetação dinâmica captura favoravelmente a variabilidade sazonal e espacial do Índice de Área Foliar (IAF) e da fração de vegetação verde.

O trabalho de [Cai et al. \(2014\)](#) avalia as simulações hidrológicas em escala regional do modelo de superfície terrestre Noah-MP que foi configurado para a Bacia do Rio Mississippi com resolução espacial de $1/8^\circ$. As simulações foram comparadas com outros conjuntos de dados observacionais, onde os resultados mostram que houve uma melhora significativa nas principais variáveis hidrológicas (US, escoamento, água subterrânea, etc), que ocorreu devido à incorporação de algumas melhorias importantes que houve no Noah-MP. Além disso, o modelo produziu valores de US consistentes com as observações do *Soil Climate Analysis Network* (SCAN) para as duas camadas superiores do solo (0–10 cm e 10–40 cm), indicando grande potencial para o uso no estudo do acoplamento terra - atmosfera.

Outra ferramenta utilizada é o CLSM, que apresenta uma estrutura de modelagem de superfície terrestre não-convencional que inclui um tratamento explícito da variabilidade de umidade do subsolo e seu efeito sobre o escoamento e a evaporação ([KOSTER et al., 2000](#)). Além da hidrologia do solo e dos processos de neve, o CLSM simula a temperatura do solo em seis camadas desde a superfície até 13 m de profundidade ([TAO et al., 2017](#)).

Um estudo realizado por [Bechtold et al. \(2019\)](#) consistiu em adicionar um módulo de hidrologia de superfície terrestre específico para turfeiras (PEAT-CLSM) ao CLSM

do *Goddard Earth Observing System* (GEOS) pertencente a NASA. Neste estudo foi alterada a abordagem do modelo hidrológico TOPMODEL do CLSM original, desenvolvendo um conceito de modelo específico de turfa. Observaram que o PEAT-CLSM simula a profundidade média do lençol freático com poucas flutuações temporais, obtendo concordância significativamente melhor com as observações *in situ*.

No estudo de [Tao et al. \(2017\)](#) foi feita uma simulação de referência que produziu temperaturas de subsuperfície para 1980-2014 em todo o Alasca com resolução espacial de 9 km para analisar o desempenho da termodinâmica de subsuperfície do CLSM. A simulação de controle foi utilizada para capturar as características gerais das variações interanuais na temperatura do solo e os resultados foram avaliados usando observações *in situ* de geleiras. De acordo com os resultados, a *Root Mean Square Error* (RMSE) do perfil para a temperatura do solo foi reduzida de 2,96 para 2,10 ° C em um local e de 2,38 para 2,25 ° C em outro usando forçantes locais e cobertura do solo, respectivamente. Além disso, de acordo com os autores, a contabilização da influência do carbono orgânico nas propriedades térmicas do solo no CLSM leva a melhorias adicionais no perfil de temperatura média do solo.

O modelo de superfície IBIS é um modelo de vegetação dinâmico global, que representa uma ampla gama de processos, incluindo física da superfície terrestre, fisiologia do dossel, fenologia da planta, dinâmica da vegetação e ciclo do carbono e nutrientes ([FIGUEROA et al., 2016](#)).

No estudo de [Costa et al. \(2007\)](#), o IBIS foi utilizado como ferramenta para investigar se a mudança climática devido à expansão da soja na Amazônia seria diferente com o aumento das pastagens. [Costa et al. \(2007\)](#) desativaram a componente dinâmica da vegetação, mantendo uma cobertura vegetal fixa. Foi atualizado a representação da floresta tropical no IBIS com uma nova calibração em relação aos dados de fluxo de quatro locais diferentes das torres de fluxo do experimento *Large-scale Biosphere-Atmosphere Experiment in Amazonia* (LBA), e de um experimento micrometeorológico de soja na Amazônia. Os resultados apresentados no estudo mostraram aumento na albedo de superfície, diminuição na evapotranspiração e também indicaram que a diminuição da precipitação se mostrou significativamente maior após a expansão da soja quando comparada à mudança após a expansão da pastagem.

Com o intuito de compreender melhor o ecossistema Caatinga, que é um ecossistema dinâmico onde a física da interface superfície-atmosfera é pouco compreendida, [Cunha et al. \(2013\)](#) avaliou um método hierárquico que foi aplicado à caatinga por meio do IBIS. Os resultados demonstraram que o conjunto calibrado com parâmetros de

vegetação produziu um balanço de energia consideravelmente diferente quando comparado com os parâmetros padrão. No entanto, obtiveram que o modelo IBIS não foi capaz de capturar mudanças intensas de curto prazo no fluxo de calor latente de uma condição seca para uma condição de solo mais úmido.

No estudo de [Chen et al. \(2015a\)](#) foi avaliado o prognóstico de US do IBIS usando dados diários de US ao longo de um período de 3 anos (2005-2007) em uma bacia hidrográfica em um local semi-árido no sudeste da Austrália usando a incerteza de probabilidade de Monte Carlo. No trabalho foi obtido que diferenças relativamente baixas na US simulada foram associadas a grandes discrepâncias nas previsões de escoamento superficial, drenagem e evapotranspiração. Os autores concluíram que, embora os esquemas de superfície da terra possam ser eficazes na simulação de fluxos de calor, eles podem ser ineficazes para a previsão da hidrologia, a menos que a US seja estimada com precisão. Além disso, observaram que o IAF pode afetar a média da série temporal diária de US quando $IAF < 1$, enquanto a variância da série temporal de US foi sensível ao $IAF > 1$.

No estudo de [Chen et al. \(2015b\)](#) foi investigado o impacto da variabilidade temporal do IAF nas previsões de US usando dados de vegetação de SR para três anos (2005-2007) advindo dos LSMs IBIS e HYDRUS no campo semi-árido de *Stanley* (Ilhas Malvinas). Os resultados da calibração de ambos os modelos sugeriram que um IAF médio ao longo do tempo, em vez de um IAF diário variando no tempo, foi suficiente para reproduzir a umidade diária do solo. Foi descoberto também que a sensibilidade do impacto da variabilidade do tempo do IAF na estimativa da US era uma função dos parâmetros do solo. Além disso, a influência da variação do tempo do IAF nas simulações de US é controlada pela sensibilidade desta variável modelada aos valores médios do IAF no período estudado.

2.3.2 Land Information System

O *Land Information System* (LIS) foi desenvolvido com intuito de apoiar o alto desempenho da modelagem de superfície terrestre e das AD, permitindo o fácil intercâmbio de subcomponentes como: física da superfície terrestre, dados de entrada e saída e as rotinas de AD ([NASA, 2021f](#)). O LIS foi desenvolvido como um componente da superfície terrestre que é orientado pela observação de um modelo de sistema terrestre com intuito de auxiliar a compreensão da dinâmica da água terrestre e dos ciclos de energia e carbono, incorporando observações exclusivas do *Earth Observation System* (EOS) da NASA ([PETERS-LIDARD et al., 2007](#)). De acordo com [Peters-Lidard et al. \(2007\)](#), o LIS trabalha com a modelagem de superfície terrestre

regional e global, com foco nas interações terra-atmosfera permitindo seu acoplamento e a incorporação em LSM. É capaz de incorporar vários modelos de superfície terrestre que podem ser executados de duas formas: (1) através de uma análise retrospectiva desacoplada (*offline*) utilizando as observações baseadas na precipitação, na radiação e em dados de entradas meteorológicas; (2) através de uma análise acoplada a um componente do modelo *Weather Research and Forecasting*(WRF).

O *software* inclui vários modelos de superfície terrestre que podem ser executados com um conjunto de modelos que possuem domínios globais ou regionais e com resoluções horizontais que variam de 2,5° a 1 km (PETERS-LIDARD et al., 2007). O LIS tenta alcançar interoperabilidade de código aplicando conceitos avançados de software, onde o sistema é projetado como uma estrutura orientada a objetos que pode ser compartilhada e utilizada por cientistas e profissionais da comunidade de modelagem de superfície terrestre (KUMAR et al., 2006).

O LIS é um ambiente de teste para modelagem de superfície terrestre e AD e é usado na NASA/GSFC, NOAA/NCEP, no *557th Weather Wing* (parte meteorológica da Força Aérea com sede em Nebraska) (NASA, 2021f) e também utilizado em modo pesquisa no Centro de Previsão de Tempo e Estudos Climáticos (CPTEC). O software permite que os sistemas de AD terrestres sejam construídos, montados e configurados facilmente, possuindo também, uma estrutura de software para os Sistema de Assimilação de Dados Terrestres (LDAS) e seus projetos que foram desenvolvidos no Laboratório de Ciências Hidrológicas da NASA Goddard (NASA, 2021f).

2.4 *South American Land Data Assimilation System*

O SALDAS foi criado com o intuito de determinar e ampliar a compreensão sobre os saldos de energia da superfície da terra e também os estoques de umidade para poder inicializar os sistemas de previsões especificamente para a América do Sul. Os conceitos utilizados neste sistema são baseados nos utilizados no LDAS empregado por (RODELL et al., 2004).

O estudo realizado por (GONCALVES et al., 2006) descreveu um experimento de *spin-up* para a AS a partir do modelo de superfície terrestre da *Simplified Simple Biosphere* (SSiB) para estudar o processo de ajuste do modelo aos dados de forçantes atmosféricos. O experimento foi realizado como um precursor para o uso de SSiB no SALDAS. A partir de uma simulação de 11 anos utilizando três CI diferentes de US, constatou-se que os estados finais de *spin-up* usando o SALDAS baseado em SSiB

são geralmente mais úmidos do que o NCEP/DOE R-2 e o CPTEC, consequentemente, o FCL modelado é maior e o FCS menor no ano final da simulação quando comparados com o primeiro ano. Foi observado que há uma rápida mudança na US em todas as camadas nos primeiros 2 meses de simulação, seguida por um ajuste lento e constante, resultando em erros crescentes nas simulações de médio alcance.

Outro estudo de [Goncalves et al. \(2009\)](#) descreveu a criação e a validação dos conjuntos de dados das forçantes atmosféricas de 5 anos utilizando o SALDAS, que também foi adotado como dados de forçantes regionais para as comparações de modelos que foram feitas no LBA. No estudo, os dados das forçantes do SALDAS foram derivados de combinações de modelos e observações para produzir os campos atmosféricos que são necessários para a modelagem da superfície terrestre em todo o continente. O resultado foi um composto de dados da Reanálise Regional da AS (SARR) suplementado por campos de precipitação e radiação de ondas curtas descendentes derivados de dados de SR combinados com observações de superfície. Devido a grande extensão do continente e a limitação das observações disponíveis, a AS foi dividida em sub-regiões selecionadas para caracterizar diferentes regimes climáticos.

3 METODOLOGIA

3.1 Base de dados utilizadas

Para gerar os campos de US foram utilizados três LSM (Noah-MP, CLSM-F2.5 e IBIS) que foram forçados com diferentes dados de entrada (GDAS, MERGE e CERES). Os resultados serão comparados com o Era-5, ESA-CCI e GLDAS, para avaliar a destreza do SALDAS. As características de cada base serão referenciadas a seguir.

3.1.1 Sistema de Informação da Terra (LIS)

O LIS inclui um sistema modular para funções de modelagem de alto desempenho, cujo componente central (núcleo do LIS) é capaz de controlar a execução de modelos de superfície terrestre, melhorando as configurações de computação paralela e gerenciando a entrada/saída de dados. Além disso, é capaz de recuperar dados observacionais atmosféricos relevantes de diversos repositórios, inclusive do seu próprio banco de dados de entrada e criar um arquivo que poderá ser usado futuramente. A componente de recuperação de dados inclui uma coleção de *scripts* de *download* de dados de protocolo de transferência de arquivos (FTP) / protocolo de transferência de hipertexto (HTTP) e programas de recuperação de dados (PETERS-LIDARD et al., 2007).

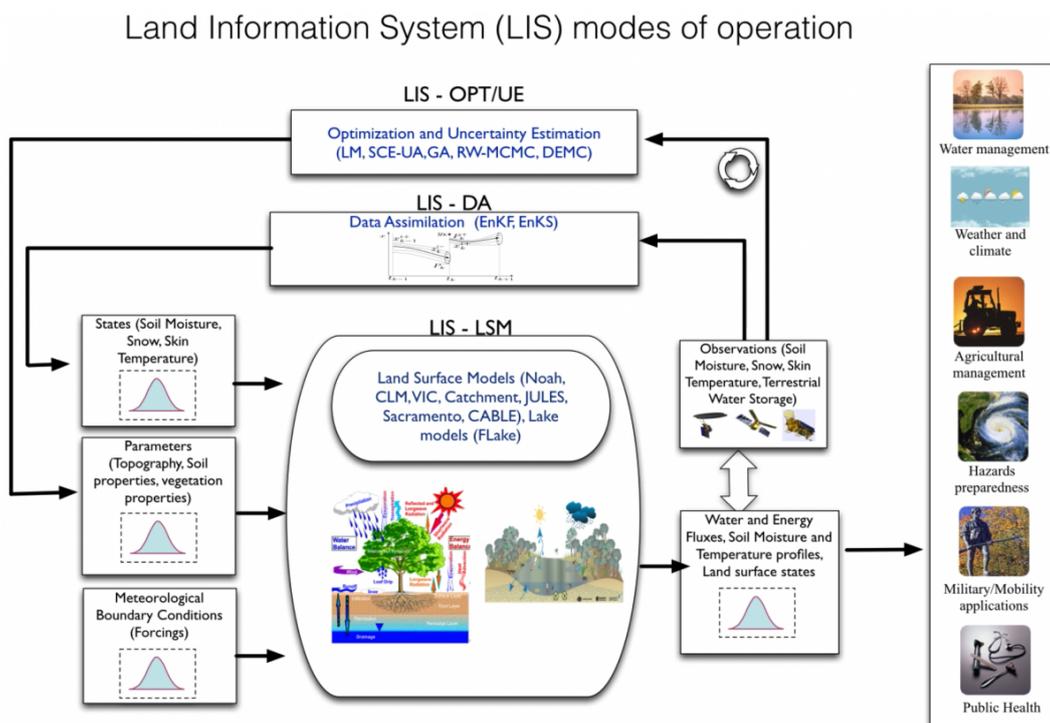
Conforme descrito na documentação online disponíveis em <https://lis.gsfc.nasa.gov/software/lis>, o LIS integra diversos tipos de dados observacionais com as previsões do modelo para gerar estimativas melhores das condições da superfície da terra, como US, evaporação, acumulação de neve e escoamento com resolução espacial de 1km (ou mais altas) e em resoluções temporal de uma hora (ou menores). O *software* executa modelos de superfície da terra em 1D com base na cobertura da terra. Além disso, a capacidade de modelagem espacial em escala fina do LIS permite tirar vantagem das observações do EOS, como o IAF do *MODerate-resolution Imaging Spectroradiometer* (MODIS), cobertura de neve e TS em resolução total (NASA, 2021d).

A Figura 3.1 apresenta as características do LIS. O subsistema LIS-LSM e o núcleo o LIS, suporta a modelagem de superfície terrestre de alto desempenho, além de ser projetado para encapsular a componente da superfície terrestre de um LSM. O subsistema LIS-DA corresponde a AD, que é capaz de suportar diversos algoritmos de AD e numerosos conjuntos de dados de observação. O LIS-OPT/UE corresponde

ao subsistema de estimativas de incertezas de otimização (NASA, 2021d).

Segundo Peters-Lidard et al. (2007), o conjunto de dados dos parâmetros no LIS inclui topografia, cobertura do solo, propriedades da vegetação (fração de área verde e/ou IAF) e textura do solo e/ou porcentagens de areia e argila. Já os mapas globais de terreno de elevação, declive, aspecto e curvatura usados no LIS são derivados do conjunto de dados global de 30 segundos do GTOPO30 (GESCH et al., 1999). Além disso, a classificação de cobertura da terra que é utilizada para o mapeamento de cada modelo foi obtido de um conjunto de dados de classificação de vegetação global estático que possui resolução de 1km e foi produzido na Universidade de Maryland (HANSEN et al., 2000).

Figura 3.1 - Características do LIS.



Fonte: NASA (2021e).

3.1.2 Modelos de superfície:

3.1.2.1 Noah-MP

O modelo Noah-MP é capaz de descrever numericamente os estados de energia terrestre, carbono, água e as trocas de fluxos entre a superfície da terra e a atmosfera que são controlados por processos terrestres hidrometeorológicos e eco-hidrológicos (NIU *et al.*, 2011). Foi acrescentado no modelo a dinâmica da vegetação e da água subterrânea mostrado no trabalho de Niu e Yang (2007) e, em seguida, foi equipado com vários esquemas para cada um dos processos eco-hidrológicos. Essa versão do Noah (Noah-MP) foi escolhida pois há mais parametrizações disponíveis, apresentando uma gama mais ampla de processos físicos que podem ser utilizados pelo modelo, se tornando mais completo. As saídas dos modelos ocorrem a cada três horas, diariamente e mensalmente. Possui, também, uma estrutura que consiste em uma camada de dossel, três camadas de neve e quatro camadas de solo e é capaz de calcular a temperatura da superfície resolvendo iterativamente o equilíbrio de energia da superfície da radiação solar, radiação de onda longa, calor sensível, calor latente e fluxos de calor do solo.

Além disso, o modelo representa explicitamente alguns processos como a evaporação da superfície do solo, perda de interceptação do dossel e transpiração por meio de formulações em analogia à lei de Ohm, considerando as resistências aerodinâmicas e estomáticas ao vapor de água e fluxos de carbono dentro e sobre os dossel da planta. A transpiração da planta é limitada pela resistência estomática, que está ligada à fotossíntese e posteriormente é controlada pela US na zona da raiz. O modelo consegue assumir raízes uniformemente distribuídas em direção vertical e a profundidade de raiz varia dependendo dos tipos de vegetação (MA *et al.*, 2017).

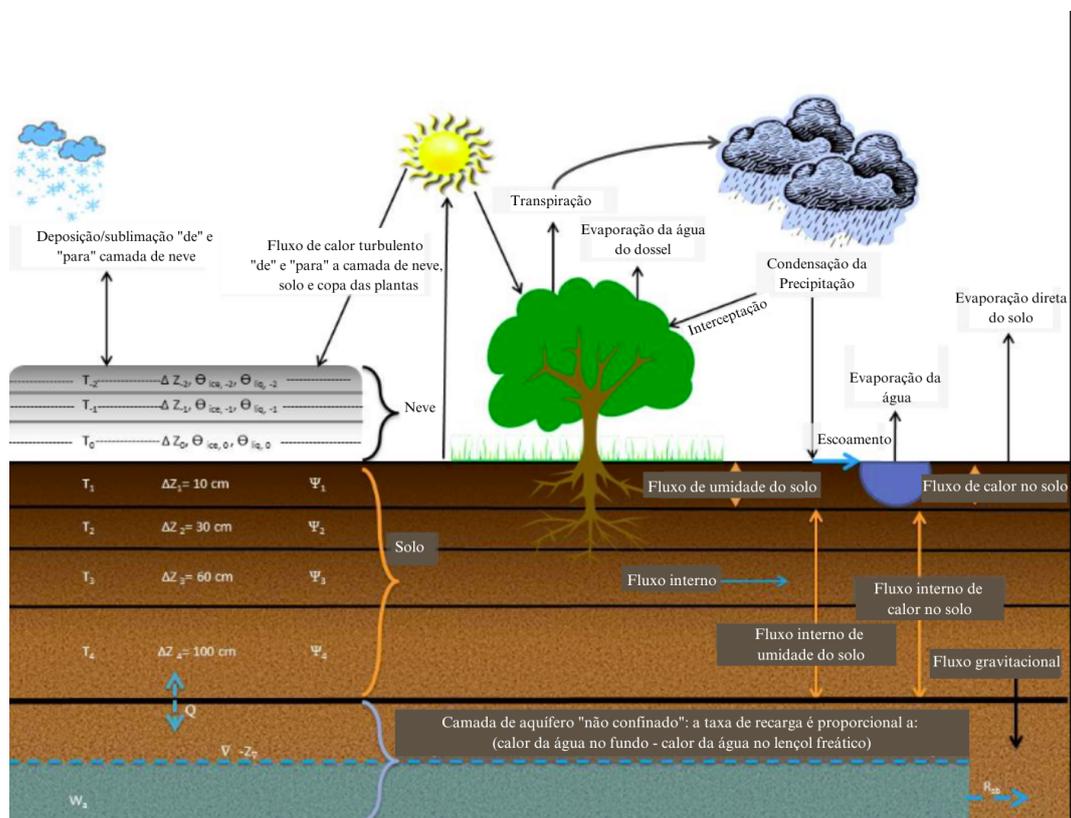
O modelo inclui opções para parametrizar 10 estados e processos físicos distintos da superfície da terra, sendo eles: (1) vegetação, (2) resistência estomática, (3) fator de US para resistência estomática, (4) escoamento e água subterrânea, (5) coeficiente de arrasto da camada superficial, (6) água líquida supercongelada, (7) permeabilidade do solo congelado, (8) transferência radiativa, (9) albedo da neve e (10) partição congelada ou líquida (ARSENAULT *et al.*, 2018). Além da vegetação dinâmica, o solo possui um perfil reconfigurável total de 2 metros, divididas em quatro camadas com 10 (0-10), 30 (10-40), 60 (40-100) e 100(100-200) cm.

Com relação aos parâmetros, o modelo possui um total de 42 parâmetros especificados pelo usuário e deve ser definido para as configurações Noah-MP que simulam

a vegetação dinâmica. Dentre os 42 parâmetros, 30 estão relacionados à vegetação e 12 ao solo. Os valores são atribuídos por meio de tabelas de pesquisa indexadas pela vegetação fornecida por *US Geological Survey* (USGS) e esquemas de categorização de solo (ARSENAULT et al., 2018).

No modelo, o Armazenamento de Água Terrestre (AAT) é a soma da US em todas as camadas, neve acumulada e água da superfície do dossel da planta (ŚLIWIŃSKA et al., 2019). Na Figura 3.2 está representado esquematicamente os processos físicos simulados pelo modelo Noah-MP.

Figura 3.2 - Esquema representando os processos físicos simulados pelo NOAH-MP.



Fonte: Adaptado de University of Texas (2021).

3.1.2.2 CLSM-F2.5

A versão CLSM-Fortuna 2.5 (CLSM-F2.5) do CLSM usado na NASA GEOS-5, é destinada à componente terrestre da modelagem terra-atmosfera acoplada em escala

global (KOSTER et al., 2000). De acordo com Rui et al. (2018), este modelo, assim como o Noah-MP, também possui um módulo de água subterrânea, porém aqui a profundidade do solo é de 1m. Ainda segundo os autores, o modelo não possui níveis verticais explícitos para a US, onde esta variável é determinada por um perfil de equilíbrio de US da superfície ao lençol freático e também por outras duas variáveis adicionais que são capazes de descrever os desvios do perfil de equilíbrio da zona superficial (0-2 cm) e da e da zona radicular (0-100 cm). Além disso, o modelo conta com seis camadas para a temperatura do solo (0-10, 10-29, 29-68, 68-144, 144-295 e 295-1295 cm).

Segundo Xia et al. (2017), o armazenamento de água subterrânea pode ser derivado do déficit de captação e da capacidade máxima de água de cada captação, que é determinada pelo parâmetro de profundidade do leito rochoso e porosidade do solo. O Armazenamento de Água Terrestre (AAT) no CLSM é a soma da água do solo, Água Equivalente da Neve (AEN), água do dossel e água subterrânea. O Armazenamento de Água Subterrânea (AAS) no CLSM já está incluído no AAT. A Equação 3.1 para calcular o AAS no CLSM está representada a seguir, onde USZR corresponde à US na zona de raiz e ID é a interceptação do dossel.

$$AAS = AAT - USZR - AEN - ID \quad (3.1)$$

Segundo Lynch-Stieglitz (1994), o CLSM inclui um modelo de camada de neve que possui três camadas que considera o derretimento e o recongelamento da neve, mudanças na densidade, propriedades de isolamento e outras físicas relevantes da camada de neve. Em cada uma dessas camadas há três variáveis prognósticas: conteúdo de calor, profundidade da neve e AEN. Além do modelo de camada de neve, o CLSM-F2.5 também inclui um modelo simples da biosfera modificado que aproveita os dados de albedo disponíveis pelo MODIS (GAO et al., 2014).

3.1.2.3 IBIS

O modelo IBIS também será utilizado neste trabalho e consiste em um modelo de superfície que é capaz de representar os processos físicos que ocorrem na superfície continental. O modelo foi desenvolvido por Foley et al. (1996), Kucharik et al. (2000) e foi projetado para ser um modelo abrangente da biosfera terrestre; sendo capaz de representar uma ampla gama de processos, incluindo física da superfície terrestre, fisiologia do dossel, fenologia vegetal e dinâmica da vegetação e ciclo de carbono e nutrientes (KUCHARIK et al., 2000). Além disso, o modelo é projetado em torno de

uma estrutura modular e hierárquica (FOLEY et al., 1996).

De acordo com Kubota (2012), o IBIS possui um modelo de solo com oito camadas para simular a temperatura do solo e o conteúdo de água e gelo e possui uma espessura total de 12 metros para melhor simular a profundidade do sistema de raiz das plantas tropicais. Além disso, também é presente um modelo de neve de três camadas usadas para cobertura de neve no solo e gelo marinho e também um módulo de vegetação dinâmica que inclui o de armazenamento de carbono no solo e a mudança de vegetação em escala de tempo mensal e anual (KUBOTA, 2012). Ainda sobre a vegetação, o modelo especifica em cada ponto de grade duas camadas de vegetação, onde a camada inferior inclui vegetação rasteiras (arbustos e gramíneas) e a camada superior que inclui árvores mais altas (FOLEY et al., 1996).

Segundo Kubota (2012), o escoamento superficial ocorre quando a evaporação menos a taxa de precipitação excede a taxa de infiltração máxima possível. A US é removida de cada camada que contém as raízes das plantas para fornecer a taxa de transpiração. O IBIS é um dos modelos de superfície que são utilizados no *Brazilian Atmospheric Model* (BAM) que é um MCGA do CPTEC/INPE.

3.1.3 Forçantes meteorológicas

3.1.3.1 GDAS

O *Global Data Assimilation System* (em português, Sistema Global de Assimilação de Dados- GDAS) foi utilizado no trabalho como forçantes dos LSM para os experimentos. Esse sistema é utilizado pelo modelo do *Global Forecast System* (GFS) do *National Center for Environmental Prediction* (NCEP) e adiciona os seguintes tipos de observações a um espaço de modelo em grade 3D: observações de superfície, radiossondas, perfis de vento, aerotransportado, observações de bóias, navios, radar e satélite (NASA, 2021c).

Segundo Rodell et al. (2004), uma grade gaussiana fina com 768 pontos de grade na direção zonal e 364 pontos de grade na direção meridional é utilizada, tendo uma resolução espacial de cerca de $0,47^\circ$. Além de assimilar diversos dados convencionais utilizando a abordagem *Four-Dimensional Variational Data Assimilation Technique* (4D-Var), o GDAS produz análises globais operacionais para quatro horas sinóticas: 0000, 0600, 1200 e 1800 UTC.

Lembrando que o GDAS fornece o conjunto completo de forçantes derivados do sistema de assimilação do GFS. Posteriormente neste trabalho, quando não está

sendo utilizado o CERES, a forçante de radiação de onda curta incidente é fornecida pelo GDAS.

3.1.3.2 MERGE

O produto *Multi-satellite Retrievals for GPM* (MERGE) consiste na combinação de dados observados de precipitação com as estimativas de precipitação de satélite *Tropical Rainfall Measuring Mission* (TRMM) que é um projeto conjunto entre a NASA e a *Japan Aerospace Exploration Agency* (JAEA) (ROZANTE et al., 2010). Os dados observados de precipitação são uma combinação de conjuntos de dados de pluviômetros do *Global Telecommunications System* (GTS) e também de estações automáticas.

De acordo com (ROZANTE et al., 2010), os dados obtidos do MERGE possuem cobertura espacial para toda a AS aproximadamente 85°O-27°O e 57°S-13°N, com uma resolução espacial de 5 km e com saídas mensais. Além disso, o MERGE faz estimativas diárias para todo o território brasileiro (75°O-34°O e 35°S-06°N). Os acumulados diários estão disponíveis em: <http://ftp.cptec.inpe.br/modelos/tempo/MERGE/GPM/>.

3.1.3.3 CERES

O projeto *Clouds and the Earth's Radiant Energy System* (CERES, em português, nuvens e sistema de energia radiante da terra) será utilizado como dado de forçante de radiação. O projeto fornece observações baseadas em satélites (TERRA e AQUA) que quantificam o orçamento de radiação na Terra (ORT) e em nuvens. O CERES é capaz de determinar as propriedades das nuvens, incluindo a quantidade de nuvens presentes, altura, espessura, tamanho das partículas e fase das nuvens usando medições simultâneas por outro EOS e instrumentos do *Joint Polar Satellite System* (JPSS), como o MODIS e o *Visible Infrared Imaging Radiometric Suite* (VIIRS) (NASA, 2021g).

Os dados deste projeto são coletados desde 1997, quando o primeiro instrumento foi lançado a bordo do satélite TRMM. O ORT no topo, dentro da atmosfera, e na superfície são descrito pelas medições do CERES juntamente com as medições de imageadores de alta resolução em órbita polar e em satélites geostacionários como também utiliza-se de outras fontes de dados. Os produtos de dados CERES capturam variações no ORT em escalas de tempo horárias, diárias e mensais e em escalas espaciais que variam de 20 km a global (NASA, 2021g). Os dados do CERES

estão disponíveis em: <https://ceres.larc.nasa.gov/data/> e o produto usado será o “SYN1deg”.

3.1.4 Dados de referência

3.1.4.1 GLDAS

O GLDAS é um sistema de modelagem terrestre offline global de alta resolução, que incorpora observações terrestres e de satélite para produzir campos ideais da superfície terrestre, estados e fluxos em tempo quase real (RODELL et al., 2004). É integrado uma grande quantidade de dados baseados em observação e é executado globalmente em altas resoluções (2,5 graus a 1km) sendo capaz de produzir resultados quase que em tempo real (NASA, 2021a).

Existem três modelos de superfície que são utilizados no GLDAS: Noah, VIC e CLSM, o primeiro possui 4 camadas (0-0,1, 0,1-0,4, 0,4-1,0, 1,0-2,0m), o segundo possui 3 níveis (0-0,3 representa a superfície e a segunda e terceira camadas são espacialmente variáveis) e o terceiro não é dividido em camadas e sim em: superfície, zona de raiz e o perfil (onde o perfil inclui superfície e zona de raiz e a zona de raiz inclui superfície) (NASA, 2021a).

Esse sistema de assimilação cobre uma extensão espacial de todo o globo terrestre que esteja ao norte de 60° em um período de 1948 até o presente com resolução temporal de 15 minutos com campos de saídas de 3 horas. As saídas desses campos são em NetCDF ou GDS (NASA, 2021b).

Para ser utilizado, os dados de umidade do solo do GLDAS, a variável passou pela mesma conversão que o modelo Noah-MP, onde a umidade do solo foi dividida pela porosidade, que no caso é 0,42 para o GLDAS e Noah-MP.

A base de dados forçantes do GLDAS é o GDAS (proveniente do sistema de AD do GFS), também utilizado neste trabalho. Assim, tornando a comparação entre GLDAS e SALDAS mais adequada. Assim como o SALDAS, o GLDAS tem como opção forçantes de precipitação e radiação bases de dados derivadas de observações e satélite.

3.1.4.2 Reanálise ERA-5

Será utilizado a quinta versão da reanálise europeia (ERA-5) pertencente ao ECMWF e que substitui a reanálise ERA-Interim (HERSBACH et al., 2019). Esses

dados serão utilizados para comparar os resultados obtidos dos experimentos. O banco de dados ERA-5 lançou em 2018 o conjunto de dados final que possui dados desde 1979 até os dias atuais, e a versão preliminar do período de 1950-1978 foi disponibilizada em novembro de 2020.

O ERA-5 possui resolução temporal de uma hora e horizontal de 30 km, contando com 37 níveis de pressão e diversas variáveis. Segundo [Hersbach et al. \(2019\)](#) o ERA-5 realiza a AD a partir do método de assimilação 4D-Var e configurações que acarretam em um aumento na qualidade dos dados quando comparado com seu antecessor ERA-Interim.

3.1.4.3 ESA-CCI

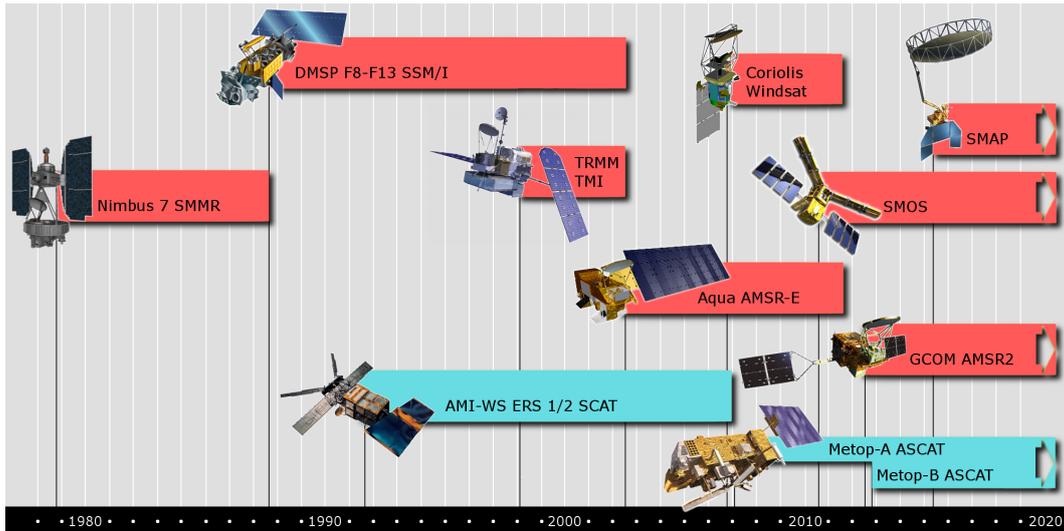
As medições de satélites são uma forma de complementar os dados observacionais de US, uma vez que as observações *in situ* da US são escassas e não conseguem ser representadas em escala global. No presente estudo será utilizado o produto de US que faz parte do programa ESA do Monitoramento Global de Variáveis Climáticas Essenciais (em inglês, *Essential Climate Variables- ECV*) mais conhecido como Iniciativas de Mudanças Climáticas (em inglês, *Climate Change Initiative -CCI*) ([ESA, 2021b](#)). Os dados do ESA-CCI serão utilizados como dados de referência para comparar os resultados dos experimentos e também serão assimilados nos modelos (Noah-MP, CLSM, IBIS) como mostrado na [Seção 4.3](#).

Segundo a documentação oficial escrita por [ESA... \(2021\)](#), o produto de US do ESA-CCI consiste em três conjuntos de dados de US de superfície: o produto Ativo e o Passivo foram criados pela fusão de produtos de US de escaterômetro e por radiômetro, respectivamente; o outro produto é o “combinado”, que consiste em um produto com base nos dois conjuntos de dados anteriores. Os arquivos de dados são fornecidos no formato NetCDF-4 e possuem resolução temporal diária e resolução espacial de 0,25° com cobertura global ([ESA..., 2021](#)).

O produto de US do ESA CCI utiliza 4 sensores de micro-ondas ativos (azul) e 8 passivos (vermelho) como mostrado na [Figura 3.3](#). Os sensores *Active Microwave Instrument - Windscat* (AMI-WS) e ASCAT são instrumentos dispersores de banda C (ativos) a bordo dos satélites do *European Remote Sensing Satellite* (ERS) e do *Meteorological Operational Satellite* (METOP), respectivamente. Os sensores SMMR, *Special Sensor Microwave Imager* (SSM/I), TRMM, *Microwave Imager* (TMI), *Microwave Scanning Radiometer Earth observing system* (AMSR-E), AMSR-2, *Microwave Imaging Radiometer using Aperture Synthesis* (MIRAS), SMAP banda L

são radiômetros multifrequenciais (passivos) a bordo do Nimbus-7, *Defense Meteorological Satellite Program* (DMSP), TRMM, *Global Change Observation Mission-Water* (GCOM-W1), SMOS, Satélites SMAP (ESA, 2021b; ESA..., 2021).

Figura 3.3 - Instrumentos de micro-ondas usados para a geração de produtos de dados de US.



Fonte: ESA (2021a).

A combinação das observações de microondas passivas e ativas no nível de recuperação é uma abordagem que mescla os produtos de US derivados de diferentes instrumentos de satélites, permitindo o fornecimento e a ampliação de dados de US global (LIU et al., 2011).

Foram utilizadas as médias mensais do ESA-CCI, assim como os demais dados utilizados no trabalho. Como a série de dados não é completamente preenchida em todo o território da AS, principalmente devido à vegetação densa na região norte, ou então pela presença de gelo na região das Cordilheira dos Andes, foi adotado um critério pelo próprio ESA-CCI onde as médias foram feitas para a base de dados que tivesse mais de 30% de dados válidos. Além disso, foi considerada a porosidade máxima do ESA-CCI, 0,45, para obter o valor volumétrico da umidade do solo na superfície. Logo, todas as estatísticas foram feitas considerando a porosidade do solo para todos os modelos, além do ESA-CCI.

3.2 Percentil de Umidade do Solo

O Percentil de Umidade do Solo é utilizado para determinar os padrões espaciais e temporais da seca. Essa estatística permite identificar períodos com maior severidade ou não da seca em diferentes níveis do solo. De acordo com a profundidade do solo, é possível identificar uma resiliência maior ou menor do evento de seca e seus impactos em atividades onde o conhecimento das condições de umidade do solo em camadas mais profundas são críticos para a tomada de decisão.

Pode ser definido como a medida que divide a amostra em 100 partes seguindo a ordem crescente dos dados. Cada parte possui uma porcentagem aproximadamente igual dos dados. O p-ésimo percentil corresponde à frequência cumulativa do número total da população N vezes p dividido por 100 ($N \times p/100$). Neste estudo o estado de seca é considerado o percentil de umidade do solo abaixo de 30, logo, a partir do percentil 30 há a presença de seca, mesmo que fraca.

3.3 Standard Precipitation Index (SPI)

Este índice representa o Índice de Precipitação Padronizado e é comumente utilizado para o monitoramento de condições associadas a secas. O conceito SPI foi desenvolvido, primeiramente, por McKee, et al. (1993), onde utilizam o SPI como indicador, uma definição funcional e quantitativa de seca pode ser estabelecida para cada escala de tempo. No estudo, a seca inicia quando o SPI cai primeiro abaixo de zero e termina com o valor positivo do SPI e a intensidade da seca é definida arbitrariamente para valores do SPI mostrado na [Tabela 3.1](#). O SPI utilizado neste trabalho é baseado somente no produto de precipitação mensal, neste caso, produzido pelo CPTEC/INPE que utiliza diversas fontes de dados disponibilizado no Brasil e se baseia na metodologia do *National Integrated Drought Information System* dos Estados Unidos da América (<http://www.drought.gov>) para monitoramento de seca, logo, o range do SPI do CPTEC/INPE corresponde ao percentil de umidade do solo do modelo CPC, mostrado no documento disponibilizado pelo *National Integrated Drought Information System* dos Estados Unidos.

As categorias da intensidade do evento de seca é mostrada na tabela abaixo

Tabela 3.1 - Valores correspondentes do SPI e do Percentil.

Categoria	Intensidade	Limiares de SPI	Percentil
DO	Fraca	-0,5 a -0,7	21 a 30
D1	Moderada	-0,8 a -1,2	11 a 20
D2	Severa	-1,3 a -1,5	6 a 10
D3	Extrema	-1,6 a -1,9	3 a 5
D4	Excepcional	-2 ou menor	0 a 2

Fonte: Produção do autor.

Existem categorias para o SPI, ou seja, 1, 3, 6, 9, 12 e 24, e essas categorias indicam os meses que foram observadas as secas, logo, para a categoria 1 representa um mês que aquela seca foi observada, indicando uma seca mais superficial, a categoria 24 representa a seca que está naquela região a 24 meses, classificando como uma seca mais intensa e duradoura, sendo capaz de afetar camadas mais profundas do solo.

3.4 Descrição da metodologia

Nessa seção será descrita a metodologia que foi utilizada no presente trabalho. Para desenvolver o trabalho, foram utilizados três LSM (NoahMP, CLSM-F2.5 e IBIS) que foram forçados com diferentes dados de entrada (GDAS, MERGE e CERES).

As descrições abaixo foram realizadas com intuito de alcançar os três objetivos específicos do trabalho (a, b, c), ou seja, analisar o impacto das diferentes forçantes atmosféricas nos modelos de superfície, comparar com os dados de referências que foram escolhidos para serem utilizados no trabalho representando a modelagem offline (GLDAS), acoplada (ERA-5) e medições de satélites (ESA-CCI). Além disso, a análise também foi utilizada para identificar eventos de seca que são uma forma de avaliar a US.

Para a realização do trabalho, o primeiro passo foi realizar as simulações feitas pelos modelos de superfície, ou seja, rodar os três LSM, com as forçantes indicadas (GDAS, MERGE e CERES). Posteriormente, foi obtido as médias diárias e mensais desses dados. Uma vez finalizada as simulações dos três modelos e as médias, foram realizados os próximos passos do estudo.

Com os resultados dos modelos prontos, foram separados em dois experimentos, A e B, onde o Experimento A representa as rodadas dos modelos forçados com GDAS e MERGE, ou seja, utilizando os dados do MERGE como dados de precipitação, e os

dados do GDAS para as demais forçantes atmosféricas e o Experimento B representa as rodadas dos LSM forçados com as 3 forçantes, GDAS, MERGE e CERES, onde foram utilizados os dados do MERGE para precipitação, o CERES para radiação e o GDAS novamente para as demais forçantes

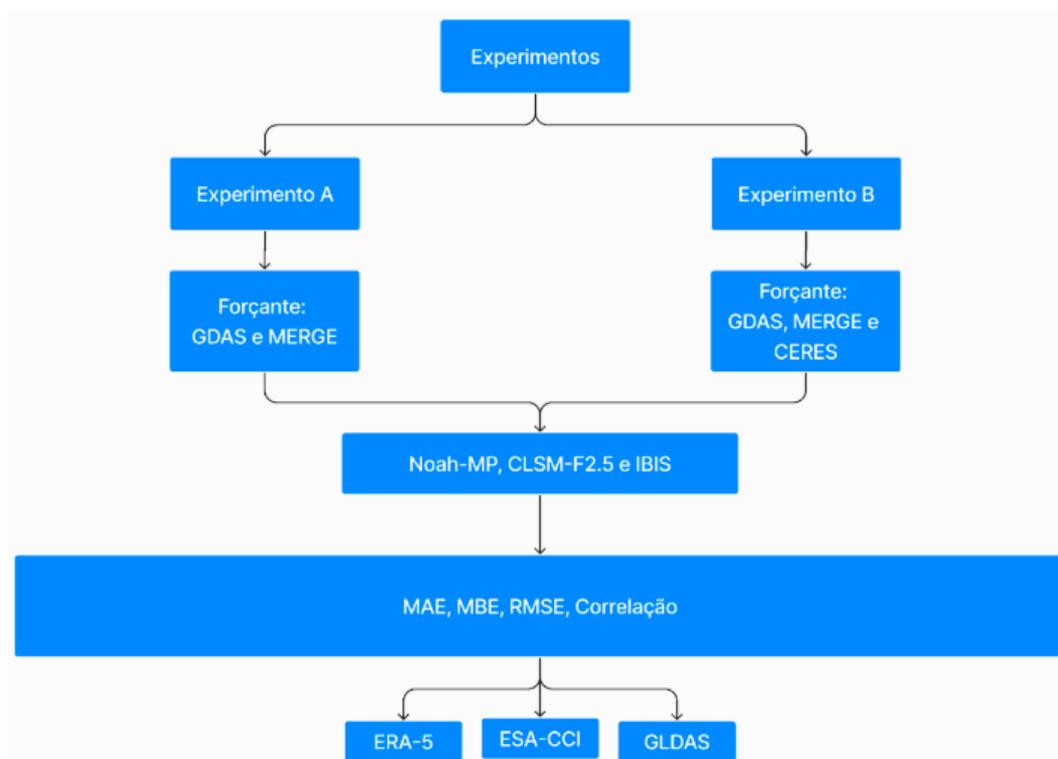
Para utilizarmos a US, foi considerada a porosidade do solo, uma vez que essa variável determina o quanto o solo pode ser ocupado pela água, logo, entendemos a importância de considerar a porosidade nas contas para se obter o valor da US mais próximo da realidade. A US, quando calculada considerando a porosidade, passou a ser obtida em porcentagem e não mais na unidade de medida de kg/m^2 .

Entendendo a extensão da AS, e seus diferentes climas, agrupamos regiões hidroclimáticas semelhantes, dividindo, então, a AS, em 5 regiões, sendo elas: Norte (NO), Nordeste (NE), Sul (Sul), Amazonas (AM) e a Bacia do Prata (PA). Além disso, essas estatísticas foram feitas para cada estação do ano, uma vez que as características do tempo alteram conforme as estações do ano.

Com o intuito de validar os dados obtidos pelos LSM utilizando as forçantes, foram utilizadas as seguintes estatísticas: MBE, RMSE, Correlação de Pearson e Desvio Padrão para comparar esses dados com os dados de referência anteriormente mencionados (ERA-5, ESA-CCI e GLDAS) e que serão abordadas na [Seção 3.5](#). Essas estatísticas foram calculadas para cada modelo, para cada experimento (A e B), para cada região e cada estação do ano.

O esquema abaixo representado pela [Figura 3.4](#). mostra esquematicamente os experimentos A e B.

Figura 3.4 - Esquemática dos experimentos realizados no estudo.



Fonte:Produção do autor.

Na Figura 3.4, cada experimento (A e B) foi dado por simulações dos modelos Noah-MP, CLSM, IBIS, com o intuito de analisar a relação dos modelos com as diferentes forçantes meteorológicas buscando identificar as regiões que possuem maior sensibilidade às alterações dos dados de precipitação e radiação. Com os experimentos finalizados, foram realizadas intercomparação entre os resultados para que se analise a sensibilidade.

Para avaliar a destreza do SALDAS, os experimentos foram comparados com outras fontes de informações: GLDAS, Reanálise ERA-5 e ESA-CCI que correspondem à referências de modelagem offline, modelagem acoplada e observações de satélites, respectivamente. Para realizar essas comparações serão utilizados os métodos estatísticos citados na Seção 3.5 Os resultados dessas estatísticas de comparação entre os experimentos e os dados de referência nos fornecerá a qualidade dos campos de US obtidos pelo SALDAS para os três modelos com as diferentes forçantes.

Para analisar os eventos de secas, foram escolhidas secas específicas entre 2000 e 2020, comparando os resultados obtidos pelos modelos do estudo com os dados obtidos do SPI-1 proveniente do CPTEC/INPE.

3.5 Análises estatísticas

3.5.1 Coeficiente de Correlação de Pearson

O Coeficiente de Correlação de Pearson (r) consiste em medir o grau e a direção da correlação. Esse coeficiente, definido pela [Equação 3.2](#) assume um valor de -1 a 1, onde valores próximos a 1 significa que a correlação é perfeita positiva entre as duas variáveis, ou seja, quando a previsão está muito próxima à observação; Analogamente, quando r é mais próximo de -1 significa que a correlação negativa perfeita entre as variáveis observadas e simuladas, ou seja, se uma variável aumenta, a outra diminui. Quando $r = 0$ temos que as duas variáveis não dependem linearmente entre si ([ALVES; VECCHIA, 2011](#)).

$$r = \frac{\sum_{i=1}^n (x_i - x') - (y_i - y')}{\sqrt{\sum_{i=1}^n (x_i - x') \sum_{i=1}^n (y_i - y')^2}} \quad (3.2)$$

Na [Equação 3.2](#) o termo x_i refere-se ao valor predito pelo modelo, onde x' refere-se à média dos valores simulados e y_i refere-se aos valores observados e y' à média dos valores observados.

3.5.2 RMSE

Root-Mean-Square Error (RMSE) é a raiz quadrada da média do erro das previsões ao quadrado. Esse método estatístico indica a qualidade do ajuste da previsão que é gerada pelo modelo com os dados observados. A [Equação 3.3](#) define o RSME que é calculado pela diferença entre o valor predito pelo modelo (\hat{y}_i - variável simulada) e o valor real (y_i - valor observado). É realizada a soma desses termos e posteriormente é dividido pelo número de observações (n). Quanto maior o valor do RMSE, pior serão os dados do modelo. Como essa métrica eleva o erro ao quadrado, o método se mostra excelente para problemas nos quais grandes erros não são tolerados.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (3.3)$$

3.5.3 MBE

Mean Bias Error (MBE), também chamado de desvio das médias, está apresentado na Equação 3.4 e indica o quanto em média a variável simulada consegue se aproximar do observado. Esse método é utilizado para corrigir e aumentar o índice de acerto das previsões (SILVA et al., 2008). Além disso, ele nos fornece o quanto em média a variável simulada se aproxima da variável observada. O MBE é capaz de mensurar o quanto a variável estudada está sendo subestimada (MBE<0) ou superestimada (MBE>0) (DAFIS et al., 2017); o valor ideal de MBE é quando tende a zero (ALVES; VECCHIA, 2011).

$$MBE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i) \quad (3.4)$$

O problema dessa técnica está quando os erros subestimados e superestimados possuem a mesma magnitude, se cancelando na somatória final. Devido a isso, é indicado sua utilização juntamente com o RMSE.

3.5.4 Desvio padrão

Essa estatística consiste na medida que expressa o grau de dispersão de um conjunto de dados. Logo, quanto mais próximo de 0 for o desvio padrão, melhor são os dados, ou seja, mais próximo são os dados da própria média calculada. Sendo o somatório de todos os termos; x_i o valor na posição i no conjunto de dados, M_A a média aritmética dos dados e n a quantidade de dados.

$$DESV = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - M_A)^2} \quad (3.5)$$

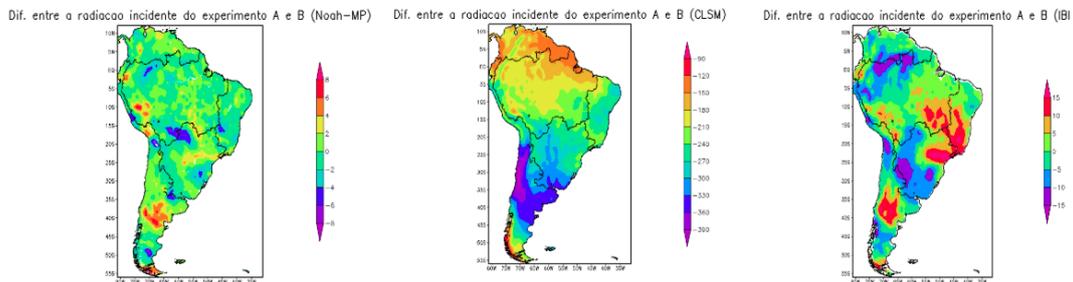
4 RESULTADOS E DISCUSSÕES

4.1 Análise estatística dos padrões de US e sua relação com as forçantes atmosféricas (GDAS, MERGE e CERES)

Para analisar o impacto das forçantes atmosféricas nas rodadas dos modelos, foram feitas a subtração do campo de radiação entre as rodadas com as forçantes GDAS e MERGE, comparando os as rodadas dos modelos utilizando as forçantes GDAS, MERGE e CERES. O resultado dessa diferença do campo de radiação é mostrado na Figura 4.1 abaixo.

Figura 4.1 Diferença entre a radiação incidente na superfície, comparando os três modelos (Noah-MP, CLSM e IBIS), utilizando apenas duas forçantes GDAS+MERGE (Experimento A) e as três forçantes, ou seja, com a inclusão da forçante de radiação CERES (Experimento B). Lembrando que as regiões delimitadas em preto nas figuras a, b e c, representam as regiões hidro-climáticas que são semelhantes.

Figura 4.1 - Diferença entre a radiação incidente na superfície (Experimento A e B), comparando os três modelos (Noah-MP, CLSM e IBIS).



Fonte:Produção do autor.

Na Figura 4.1(a) é a rodada do modelo Noah-MP, nela é possível observar que o modelo apresenta menor sensibilidade com a adição da forçante de radiação CERES, ou seja, apresenta uma menor diferença entre os campos utilizando a forçante CERES e sem utilizá-la (colocar motivo). Na figura é possível notar que basicamente toda a extensão da AS apresenta diferenças positivas entre a diferença da rodada do modelo com as três forçantes e o modelo sem a forçante de radiação. São poucas as regiões onde apresentam uma diferença negativa, apresentadas pelas cores azuladas no mapa, no extremo sul do continente, no centro da AS e em algumas pequenas

regiões ao longo do continente. Essa pequena diferença da radiação utilizando a forçante do CERES pode ser explicada devido a vegetação dinâmica do modelo.

O IBIS (Figura 4.1(b)), assim como o Noah-MP, também apresenta uma diferença não muito significativa na radiação quando comparado com o CLSM. Sua escala é de +/- 15 W/m² e as diferenças positivas mais significativas se encontram entre as regiões NE e PA e, também, no centro da região SU da AS. Já as regiões que apresentam diferenças negativas mais significativas se encontram entre as regiões AM e NO, e também na região do sudoeste do PA. Essas pequenas diferenças positivas na radiação, ou seja, quando a rodada do IBIS utiliza o CERES apresenta uma radiação maior que a rodada do modelo sem essa forçante.

O CLSM mostra diferenças maiores, seja positiva ou negativa, quando comparado os três modelos, principalmente na região da Cordilheira dos Andes com uma diferença negativa superior a 300 W/m². Já o modelo IBIS apresenta maior diferença negativa distribuído em toda a América do Sul.

As diferenças apresentadas acima pode ser explicadas pelo modelo Noah apresentar uma vegetação dinâmica, isso faz com que a vegetação seja alterada a cada ciclo do modelo, fazendo com que o Noah-MP tenha mais equações para calcular o balanço de radiação, logo, as rodadas com ou sem CERES não interfere significativamente na saída da radiação. Já nos modelos CLSM e IBIS, a vegetação não está dinâmica, apresentando mais valores constantes, podendo resultar em diferenças mais significativas quando considerado o CERES na rodada. É interessante ressaltar que uma melhor representação da vegetação, influencia no albedo, que por sua vez influencia na radiação de onda curta. Logo, quando uma região apresenta degradação da vegetação, há um aumento do albedo e, conseqüentemente, um aumento da radiação de onda curta, que é mostrado pelas figuras.

4.2 Análise estatística dos padrões de US em comparação com a base de dados de referência

Neste tópico será discutido sobre o desempenho das rodadas dos modelos, utilizando forçantes distintos e comparando com os dados de referência. É válido recapitular que esses dados de referência utilizados no trabalho representam a modelagem *offline* (GLDAS), acoplada (ERA-5) e medições de satélites (ESA-CCI). No contexto do trabalho, quando é usado os termos *offline* e acoplado, refere-se a superfície e atmosfera, logo, as simulações *offline* são representadas pelo SALDAS e GLDAS, as simulações acopladas são representados pelo ERA-5 e GLDAS. Para facilitar a

visualização dos resultados obtidos, foram coloridos de azul aqueles resultados que apresentaram melhor desempenho quando comparado com a base de dados de referência.

Os resultados foram divididos de forma que facilite o entendimento: foram separadas tabelas contendo todos os modelos e suas devidas referências, cada tabela representa a estatística com o dado de referência. Esses modelos foram divididos nas cinco regiões de estudo, e agrupados por estação do ano. Logo, fica mais fácil a visualização do desempenho dos modelos em todas as regiões de estudo e estação do ano. As tabelas estão representadas nas figuras a seguir.

4.2.1 Correlação

4.2.1.1 ERA5

As Figura 4.2 e Figura 4.3 representam os resultados obtidos do cálculo da Correlação de Pearson entre os três modelos e a base de dados do ERA5. A Figura 4.2 representa os três modelos forçados com as forçantes GDAS e MERGE, ou seja, sem a forçante de radiação e a Figura 4.3 representa os três modelos forçados com o GDAS, MERGE e CERES. As figuras a seguir apresentarão os resultados obtidos. Sabe-se que quanto maior o valor da correlação entre os dados, melhor é a estimativa do modelo e mais ele se assemelha aos dados da referência, que neste caso é o ERA5.

Figura 4.2 - Correlação dos dados obtidos pelos três modelos, em relação aos dados do ERA5, utilizando as forçantes meteorológicas GDAS e MERGE.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,94	0,94	0,95	0,94	0,94	0,94	0,93	0,91	0,91	0,94	0,93	0,94	0,94	0,94	0,93	0,95	0,96	0,94	0,94	0,96
CLSM	0,96	0,96	0,97	0,95	0,96	0,97	0,96	0,95	0,94	0,94	0,96	0,97	0,96	0,95	0,98	0,97	0,98	0,98	0,97	0,97
IBIS	0,70	0,64	0,60	0,65	0,65	0,76	0,72	0,78	0,75	0,76	0,78	0,77	0,81	0,83	0,77	0,82	0,82	0,73	0,77	0,77
GLDAS	0,96	0,96	0,96	0,95	0,95	0,97	0,96	0,95	0,96	0,96	0,96	0,96	0,95	0,96	0,96	0,96	0,96	0,95	0,94	0,97

Fonte:Produção do autor.

A Figura 4.2 acima, apresenta a correlação dos modelos em relação ao ERA5, sem ser considerada a forçante de radiação CERES. O intuito de calcular as estatísticas utilizando as diferentes forçantes é identificar se com a inclusão da forçante de ra-

dição o resultado das rodadas dos modelos se assemelha mais (ou menos) com os dados de referência.

Em relação à análise do desempenho dos modelos por região e por estação do ano, temos que para o verão o ranking dos modelos para as regiões NE, NO, AM e PA é CLSM, GLDAS, Noah-MP e IBIS; já a região SU, o ranking é GLDAS, CLSM, Noah-MP e IBIS. Na primavera, o ranking para as regiões NE, NO, SU e PA foi GLDAS, CLSM, Noah-MP e IBIS, para a região AM, o ranking ficou com CLSM, GLDAS, Noah-MP e IBIS. No inverno, o ranking para as regiões NO, AM e PA ficou com CLSM, GLDAS, Noah-MP e IBIS, já para as regiões NE e SU, ficou GLDAS, CLSM, Noah-MP e IBIS. E para a primavera o ranking para as regiões NE, NO e AM ficou CLSM, GLDAS, Noah-MP e IBIS; para a região SU, ficou CLSM, Noah-MP, GLDAS e IBIS; e para PA, ficou GLDAS, CLSM, Noah-MP e IBIS. Logo, dos modelos utilizados, o CLSM é o que apresenta melhor performance dentre os outros (Noah-MP e IBIS), porém, para algumas regiões o GLDAS apresentou melhor desempenho que o CLSM, no entanto, dentre os 3 modelos utilizados na pesquisa (CLSM, Noah-MP e IBIS), o CLSM é o que apresentou maior correlação com os dados do ERA5. Vale ressaltar que o IBIS apresentou menor desempenho dentre os modelos utilizados.

Podemos perceber que a região que apresenta melhores correlações é a NE e AM. Sobre as estações do ano, a que apresenta maior correlação é o inverno (PA - CLSM), seguido pela primavera (NO - CLSM), verão (AM - CLSM) e outono (NE - GLDAS).

Figura 4.3 - Correlação dos dados obtidos pelos três modelos, em relação aos dados do ERA5, utilizando as três forçantes meteorológicas.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,94	0,94	0,95	0,94	0,94	0,94	0,92	0,91	0,91	0,94	0,93	0,95	0,95	0,94	0,93	0,96	0,96	0,95	0,95	0,96
CLSM	0,96	0,95	0,97	0,95	0,94	0,94	0,96	0,93	0,91	0,93	0,94	0,97	0,95	0,94	0,97	0,97	0,97	0,97	0,96	0,96
IBIS	0,80	0,79	0,73	0,73	0,75	0,76	0,71	0,73	0,72	0,73	0,73	0,68	0,76	0,77	0,76	0,83	0,83	0,75	0,78	0,78
GLDAS	0,96	0,96	0,96	0,95	0,95	0,97	0,96	0,95	0,96	0,96	0,96	0,96	0,95	0,96	0,96	0,96	0,96	0,95	0,94	0,97

Fonte:Produção do autor.

A Figura 4.3 acima temos a correlação dos dados entre os modelos meteorológicos utilizados no trabalho e o GLDAS, com os dados do ERA5. Fazendo a análise por

região, temos que para a estação do verão, as regiões NE e AM, a ordem dos modelos que apresentaram melhor performance foi CLSM, GLDAS, Noah-MP e IBIS. Já para as regiões NO e SU, a ordem de desempenho dos modelos é GLDAS, CLSM, Noah-MP e IBIS, e para a região PA, o ranking fica GLDAS, Noah-MP, CLSM e IBIS.

Para o outono, nas regiões NO e AM o ranking dos modelos ficou GLDAS, CLSM, Noah-MP e IBIS, já nas regiões NE, SU e PA, o ranking ficou GLDAS, Noah-MP, CLSM e IBIS. Para o inverno, na região NE o ranking dos modelos ficou GLDAS, CLSM, Noah-MP e IBIS; já nas regiões NO, AM e PA, o ranking dos modelos é composto pelo CLSM, GLDAS, Noah-MP e IBIS; e para a região SU é GLDAS, Noah-MP, CLSM e IBIS. Em relação à primavera, temos que para as regiões NE, NO e AM, os modelos que apresentaram melhor desempenho foram o CLSM, GLDAS, Noah-MP e IBIS, já para a região SU, o ranking dos modelos ficou CLSM, Noah-MP, GLDAS e IBIS; e a região PA, ficou GLDAS, CLSM, Noah-MP e IBIS. Resumindo, o CLSM foi o modelo que apresentou melhores resultados quando comparado com os dados do ERA5, seguido pelo GLDAS, Noah-MP e IBIS, sendo o IBIS, o modelo com menor correlação.

Podemos observar que a região com os valores mais elevados da correlação estão concentrados nas regiões NE, NO e AM. Sobre as estações com melhores performances temos o inverno (PA - CLSM), seguido pela primavera (NO - CLSM), verão (AM - CLSM) e outono (NE - GLDAS)

Comparando os dados das [Figura 4.2](#) e [Figura 4.3](#), temos que para o Noah-MP, a maioria das correlações são maiores quando utilizado as três forçantes (GDAS, MERGE e CERES), apenas no verão que para algumas regiões (NE e SU), o melhor desempenho foi visto sem a utilização da forçante de radiação. Já para o CLSM, as maiores correlações estão nas rodadas dos modelos que não consideram o CERES como forçante de radiação. Para o modelo IBIS, no verão, outono e inverno as maiores correlações se encontram quando o modelo desconsidera o CERES em suas rodadas, para a primavera, temos que as maiores correlações estão presentes nas rodadas dos modelos que consideram o CERES como forçante de radiação.

4.2.1.2 ESA-CCI

Nas [Figura 4.4](#) e [Figura 4.5](#) a seguir, representam as correlações dos modelos utilizados no estudo com a base de dados do satélite ESA-CCI. A [Figura 4.4](#) representa a correlação dos modelos com o ESA-CCI, considerando as duas forçantes atmosféricas; já na [Figura 4.5](#) representa a correlação dos modelos com os dados do ESA-CCI,

mas com as três forçantes, ou seja, com o CERES.

Figura 4.4 - Correlação dos dados obtidos pelos três modelos, em relação aos dados do ESA-CCI, utilizando as duas forçantes meteorológicas (GDAS e MERGE).

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,96	0,94	0,96	0,97	0,96	0,93	0,94	0,93	0,95	0,94	0,97	0,96	0,98	0,96	0,94	0,97	0,97	0,96	0,96	0,98
CLSM	0,93	0,93	0,95	0,95	0,94	0,96	0,94	0,97	0,93	0,93	0,95	0,97	0,97	0,95	0,97	0,98	0,97	0,96	0,97	0,96
IBIS	0,63	0,52	0,45	0,54	0,49	0,64	0,61	0,67	0,58	0,65	0,67	0,69	0,72	0,77	0,71	0,71	0,74	0,63	0,65	0,65
GLDAS	0,96	0,95	0,96	0,96	0,95	0,93	0,96	0,95	0,95	0,95	0,97	0,96	0,96	0,96	0,96	0,97	0,97	0,96	0,96	0,97

Fonte:Produção do autor.

Sobre a análise em relação ao desempenho NE, AM, SU e PA, o ranking dos modelos ficaram Noah-MP, GLDAS, CLSM e IBIS; já para a região NO, o ranking ficou GLDAS, Noah-MP, CLSM e IBIS. Para o outono, na região NE o CLSM apresentou maior correlação, seguido pelo Noah-MP, GLDAS e IBIS; na região NO, o modelo que apresentou maior desempenho foi o GLDAS, seguido pelo CLSM, Noah-MP e IBIS; na região AM, o CLSM apresentou, novamente melhor desempenho, seguido pelos modelos GLDAS, Noah-MP e IBIS; na região SU o Noah-MP apresentou melhor desempenho, seguido do GLDAS, CLSM e IBIS; já a região PA, o ranking dos modelos foram GLDAS, Noah-MP, CLSM e IBIS. Para o inverno, nas regiões NE e SU o GLDAS apresentou melhor performance, seguido pelo Noah-MP, CLSM e IBIS; já as regiões NO e PA o CLSM apresentou melhor desempenho seguido pelo GLDAS, Noah-MP e IBIS; na região AM o Noah-MP apresentou melhor desempenho, seguido pelo CLSM, GLDAS e IBIS. Para a primavera, as regiões NE, NO, AM e SU apresentaram o seguinte ranking para os modelos CLSM, Noah-MP, GLDAS e IBIS; a região PA apresentou o seguinte ranking: Noah-MP, GLDAS, CLSM e IBIS.

Observa-se na tabela que as regiões que apresentaram maiores correlações com o ESA-CCI é, a região AM, seguida pela região NE. Sobre as estações do ano e região, a que teve melhor desempenho foi a primavera (PA - Noah-MP), seguida pelo inverno (AM - Noah-MP), verão (SU - Noah-MP) e outono (AM - CLSM). É possível perceber que o IBIS apresenta os menores valores para correlação com os dados do ESA-CCI, quanto aos modelos que apresentaram maiores valores para correlação, tem-se o Noah-MP e GLDAS.

A Figura 4.5 representa a correlação entre os modelos usados no trabalho e o ESA-CCI com a adição da forçante de radiação. Os resultados estão apresentados a seguir.

Figura 4.5 - Correlação dos dados obtidos pelos três modelos, em relação aos dados do ESA-CCI, utilizando as três forçantes meteorológicas.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,96	0,95	0,96	0,96	0,96	0,94	0,92	0,93	0,95	0,95	0,97	0,97	0,98	0,96	0,95	0,97	0,97	0,96	0,97	0,98
CLSM	0,93	0,92	0,94	0,95	0,92	0,94	0,93	0,94	0,90	0,91	0,94	0,96	0,96	0,95	0,97	0,97	0,97	0,95	0,95	0,95
IBIS	0,70	0,69	0,62	0,63	0,62	0,65	0,61	0,64	0,56	0,63	0,65	0,61	0,68	0,72	0,72	0,72	0,76	0,66	0,67	0,67
GLDAS	0,96	0,95	0,96	0,96	0,95	0,93	0,96	0,95	0,95	0,95	0,97	0,96	0,96	0,96	0,96	0,97	0,97	0,96	0,96	0,97

Fonte:Produção do autor.

Observa-se que na Figura 4.5 acima, em relação à análise do desempenho dos modelos em cada estação e região do estudo temos que para o verão, na região NE, os melhores desempenhos foram obtidos pelo Noah-MP, GLDAS, CLSM e IBIS, nas regiões NO, SU e PA temos que o ranking ficou Noah-MP, GLDAS, CLSM e IBIS; na região AM, ficou GLDAS, Noah-MP, CLSM e IBIS. Para o outono, na região NE, o Noah-MP e CLSM apresentaram o mesmo valor de correlação, seguido pelo GLDAS e IBIS. Já na região NO, o ranking ficou GLDAS, CLSM, Noah-MP e IBIS; para a região AM, o ranking ficou GLDAS, CLSM, Noah-MP e IBIS; para as regiões SU e PA o ranking ficou Noah-MP, GLDAS, CLSM e IBIS. No inverno, temos que para as regiões NE e SU, o ranking dos modelos ficaram GLDAS, Noah-MP, CLSM e IBIS, para as regiões NO e AM, ficou Noah-MP, GLDAS, CLSM e IBIS, e para a região PA o ranking ficou CLSM, GLDAS e Noah-MP. Na primavera, nas regiões NE, AM, SU e PA o ranking dos modelos ficaram Noah-MP, GLDAS, CLSM e IBIS; já para a região NO, ficou Noah-MP, CLSM, GLDAS e IBIS. Observamos que o CLSM não foi o modelo que apresentou maiores correlações com os dados do ESA-CCI, ao contrário do que foi visto nas Figura 4.2 e Figura 4.3 anteriormente com os dados do ERA5. Aqui, os modelos que apresentaram melhor desempenho foram o Noah-MP, seguido pelo GLDAS, CLSM e IBIS. Novamente vemos que o IBIS foi o modelo que apresentou menores correlações.

Quanto à região que apresentou maior correlação foi a região NE. Sobre as estações do ano, o inverno (AM - Noah-MP) e primavera (PA - Noah-MP) foram as estações

que apresentaram maiores valores de correlação da [Figura 4.5](#), seguido pelas estações verão (SU - Noah-MP) e outono (SU - Noah-MP).

Comparando as correlações obtidas dos modelos utilizando as duas forçantes e as três forçantes, temos que o modelo Noah-MP, no verão, as regiões NE e NO apresentam maiores correlações quando consideram o CERES, já regiões como AM e SU, as maiores correlações se encontram quando não é considerado o CERES na rodada do Noah-MP, a região PA apresentou correlações semelhantes, tanto com a inclusão do CERES, e sem a inclusão do mesmo. Para o outono, as regiões NE, SU e PA apresentaram maiores correlações quando considerado o CERES nas rodadas do Noah-MP, na região NO, a maior correlação foi quando o CERES não foi considerado nas rodadas, e na região AM não teve variação da correlação com ou sem o CERES. Em relação aos dados do CLSM, para todas as estações do ano e para todas as regiões do estudo, as maiores correlações se encontram nas rodadas do modelo com a inclusão do CERES. Para o modelo IBIS, para o verão e primavera, para todas as regiões do estudo, as rodadas sem considerar os dados do CERES apresentaram maiores valores de correlação; para o outono, para as regiões NE, NO e AM, as correlações são superiores com a inclusão do CERES, já as regiões SU e PA, as correlações são maiores quando não são considerados os dados do CERES; para o inverno, as correlações mais altas estão nas rodadas do modelo sem considerar a forçante CERES.

4.2.1.3 GLDAS

Na [Figura 4.6](#) e [Figura 4.7](#) representa as correlações dos modelos (Noah-MP, CLSM e IBIS) com relação ao GLDAS, a terceira base de referência do trabalho.

Figura 4.6 - Correlação dos dados obtidos pelos três modelos, em relação aos dados do GLDAS, utilizando as duas forçantes meteorológicas.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,98	0,97	0,99	0,99	0,99	0,98	0,97	0,98	0,97	0,99	0,99	0,99	0,98	0,98	0,98	0,99	0,99	0,98	0,99	0,99
CLSM	0,93	0,91	0,94	0,91	0,91	0,94	0,94	0,93	0,94	0,92	0,94	0,95	0,95	0,93	0,94	0,96	0,95	0,94	0,93	0,94
IBIS	0,56	0,52	0,43	0,49	0,47	0,63	0,57	0,60	0,59	0,61	0,62	0,62	0,68	0,70	0,62	0,68	0,68	0,56	0,57	0,62

Fonte:Produção do autor.

Quanto à análise da performance dos modelos em relação às estações do ano e regiões, temos a configuração semelhante à Figura 4.4.a, para todas as estações do ano, e para todas as regiões de estudo (NE, NO, AM, SU e PA) possuem o mesmo ranking de modelos para as melhores performance, que é Noah-MP, CLSM e IBIS. A região que apresentou as melhores correlações foi a região NE. Em relação ao desempenho levando em consideração às estações do ano, temos a primavera (PA - Noah-MP) é a que possui a maior correlação dos dados, seguida pelo verão (SU - Noah-MP), inverno (NO - Noah-MP) e outono com (PA - Noah-MP).

A Figura 4.7 abaixo representa a correlação para os dados dos modelos em relação ao GLDAS utilizando as três forçantes.

Figura 4.7 - Correlação dos dados obtidos pelos três modelos, em relação aos dados do GLDAS, utilizando as três forçantes meteorológicas.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,97	0,98	0,99	0,99	0,99	0,99	0,95	0,98	0,97	0,99	0,99	0,99	0,98	0,99	0,98	0,99	0,99	0,98	0,99	0,99
CLSM	0,92	0,90	0,93	0,92	0,89	0,90	0,91	0,89	0,88	0,88	0,93	0,93	0,94	0,91	0,93	0,95	0,94	0,93	0,92	0,93
IBIS	0,65	0,65	0,56	0,55	0,57	0,62	0,55	0,54	0,55	0,56	0,57	0,51	0,60	0,62	0,60	0,69	0,69	0,58	0,58	0,64

Fonte:Produção do autor.

Na Figura 4.7 acima apresenta as correlações dos modelos com o GLDAS. Analisando o desempenho dos modelos com as regiões e estações do ano, temos que para todas as estações do ano e todas as regiões de estudo (NE, NO, AM, SU e PA) o ranking dos modelos com melhor performance são Noah-MP, CLSM e IBIS. A região que apresentou melhores correlações foi a região NE.

Em relação às estações do ano, temos que tanto para o verão (AM-Noah-MP) e primavera (NE e PA - Naoh-MP) apresentam as maiores correlações da tabela, seguido pelo inverno (NO - Noah -MP) e outono (PA - Noah-MP).

Sobre a comparação entre as rodadas utilizando a forçante do CERES e sem essa forçante, temos que o modelo Noah-MP apresenta correlações semelhantes com e sem a adição da radiação, mas a maioria das correlações são ligeiramente maiores com a adição do CERES na rodada do Noah-MP. O CLSM também apresenta correlações semelhantes com e sem a adição do CERES, no entanto, as rodadas sem a inclusão da

forçante de radiação apresenta correlações maiores. O modelo IBIS também possui correlações semelhantes com e sem a forçante CERES, mas os maiores valores, em maioria, estão com a inclusão do CERES na rodada do modelo.

Observa-se, então, que o IBIS apresentou menor correlação quando comparado com o CLSM e Noah-MP, independente do dado de referência utilizado, sendo considerado, então, o modelo que mais se distanciou dos dados de referência. O modelo que mais apresentou similaridade com os dados do ERA5 foi o CLSM, e com o dado do GLDAS foi o Noah-MP o modelo que mais se assemelhou com os dados desta referência. Sobre os dados do ESA-CCI, tanto o Noah-MP quanto o CLSM apresentaram alta correlação com essa base de dados de referência.

4.2.2 RMSE

4.2.2.1 ERA5

A Figura 4.8 apresenta os resultados obtidos a partir do cálculo do RMSE para as rodadas dos modelos utilizando as forçantes GDAS e MERGE, para os três modelos (Noah-MP, CLSM e IBIS) e também em relação à base de referência GLDAS. Já a Figura 4.9 representa o RMSE para as rodadas utilizando as forçantes GDAS, MERGE e CERES, também comparando os com dados do ERA5.

Figura 4.8 - RMSE dos dados obtido pelos três modelos, em relação aos dados do ERA5, utilizando as duas forçantes meteorológicas.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,30	0,29	0,29	0,29	0,28	0,28	0,29	0,29	0,30	0,28	0,28	0,28	0,28	0,28	0,28	0,28	0,28	0,27	0,28	0,27
CLSM	0,08	0,08	0,08	0,08	0,08	0,09	0,09	0,08	0,08	0,08	0,09	0,09	0,10	0,10	0,09	0,10	0,10	0,10	0,10	0,10
IBIS	0,39	0,41	0,39	0,40	0,41	0,46	0,47	0,47	0,48	0,49	0,48	0,49	0,49	0,44	0,46	0,45	0,45	0,47	0,47	0,47
GLDAS	0,33	0,34	0,33	0,33	0,32	0,33	0,33	0,33	0,33	0,33	0,33	0,32	0,32	0,33	0,32	0,31	0,32	0,31	0,31	0,31

Fonte:Produção do autor.

Em relação ao desempenho dos modelos em relação às regiões de estudo e também em relação às estações, temos que para todas as estações e todas as regiões apresentam performance semelhante, onde o ranking dos modelos com menores valores de RMSE são CLSM, Noah-MP, GLDAS e IBIS.

As regiões que apresentaram melhor desempenho foram a região NE e AM. Em relação à estação do ano, observamos que a estação com menor valor de RMSE é a verão (NE - CLSM), seguida do outono (AM - CLSM), o inverno (NO - CLSM) e por último a o primavera (AM - CLSM).

A Figura 4.9 apresenta os resultados obtidos a partir do cálculo do RMSE para as rodadas dos modelos utilizando as forçantes GDAS e MERGE para os três modelos (Noah-MP, CLSM e IBIS) e também em relação à base de referência GLDAS.

Figura 4.9 - RMSE dos dados obtidos pelos três modelos, em relação aos dados do ERA5, utilizando as três forçantes meteorológicas.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,31	0,30	0,30	0,30	0,30	0,29	0,30	0,31	0,31	0,29	0,29	0,29	0,29	0,29	0,29	0,29	0,30	0,29	0,29	0,29
CLSM	0,07	0,08	0,08	0,08	0,07	0,08	0,06	0,06	0,07	0,07	0,09	0,08	0,09	0,09	0,08	0,10	0,10	0,09	0,09	0,09
IBIS	0,48	0,49	0,49	0,50	0,51	0,52	0,52	0,53	0,53	0,53	0,54	0,55	0,54	0,54	0,51	0,44	0,44	0,46	0,46	0,46
GLDAS	0,33	0,34	0,33	0,33	0,32	0,33	0,33	0,33	0,33	0,33	0,33	0,32	0,32	0,33	0,32	0,31	0,32	0,31	0,31	0,31

Fonte:Produção do autor.

Analisando agora a estatística RMSE, iremos avaliar o desempenho dos modelos quanto às estações do ano e regiões estudadas. Para as estações verão, outono, inverno e primavera, todas as regiões (NE, NO, AM, SU e PA) têm um ranking com os modelos que apresentam menor RMSE, que são CLSM, Noah-MP, GLDAS e IBIS.

Em relação a figura acima, podemos perceber que as regiões que apresentaram melhor desempenho foi a região AM. Quanto às estações do ano, o outono (AM - CLSM) foi a estação que apresentou menor valor do RMSE, seguido pelo verão (PA - CLSM), inverno (NO - CLSM) e primavera (AM - CLSM).

Comparando os dados das Figura 4.8 e Figura 4.9, notamos que para ambas figuras o CLSM foi o modelo que apresentou melhor desempenho e o IBIS o menor desempenho. Em relação a cada modelo, temos que os dados do RMSE do Noah-MP que apresentam menores valores de RMSE, ou seja, mais similaridade com os dados do ERA5 foram as rodadas que não consideraram os dados do CERES. Para o CLSM, os menores valores de RMSE foram encontrados nas rodadas onde o CERES foi

considerado. Para o IBIS, nas estações verão, outono e inverno, os valores do RMSE foram menores quando não foram considerados os dados do CERES, já na primavera, os valores menores de RMSE se encontraram nas rodadas onde o CERES foi considerado.

4.2.2.2 ESA-CCI

A Figura 4.10 0 apresenta os valores obtidos pelo RMSE entre os dados do ESA-CCI (referência) com os modelos do presente estudo com as forçantes GDAS e MERGE.

Figura 4.10 - RMSE dos dados obtidos pelos três modelos, em relação aos dados do ESA-CCI, utilizando as forçantes meteorológicas GDAS e MERGE.

	Verão					Outono					Inverno					Primavera					
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	
Noah-MP	0,06	0,05	0,05	0,05	0,05	0,05	0,05	0,06	0,06	0,06	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04
CLSM	0,33	0,34	0,34	0,34	0,33	0,35	0,35	0,33	0,33	0,34	0,34	0,34	0,35	0,35	0,35	0,35	0,36	0,35	0,35	0,35	0,35
IBIS	0,17	0,19	0,17	0,18	0,20	0,22	0,23	0,24	0,25	0,24	0,24	0,25	0,25	0,20	0,21	0,22	0,21	0,24	0,24	0,24	0,23
GLDAS	0,08	0,08	0,08	0,09	0,09	0,09	0,08	0,09	0,09	0,08	0,08	0,08	0,08	0,08	0,07	0,07	0,07	0,07	0,07	0,07	0,07

Fonte:Produção do autor.

Analisando o desempenho dos modelos em relação às regiões do estudo e às estações, observa-se que para todas as estações do ano e todas as regiões possuem a mesma configuração das performances dos modelos, ou seja, o Noah-MP possui o menor valor do RMSE, seguido pelo GLDAS, IBIS e CLSM. Logo, o CLSM apresentou o pior desempenho dentre todos os modelos utilizados, novamente, e o Noah-MP foi considerado o melhor modelo.

Sobre o desempenho das regiões do estudo, a região NE é a região que apresentou mais vezes os menores valores para RMSE. Analisando as estações do ano, temos que a primavera (NE - Noah-MP) foi a estação que apresentou menor valor de RMSE de toda a tabela, seguido pela estação inverno (NO e AM - Noah-MP), verão (SU - Noah-MP) e outono (NE - Noah-MP).

A Figura 4.11 apresenta os valores obtidos do RMSE entre os modelos do estudo e o dado de referência ESA-CCI utilizando as forçantes GDAS, MERGE e CERES.

Figura 4.11 - RMSE dos dados obtidos pelos três modelos, em relação aos dados do ESA-CCI, utilizando as três forçantes meteorológicas.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,06	0,05	0,06	0,05	0,06	0,05	0,06	0,07	0,07	0,06	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05
CLSM	0,33	0,33	0,33	0,33	0,32	0,33	0,32	0,29	0,30	0,30	0,33	0,33	0,34	0,35	0,34	0,34	0,35	0,34	0,34	0,34
IBIS	0,24	0,24	0,25	0,26	0,27	0,27	0,27	0,29	0,29	0,28	0,30	0,31	0,30	0,29	0,26	0,21	0,21	0,23	0,23	0,23
GLDAS	0,08	0,08	0,08	0,09	0,09	0,09	0,08	0,09	0,09	0,08	0,08	0,08	0,08	0,07	0,07	0,07	0,07	0,07	0,07	

Fonte:Produção do autor.

Analisando, primeiramente, o desempenho dos modelos quanto às regiões e estações do ano, temos que para todas as estações do ano e todas as regiões possuem a mesma configuração das performances dos modelos, ou seja, o Noah-MP possui o menor valor do RMSE, logo, o melhor desempenho, seguido pelo GLDAS, IBIS e CLSM. Nota-se que aqui, o CLSM apresentou o pior desempenho dentre todos os modelos utilizados, e o Noah-MP foi considerado o melhor modelo.

Em relação à região que apresenta melhor desempenho em todas as estações do ano, é a região AM. Sobre as estações do ano com melhores desempenhos, encontramos os menores valores de RMSE na estação inverno (NE, NO, SU e PA- Noah-MP), seguido pela estação primavera (NE e PA - Noah-MP), verão (NO - Noah-MP) e outono (NE - Noah-MP). Percebemos então que a região NE é a região que apresenta os valores mais próximos da referência (ESA-CCI).

Comparando os dados apresentados na [Figura 4.10](#) e [Figura 4.11](#) notou-se que para o Noah-MP, os valores de RMSE foram menores nas rodadas que o CERES não foi considerado, já para o CLSM, os menores valores de RMSE se encontram nas rodadas onde os dados do CERES são consideradas. Para o IBIS, exceto na primavera, os valores de RMSE são menores quando o CERES não é considerado nas rodadas.

4.2.2.3 GLDAS

A [Figura 4.12](#) representa os resultados obtidos do cálculo do RMSE entre os dados dos modelos e o dado de referência GLDAS considerando as forçantes meteorológicas GDAS e MERGE

Figura 4.12 - RMSE dos dados obtidos pelos três modelos, em relação aos dados do GLDAS, utilizando as duas forçantes meteorológicas (GDAS e MERGE).

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,05	0,05	0,04	0,05	0,05	0,06	0,05	0,05	0,05	0,05	0,06	0,05	0,05	0,06	0,06	0,04	0,05	0,05	0,04	0,04
CLSM	0,41	0,41	0,41	0,41	0,41	0,42	0,42	0,40	0,41	0,41	0,41	0,41	0,41	0,42	0,41	0,41	0,42	0,41	0,41	0,41
IBIS	0,17	0,16	0,15	0,16	0,17	0,17	0,18	0,19	0,19	0,20	0,19	0,20	0,20	0,16	0,18	0,18	0,17	0,20	0,20	0,19

Fonte:Produção do autor.

Analisando o desempenho dos modelos meteorológicos em relação às regiões e às estações do ano, observa-se que para todas as estações do ano e regiões de estudo, o ranking dos modelos ficou Noah-MP, IBIS e CLSM. Não houve uma região em específico que se destacou por apresentar os menores valores de RMSE. Em termos de estações do ano, temos que a primavera (SU - Noah-MP) apresentou o menor valor de erro de toda a tabela, seguida pela estação verão (AM - Noah-MP), outono (SU - Noah-MP) e inverno (NO - Noah-MP).

Na Figura 4.13 estão os dados da estatística RMSE dos dados dos modelos utilizados neste trabalho com os dados de referência do GLDAS utilizando apenas as três forçantes, ou seja, considerando o CERES nas rodadas dos modelos.

Figura 4.13 - RMSE dos dados obtido pelos três modelos, em relação aos dados do GLDAS, utilizando as três forçantes meteorológicas.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,04	0,04	0,04	0,04	0,04	0,05	0,05	0,04	0,04	0,05	0,05	0,04	0,04	0,04	0,04	0,03	0,03	0,04	0,03	0,03
CLSM	0,40	0,41	0,40	0,40	0,39	0,40	0,39	0,36	0,37	0,37	0,41	0,40	0,41	0,41	0,40	0,41	0,41	0,40	0,40	0,40
IBIS	0,18	0,19	0,20	0,21	0,22	0,22	0,22	0,23	0,23	0,24	0,25	0,26	0,25	0,24	0,21	0,17	0,16	0,19	0,20	0,19

Fonte:Produção do autor.

A primeira análise a ser feita é em relação ao desempenho dos modelos perante ao dado de referência focado nas regiões de estudo e nas estações do ano. Para todas as estações do ano e regiões, temos que o ranking dos melhores modelos são: Noah-MP,

IBIS e CLSM.

Analisando as regiões, não houve uma região em específico que se destacou por apresentar os menores valores de RMSE. Observando as estações do ano, podemos ver que a primavera (SU - Noah-MP) foi a estação que teve o menor RMSE, seguido pela estação verão (AM e PA - Noah-MP), inverno (NO - Noah-MP) e outono (AM - Noah-MP).

Comparando as Figura 4.12 e Figura 4.13, é possível perceber que os dados obtidos com a forçante de radiação (Figura 4.13) possuem erros menores do que quando a forçante é desconsiderada (Figura 4.12) para os modelos Noah-MP e CLSM. O modelo IBIS, exceto na primavera, quando desconsideram os dados do CERES, possuem um valor de RMSE menor, na primavera ocorre o contrário, e os dados com o CERES são menores.

4.2.3 MBE

4.2.3.1 ERA5

Será analisado neste momento outra estatística, o MBE. Essa estatística é capaz de mensurar o quanto uma variável está sendo subestimada ($MBE < 0$) ou superestimada ($MBE > 0$), o valor ideal para essa estatística é 0.

A Figura 4.14 apresenta os resultados obtidos do MBE para as rodadas dos modelos com os dados de referência do ERA5, quando os modelos não consideram os dados do CERES em suas rodadas.

Figura 4.14 - MBE dos dados obtidos pelos três modelos, em relação aos dados do ERA5, utilizando as forçantes meteorológicas GDAS e MERGE.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,30	0,29	0,29	0,28	0,28	0,27	0,28	0,29	0,29	0,28	0,27	0,27	0,27	0,27	0,27	0,27	0,28	0,27	0,27	0,27
CLSM	0,07	0,07	0,08	0,08	0,08	0,09	0,08	0,07	0,08	0,08	0,08	0,08	0,09	0,09	0,09	0,10	0,10	0,09	0,09	0,10
IBIS	0,38	0,39	0,37	0,39	0,40	0,45	0,46	0,46	0,47	0,48	0,47	0,48	0,48	0,43	0,45	0,44	0,44	0,46	0,46	0,46
GLDAS	0,33	0,33	0,33	0,33	0,32	0,33	0,33	0,32	0,33	0,32	0,32	0,32	0,31	0,32	0,32	0,31	0,31	0,31	0,30	0,31

Fonte:Produção do autor.

Na Figura 4.14 é possível observar que, em todas as estações do ano e regiões de

estudo, o CLSM é o modelo que apresenta menor erro, seguido pelo Noah-MP, GLDAS e IBIS.

Em termos de região que apresentou melhor desempenho, temos que a região AM apresenta a maior quantidade de valores em azul (menores erros). Em termos de estações do ano, o verão (NE - CLSM) e o outono (AM - CLSM) foram as estações que apresentaram o menor valor de erro, seguido pelo inverno (NO - CLSM), primavera (AM e SU - CLSM).

A Figura 4.15 apresenta os resultados obtidos do MBE quando os modelos meteorológicos foram rodados considerando a radiação do CERES.

Figura 4.15 - MBE dos dados obtidos pelos três modelos, em relação aos dados do ERA5, utilizando as três forçantes meteorológicas.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,31	0,30	0,30	0,29	0,29	0,29	0,30	0,30	0,30	0,29	0,28	0,28	0,29	0,29	0,28	0,29	0,29	0,28	0,29	0,29
CLSM	0,07	0,07	0,07	0,07	0,06	0,06	0,05	0,03	0,04	0,03	0,08	0,08	0,08	0,08	0,08	0,09	0,09	0,08	0,08	0,09
IBIS	0,47	0,48	0,48	0,49	0,50	0,51	0,51	0,52	0,52	0,52	0,54	0,54	0,54	0,53	0,50	0,43	0,43	0,45	0,45	0,45
GLDAS	0,33	0,33	0,33	0,33	0,32	0,33	0,33	0,32	0,33	0,32	0,32	0,32	0,31	0,32	0,32	0,31	0,31	0,31	0,30	0,31

Fonte:Produção do autor.

A primeira análise consiste em avaliar o desempenho dos modelos em questão para cada região e estação do ano. É possível observar que em todas as estações do ano, e em todas as regiões, o modelo CLSM apresentou melhor desempenho, seguido pelo Noah-MP, GLDAS e IBIS.

Em termos das regiões que apresentaram melhor desempenho, estão as regiões NE, AM e PA. Sobre as estações do ano, temos que o outono (AM - CLSM) apresenta o menor erro da tabela, seguido pelo verão (PA - CLSM), inverno (NO-CLSM) e primavera (AM - CLSM).

Em termos de comparação entre as rodadas do modelo utilizando os dados do CERES e sem utilizar os dados do CERES, temos que o Noah-MP, os menores erros correspondem aos dados sem a utilização da forçante CERES, já para o CLSM, os resultados são melhores quando o CERES é incluído na rodada dos modelos, para

o IBIS, exceto na primavera, os valores de MBE são menores quando desconsidera os dados do CERES.

4.2.3.2 ESA-CCI

Nas Figura 4.16 e Figura 4.17 apresentam o cálculo do MBE dos modelos em relação ao dado de satélite do ESA-CCI.

Figura 4.16 - MBE dos dados obtidos pelos três modelos, em relação aos dados do ESA-CCI, utilizando as duas forçantes meteorológicas (GDAS e MERGE).

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,04	0,03	0,03	0,03	0,03	0,01	0,02	0,03	0,04	0,02	0,02	0,02	0,02	0,01	0,03	0,03	0,02	0,02	0,02	
CLSM	0,33	0,33	0,33	0,33	0,33	0,34	0,34	0,32	0,33	0,34	0,33	0,33	0,34	0,35	0,34	0,35	0,35	0,34	0,34	0,34
IBIS	0,12	0,13	0,11	0,13	0,15	0,19	0,19	0,21	0,21	0,22	0,22	0,23	0,23	0,18	0,19	0,20	0,19	0,21	0,21	0,21
GLDAS	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,06	0,07	0,06	0,07	0,06	0,06	0,06	0,06	0,06	0,05	0,06

Fonte:Produção do autor.

Para todas as estações do ano e para todas as regiões de estudo, o ranking dos modelos é Noah-MP. GLDAS, IBIS e CLSM, ou seja, o Noah-MP apresenta melhor performance, enquanto que o CLSM apresenta os maiores valores de MBE da tabela.

Em relação ao desempenho das regiões de estudo, a região PA foi a que apresentou maior quantidade de valores azuis, que representa os menores erros. Em relação ao desempenho das estações do ano, temos que a estação que apresentou menor valor de MBE foi o outono (PA - Noah-MP), seguido pelo inverno (PA - Noah-MP), verão (SU - Noah-MP) e primavera (AM, SU e PA - Noah-MP). Concluimos nesta análise que o modelo Noah-MP apresentou maior similaridade com os dados de referência do ESA-CCI.

A Figura 4.17 a seguir, mostra os resultados do cálculo do MBE dos modelos com a utilização da forçante de radiação do CERES.

Figura 4.17 - MBE dos dados obtidos pelos três modelos, em relação aos dados do ESA-CCI, utilizando as três forçantes meteorológicas.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,05	0,04	0,04	0,04	0,04	0,03	0,04	0,05	0,05	0,03	0,03	0,03	0,04	0,03	0,03	0,04	0,04	0,04	0,04	0,04
CLSM	0,32	0,33	0,33	0,33	0,31	0,32	0,31	0,28	0,29	0,30	0,33	0,33	0,33	0,34	0,34	0,34	0,34	0,33	0,33	0,34
IBIS	0,21	0,22	0,23	0,24	0,25	0,25	0,25	0,27	0,26	0,26	0,29	0,29	0,29	0,28	0,24	0,19	0,18	0,20	0,20	0,20
GLDAS	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,07	0,06	0,07	0,06	0,07	0,06	0,06	0,06	0,06	0,06	0,05	0,06

Fonte:Produção do autor.

Para todas as estações do ano e para todas as regiões de estudo, o ranking dos modelos é Noah-MP, GLDAS, IBIS e CLSM, ou seja, o Noah-MP apresenta melhor performance, enquanto que o CLSM apresenta os maiores valores de MBE da tabela. Quanto ao desempenho das regiões, a região PA é a que apresentou melhores valores. Em relação à estação do ano, temos que o menor valor do MBE está presente na estação outono (PA - Noah-MP), seguido pelo inverno (PA - Noah-MP), verão (SU - Noah-MP) e primavera (AM, SU e PA - Noah-MP).

Em termos de comparação do desempenho dos modelos com e sem a adição do CERES, temos que para o modelo Noah-MP, as rodadas sem a adição do CERES resulta em erros menores; para o CLSM é o contrário, ou seja, as rodadas com a adição do CERES resultam em erros menores. Já para o IBIS, exceto na primavera, os valores dos erros são menores quando o CERES é desconsiderado.

4.2.3.3 GLDAS

A Figura 4.18 mostra os resultados do MBE para as rodadas dos modelos sem a forçante CERES comprando com os dados da referência GLDAS.

Figura 4.18 - MBE dos dados obtidos pelos três modelos, em relação aos dados do GLDAS, utilizando as duas forçantes meteorológicas (GDAS e MERGE).

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,03	0,04	0,04	0,04	0,04	0,05	0,04	0,04	0,04	0,05	0,05	0,04	0,04	0,05	0,05	0,04	0,04	0,04	0,03	0,04
CLSM	0,40	0,41	0,40	0,40	0,40	0,41	0,41	0,39	0,40	0,40	0,41	0,40	0,40	0,41	0,40	0,41	0,41	0,40	0,40	0,40
IBIS	0,05	0,06	0,04	0,06	0,08	0,12	0,13	0,14	0,14	0,15	0,15	0,16	0,16	0,11	0,13	0,14	0,13	0,15	0,15	0,15

Fonte:Produção do autor.

Analisando as estações do ano e regiões de interesse, o ranking da Figura 4.18 é composto pelo Noah-MP, que apresentou a melhor performance, seguido do IBIS e CLSM. Em termos de regiões, a que apresentou melhor desempenho foi a região SU. Em relação às estações do ano, o menor valor de MBE foi encontrado no verão (NE - Noah-MP), seguido pela primavera (SU - Noah-MP), outono (SU - Noah-MP) e inverno (AM - Noah-MP).

Na Figura 4.19 apresenta os valores obtidos do MBE dos modelos utilizando somente as forçantes GDAS, MERGE e CERES.

Figura 4.19 - MBE dos dados obtidos pelos três modelos, em relação aos dados do GLDAS, utilizando as três forçantes meteorológicas.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,02	0,03	0,03	0,03	0,03	0,04	0,03	0,02	0,03	0,04	0,04	0,03	0,03	0,03	0,03	0,02	0,02	0,02	0,02	0,02
CLSM	0,39	0,40	0,40	0,40	0,38	0,39	0,38	0,35	0,36	0,36	0,40	0,39	0,40	0,41	0,40	0,40	0,40	0,39	0,39	0,39
IBIS	0,14	0,15	0,16	0,17	0,18	0,18	0,18	0,20	0,19	0,20	0,22	0,23	0,22	0,21	0,18	0,13	0,12	0,14	0,15	0,14

Fonte:Produção do autor.

Nota-se que para todas as estações do ano, e todas as regiões de estudo, o modelo Noah-MP apresenta melhor desempenho quando comparado com o dado de referência (GLDAS), apresentando os menores erros da Figura 4.19, seguido pelo IBIS e CLSM. Vemos que assim como as outras estatísticas com o GLDAS, o ranking dos modelos é o mesmo, onde o Noah-MP apresenta melhor performance, e o CLSM a

pior.

Em termos de região que apresenta maiores quantidades de valores azuis (menores erros), temos a região AM. Em relação à estação do ano, a estação que apresenta o menor erro é a primavera (PA - Noah-MP), seguido pelo verão (NE - Noah-MP), outono (AM- Noah-MP) e inverno (AM - Noah-MP).

Comparando os resultados das estatísticas da [Figura 4.18](#) e [Figura 4.19](#), os modelos Noah-MP e CLSM apresentaram melhor performance quando considerados os dados do CERES na rodada do modelo, apresentando valores de erros menores de quando comparado com as rodadas que não utilizaram esses dados. No entanto, o IBIS apresenta melhoria nas suas simulações quando não considera os dados do CERES em suas rodadas, exceto para a primavera.

Observa-se que para todos os valores de MBE obtidos nas análises mostradas anteriormente, todos os modelos, para todas as estações, e para todas as bases de dados de referência, houve superestimação da variável umidade do solo, em nenhum caso houve subestimação dessa variável.

4.2.4 Desvio padrão

Nessa sessão será discutido o desvio padrão dos dados dos modelos meteorológicos utilizados neste trabalho, Noah-MP, CLSM, IBIS e GLDAS. As figuras a seguir contemplam o desvio padrão para cada modelo, cada estação do ano e região de estudo. A [Figura 4.20](#) apresenta o desvio padrão dos modelos utilizando as duas forçantes (GDAS e MERGE), e a [Figura 4.21](#) apresenta o desvio padrão para os modelos onde a forçante CERES foi considerada.

Figura 4.20 - Desvio padrão dos modelos (Noah-MP, CLSM, IBIS e GLDAS) utilizando as duas forçantes meteorológicas GDAS e MERGE.

	Verão					Outono					Inverno					Primavera					
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	
Noah-MP	0,11	0,12	0,13	0,12	0,12	0,11	0,12	0,13	0,13	0,12	0,12	0,13	0,13	0,11	0,12	0,12	0,12	0,12	0,12	0,12	0,12
CLSM	0,06	0,06	0,06	0,06	0,06	0,05	0,06	0,06	0,06	0,06	0,05	0,06	0,06	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05
IBIS	0,14	0,14	0,14	0,15	0,15	0,14	0,14	0,14	0,14	0,14	0,13	0,13	0,14	0,14	0,14	0,14	0,14	0,14	0,14	0,14	0,14
GLDAS	0,13	0,12	0,13	0,13	0,14	0,13	0,13	0,14	0,14	0,13	0,13	0,14	0,14	0,13	0,12	0,13	0,13	0,13	0,13	0,13	0,14

Fonte:Produção do autor.

Na [Figura 4.20](#) acima apresenta o desvio padrão dos dados utilizando apenas as forçantes GDAS e MERGE. Observa-se que o CLSM segue sendo o modelo que menos apresentou desvio em relação à sua média, seguido pelo Noah-MP, GLDAS e IBIS, onde o IBIS segue sendo o modelo que apresentou maior desvio da média.

Figura 4.21 - Desvio Padrão dos modelos (Noah-MP, CLSM, IBIS e GLDAS) utilizando as três forçantes meteorológicas.

	Verão					Outono					Inverno					Primavera				
	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA	NE	NO	AM	SU	PA
Noah-MP	0,12	0,12	0,12	0,12	0,13	0,12	0,12	0,13	0,13	0,12	0,12	0,13	0,13	0,11	0,12	0,12	0,12	0,12	0,12	0,13
CLSM	0,06	0,06	0,06	0,06	0,06	0,06	0,06	0,07	0,07	0,07	0,06	0,06	0,06	0,05	0,05	0,06	0,06	0,06	0,05	0,06
IBIS	0,15	0,15	0,14	0,14	0,14	0,13	0,13	0,13	0,13	0,13	0,12	0,12	0,12	0,12	0,13	0,14	0,14	0,14	0,14	0,14
GLDAS	0,13	0,12	0,13	0,13	0,14	0,13	0,13	0,14	0,14	0,13	0,13	0,14	0,14	0,13	0,12	0,13	0,13	0,13	0,13	0,14

Fonte:Produção do autor.

Analisando a [Figura 4.21](#) percebemos que o CLSM é o modelo que apresenta menor desvio padrão, ou seja, onde os dados do modelo menos se distancia da própria média, e esse comportamento é visto para todas as regiões e em todas as estações do ano. Em seguida ao CLSM, o modelo que menos se desvia de sua própria média é o Noah-MP, seguido pelo GLDAS, e por último o IBIS, que apresenta maiores desvios da média de seus dados.

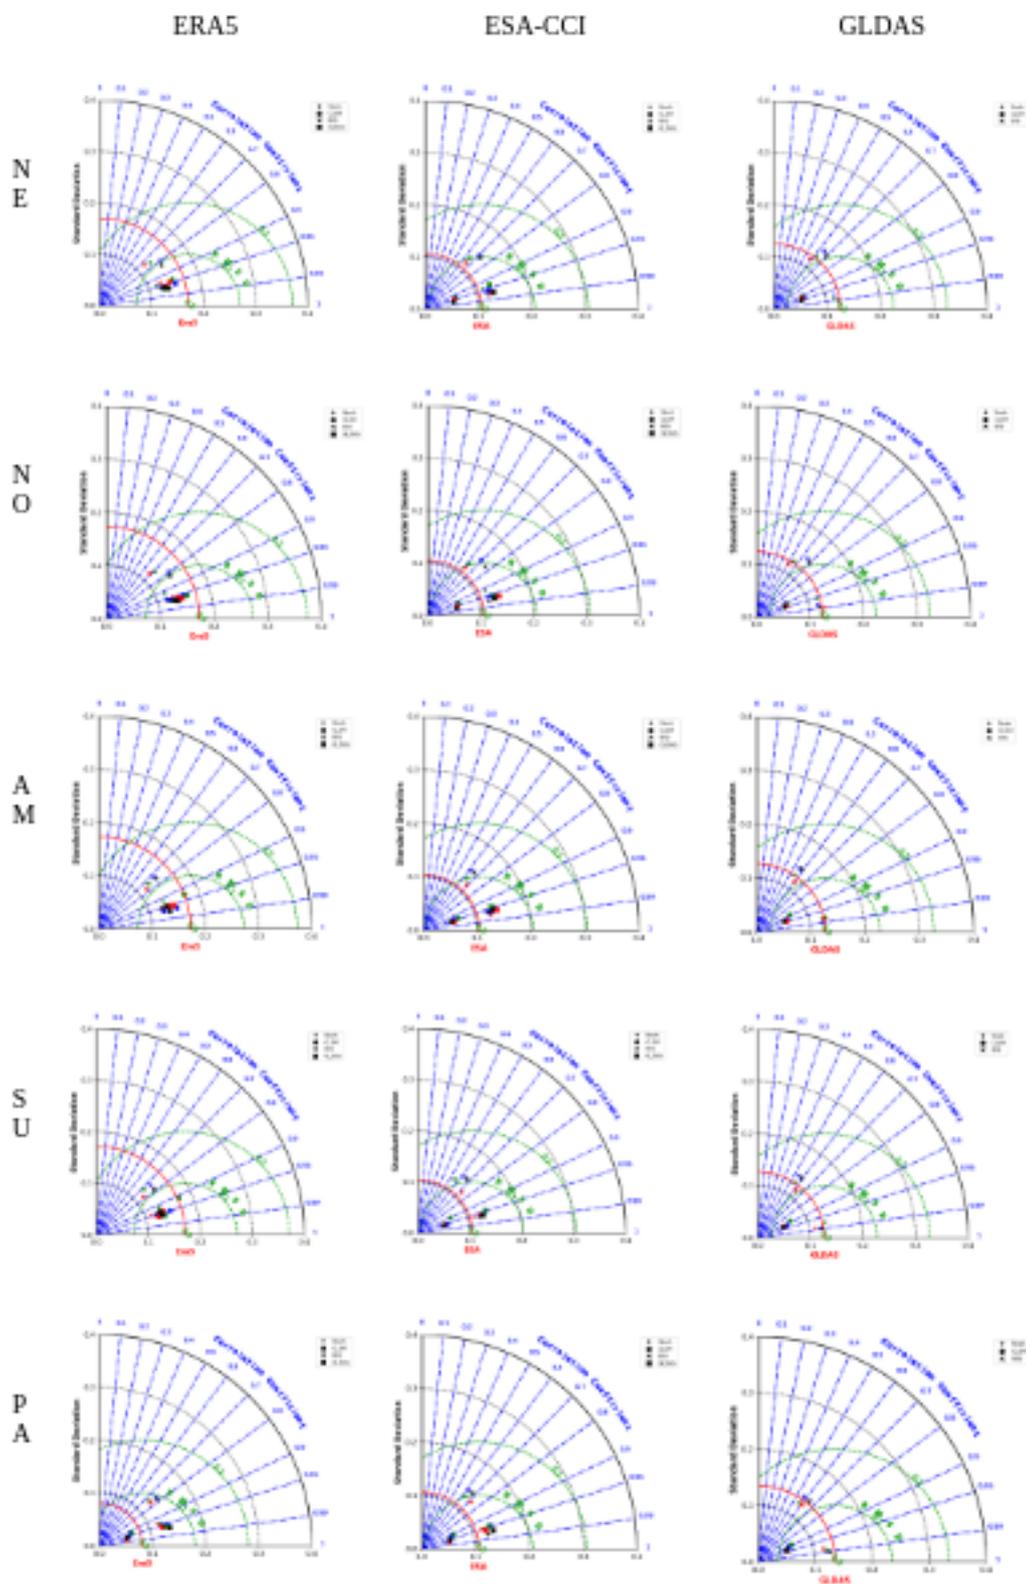
4.3 Diagrama de Taylor

4.3.1 GDAS, MERGE e CERES

Na [Figura 4.22](#) abaixo estão representados os diagramas de Taylor para cada modelo escolhido no trabalho (Noah-MP, CLSM, IBIS e GLDAS). Cada linha representa o diagrama para uma região do estudo, e cada coluna representa a referência da qual o diagrama foi feito. As cores do diagrama representam as estações do ano, e as formas representam os modelos (cruz é o Noah-MP; bola é o CLSM; xis é o IBIS e o quadrado é o GLDAS). Para as cores, temos: verão (azul), outono (verde) inverno (vermelho) e primavera(preto).

O diagrama de Taylor foi colocado no trabalho como forma de visualizar melhor os dados obtidos nas tabelas discutidas anteriormente. Sendo assim, ele apresenta os valores obtidos pela Correlação de Pearson, o desvio padrão e o RMSE.

Figura 4.22 - Diagrama de Taylor para os modelos utilizando as forçantes GDAS, MERGE e CERES.



Fonte:Produção do autor.

Observa-se que na região NE, o IBIS apresenta os maiores valores de erro, e menores valores de correlação, enquanto que o CLSM, Noah-MP e GLDAS apresentam desempenhos semelhantes quando comparado com o ERA5 e o ESA-CCI, ou seja, com elevados valores de correlação e baixos valores de erros ($< 0,1$) para todas as estações do ano, e baixo desvio padrão também. Quando comparado com o GLDAS é possível observar que o Noah-MP apresenta correlações ligeiramente maiores que o CLSM, diferença essa que não é tão significativa no ERA5 e ESA-CCI. Observa-se que o desvio padrão do CLSM é o menor dos modelos, como já visto nas tabelas discutidas acima.

Para a região NO, observa-se comportamento semelhante à região NE, ou seja, no ERA5 o IBIS apresenta menor performance, e o Noah-MP, CLSM e GLDAS apresentam valores semelhantes, altos para correlação e baixos para o RMSE; para a comparação do ESA-CCI, nota-se uma variação maior dos dados do Noah-MP para o outono e primavera para a correlação e RMSE, no entanto, essa variação não é muito significativa.

Na região AM observa-se que para a comparação com o ERA5, o IBIS continua sendo o modelo que mais se afasta dos dados de referência, enquanto que os outros modelos apresentam correlações altas e erros baixos. Observa-se que o CLSM no outono, foi o valor que mais se distanciou dos dados do Noah-MP, GLDAS e CLSM para as outras estações do ano. Nota-se que, novamente, os três melhores modelos possuem valores semelhantes de correlação e erro. Para o dado de comparação ESA-CCI, nota-se comportamento semelhante do apresentado no ERA5, no entanto, percebe-se que os dados do desvio padrão são menores que para os outros modelos. Para a comparação do GLDAS, temos condições semelhantes ao ESA-CCI e ERA5, ou seja, a correlação do CLSM e Noah-MP são superiores ao do IBIS, no entanto, os valores para o Noah-MP são maiores que o apresentado pelo CLSM.

Observa-se que para a região SU, comparando com os dados do ERA5, os dados do CLSM, GLDAS e Noah-MP apresentam semelhanças quando o valor de correlação, RMSE e desvio padrão, apenas o verão do CLSM apresenta uma correlação significativamente menor que os demais modelos e estações. Nota-se também que o IBIS segue sendo o modelo que menos se aproximou da referência. Quanto à comparação com a base de dados do ESA-CCI, percebemos que o desvio padrão do CLSM é menor que os demais modelos, mas que a correlação do mesmo é semelhante ao GLDAS e Noah-MP, e o IBIS é o modelo que mais se distancia, tanto em termos de correlação, quanto do desvio padrão. Quanto à comparação do GLDAS, observa-se

que o Noah-MP é o modelo que mais se assemelha com os dados de referência, ou seja, apresenta maior correlação; o CLSM é o segundo melhor modelo e apresenta menor valor de desvio padrão, e o IBIS é o modelo que mais se afasta dos dados de referência (GLDAS).

Na região PA observa-se que para o ERA5, o CLSM e o Noah-MP são os modelos que apresentam maior correlação quando comparado com o IBIS, nota-se que o CLSM é o modelo que apresenta menor desvio padrão, e RMSE também. Para a comparação com o ESA-CCI, temos que o Noah-MP e o CLSM seguem sendo os melhores modelos, agora comparando com o ERA5, o CLSM segue sendo o modelo que apresenta o menor desvio padrão, e nota-se que o IBIS apresentou um aumento no RMSE quando comparado com os valores obtidos do RMSE com o ERA5. Para a comparação com o GLDAS, observa-se que o Noah-MP apresenta maiores valores de correlação, seguido do CLSM e por último, o IBIS. Nessa comparação percebe-se que houve um aumento dos valores do IBIS quanto ao RMSE quando comparado com o ERA5 e ESA-CCI, e que o CLSM segue sendo o modelo que apresenta menor desvio padrão dos seus dados.

4.3.2 GDAS e MERGE

A figura abaixo apresenta o diagrama de Taylor para os modelos utilizando a forçante GDAS e MERGE.

Observa-se que o desempenho dos modelos para a região NE, tanto para as comparações com o ERA5, ESA-CCI e GLDAS, são bem semelhantes ao apresentado na discussão acima considerando as três forçantes meteorológicas, isso porque, como visto nas tabelas apresentadas anteriormente, as diferenças entre os valores considerando ou não o CERES, não é muito significativo. Isso ocorre também com a região NO, onde a diferença mais significativa está no IBIS por apresentar uma variação maior dos valores de correlação e RMSE.

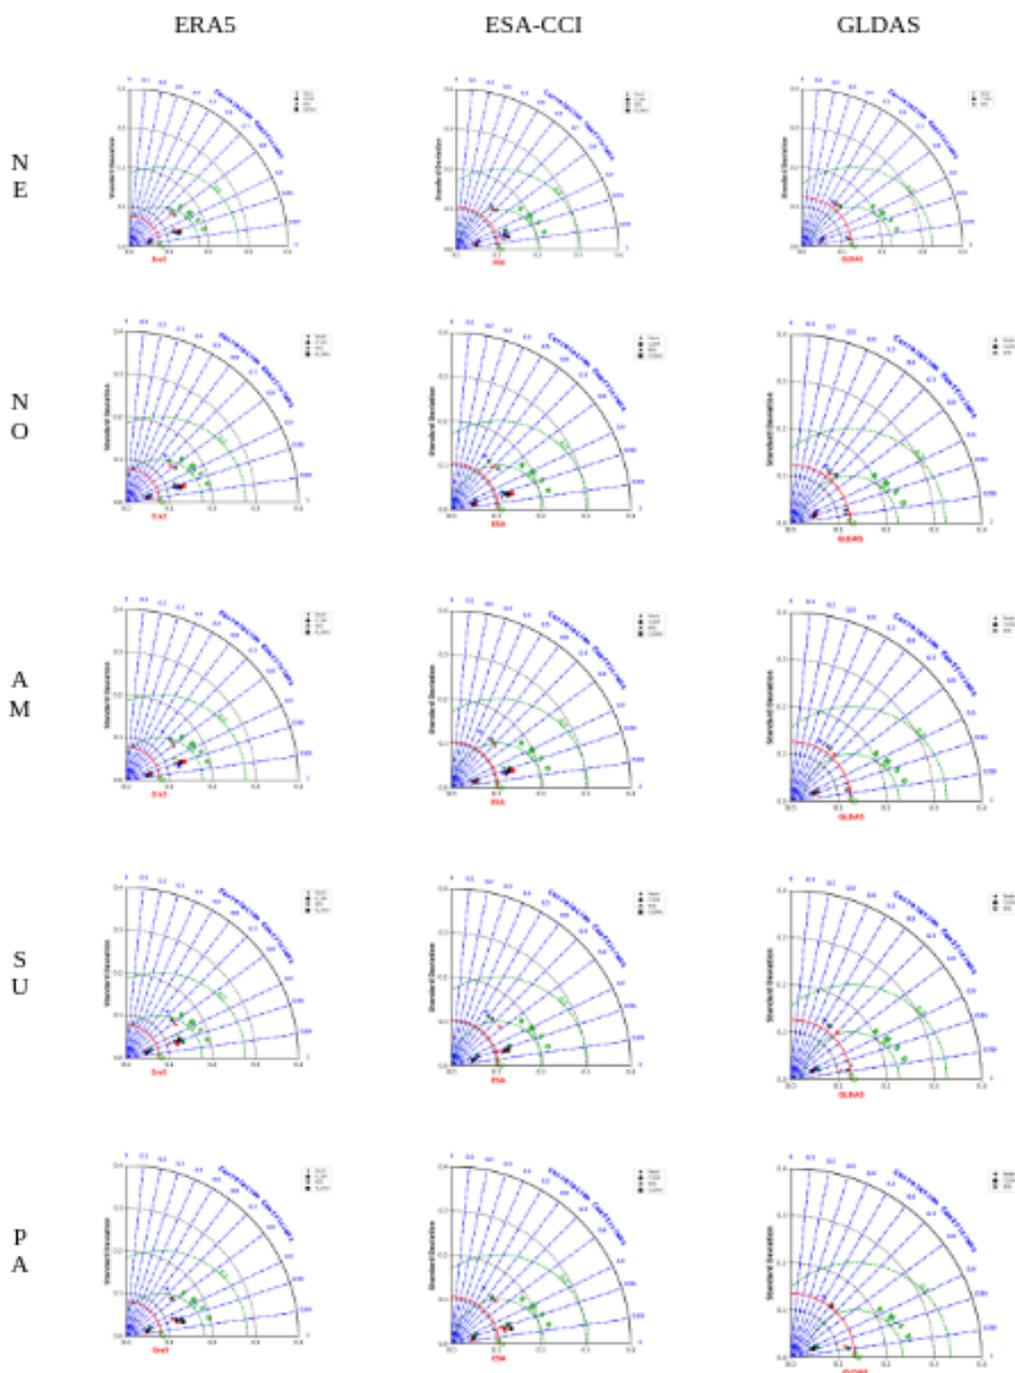
A dispersão dos valores do IBIS para a correlação e RMSE, aumenta na região AM, no entanto, os outros modelos seguem com valores semelhantes ao apresentado no AM quando considerado o CERES nas rodadas dos modelos.

Para a região SU, nota-se que a dispersão do IBIS diminuiu na comparação com os dados do ERA5, e permanece significativamente mais distantes na comparação com o ESA-CCI e GLDAS.

Para a região PA, nota-se que o IBIS novamente é o modelo que mais se distancia dos

dados de referência (ERA-5, ESA-CCI e GLDAS), enquanto que os demais modelos apresentam valores de correlação, RMSE e desvio padrão considerados muito bons, para todas as estações do ano.

Figura 4.23 - Diagrama de Taylor para os modelos utilizando as forçantes GDAS, MERGE e CERES.



Fonte:Produção do autor.

Devido ao tamanho das figuras apresentadas acima para o Diagrama de Taylor, foi

incluído no Apêndice A as figuras para cada diagrama de Taylor, ou seja, para cada dado de referência e cada região, assim como mostrado no compilado de figuras acima.

4.4 Estudos de caso de secas no Brasil

Nos últimos anos, foram observados diversos casos de secas no território brasileiro que afetaram diferentes regiões, como por exemplo o caso do Nordeste do Brasil durante 2012-2017; sudeste do Brasil em 2014-15; Amazônia em 2005, 2010 e 2016; Sul do Brasil em 2005 e 2012.

Para analisar o desempenho dos modelos do SALDAS (Noah-MP, CLSM e IBIS) em identificar secas superficiais, nesta sessão será avaliada algumas figuras dos percentis de umidade do solo obtidos pelos modelos do SALDAS em comparação com o SPI-1 obtido pelo CPTEC/INPE. Vale ressaltar que o SPI para caracterizar um evento de seca do CPTEC/INPE é baseado na metodologia utilizada no *National Integrated Drought Information System* dos Estados Unidos da América, que possui 5 classificações: seca fraca, moderada, severa, extrema e excepcional. E serão essas as classificações utilizadas no presente trabalho. É válido lembrar que as comparações serão feitas para a camada mais superficial dos modelos meteorológicos escolhidos.

Além disso, foram escolhidos eventos de secas específicos para serem analisados neste trabalho com intuito de deixar as análises mais objetivas. Sendo assim, serão apresentados nessa seção os casos de secas ocorridos na região Amazônica para os anos de 2005, 2010 e 2015, como também a seca histórica que ocorreu em São Paulo, no complexo de represas da Cantareira.

4.4.1 Região Amazônica

Há diversos casos de secas extremas registradas na região amazônica, como por exemplo em 2005, 2010 e 2015-2016. Algumas dessas secas ocorreram devido ao El Niño, com subsidência anômala em grande parte da Amazônia devido às anomalias quentes da temperatura da superfície do mar na região Pacífico equatorial como nos anos de El Niño de 2010 e 2015–2016, e também, devido a influência das águas superficiais quentes no Atlântico Norte tropical com ausência de El Niño, como em 2005 (JIMÉNEZ-MUÑOZ et al., 2016; MARENGO et al., 2018).

Explicada as causas das secas na região Amazônica para os anos de 2005, 2010, e 2015-2016, abaixo estão apresentados as figuras do SPI-1, juntamente com as figuras do percentil de umidade do solo dos modelos Noah-MP, CLSM e IBIS, com intuito de

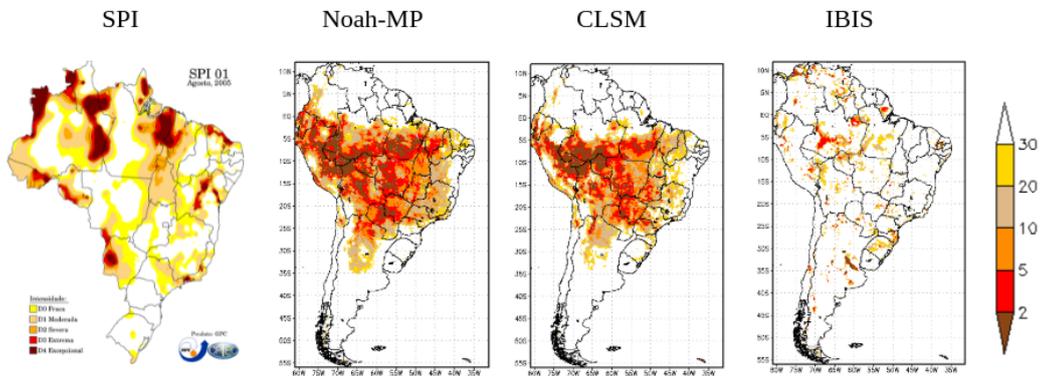
comparar e analisar o desempenho dos modelos utilizado no SALDAS em identificar a presença dessas secas. Foram separados por tópicos para melhor organização dos dados. Para a escolha das figuras, foram escolhidos os meses mais secos, ou seja, entre julho, agosto e setembro (SAATCHI et al., 2013) com o intuito de padronizar o mês escolhido para a análise das secas na Amazônia, foi escolhido o mês de agosto.

4.4.1.1 2005

É possível notar na Figura 4.24 abaixo que tanto o modelo Noah-MP, quanto o modelo CLSM conseguem identificar a seca que é mostrada no SPI-1, no entanto os modelos indica essa seca com maior abrangência, mostrando ela com mais severidade em diversas regiões onde o SPI-1 não identifica a seca, ou identifica com menor intensidade. Vale lembrar que a análise é feita para a região da Amazônia, logo, demais regiões não entram na análise.

De modo geral, os modelos Noah-MP e CLSM são capazes de identificar as secas, até as mais extremas, no entanto, superestimam essa seca, não conseguindo determinar os locais exatos que são vistos no SPI-1. O IBIS é o modelo que apresenta menor desempenho na identificação das secas mostradas no SPI-1, e como visto nas estatísticas discutidas anteriormente, também é o modelo que mais se distancia dos dados de referência usados no trabalho, ao contrário dos modelos Noah-MP e CLSM que apresentaram melhor desempenho dentre os três modelos.

Figura 4.24 - Análise da seca de 2005 na região Amazônica obtida pelo SPI-1, Noah-MP, CLSM e IBIS.



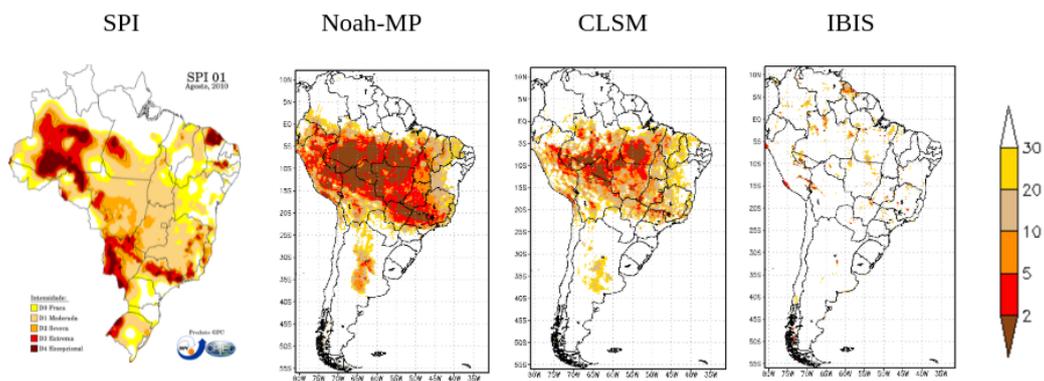
Fonte:Produção do autor.

4.4.1.2 2010

Na Figura A.30 abaixo é apresentada a seca de 2015 para a região Amazônica. Nota-se que o SPI-1 na região Amazônica apresenta seca extrema em grande parte da região, inclusive com a presença de seca excepcional também, o restante da região é composta por seca fraca e moderada, e apenas em poucos lugares o SPI-1 não identificou seca. Observa-se que o modelo Noah-MP apresenta extensas regiões com seca excepcional e extrema para a região de estudo, poucos são os locais onde apresentam apenas a seca severa, onde no SPI-1 é apontada como seca moderada. Já o CLSM mostra uma compatibilidade maior com as secas apresentadas no SPI-1, inclusive nas regiões de seca excepcional no Pará. Essa seca excepcional no Pará também é identificada no Noah-MP, no entanto, com uma abrangência maior que a observada no CLSM. Em relação ao modelo IBIS, novamente subestimou as secas na região Amazônica, não identificando praticamente nenhum ponto de seca na região do estudo.

Portanto, analisando visualmente os dados, o CLSM é o modelo que mais apresenta similaridade com os dados de seca observado pelo SPI-1 do CPTEC/INPE, enquanto que o Noah-MP mostra superestimação dessas secas e o IBIS subestimação.

Figura 4.25 - Análise da seca de 2010 na região Amazônica obtida pelo SPI-1, Noah-MP, CLSM e IBIS.



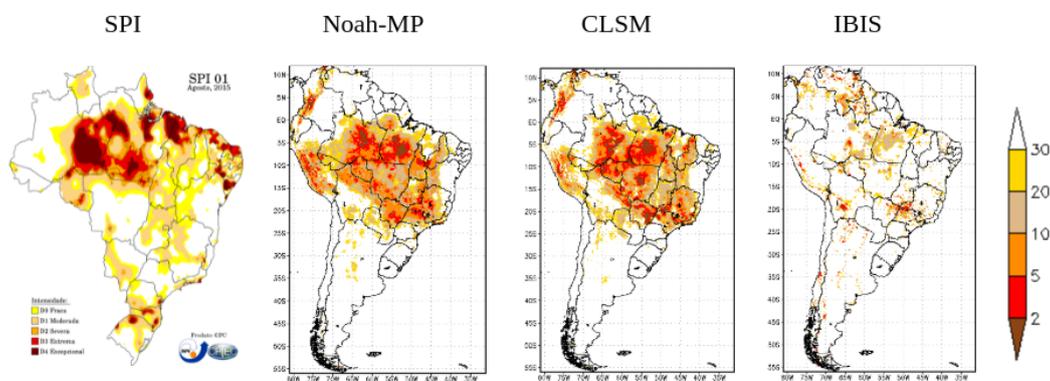
Fonte:Produção do autor.

4.4.1.3 2015

Na Figura 4.26 abaixo é apresentada a seca para a região Amazônica no ano de 2015, considerado o ano mais intenso de secas já registrado nessa região. Na seca apresentada pelo SPI-1 foi nota-se que no leste do Amazonas há a presença de seca extrema e excepcional, assim como em todo o estado do Pará; já a oeste do Amazonas, o SPI-1 não identificou presença de secas fortes, apenas pontos com seca fraca. Os modelos Noah-MP e CLSM apresentam secas em todo Amazonas, Pará e Tocantins, superestimando as secas neste período; há a presença de secas excepcionais em quase toda a extensão da região amazônica. Já o IBIS, consegue captar pequenas regiões de seca fracas e moderadas, e pequenos pontos de seca extrema, mais uma vez subestimando os dados de seca.

Portanto, nota-se que os modelos Noah-MP e CLSM superestimam os eventos de seca, no entanto, apresentam maior semelhança com os dados do SPI-1 quando comparado com o IBIS.

Figura 4.26 - Análise da seca de 2015 na região Amazônica obtida pelo SPI-1, Noah-MP, CLSM e IBIS.



Fonte:Produção do autor.

4.4.1.4 São Paulo - 2014

O sistema Cantareira, é considerado um dos maiores reservatórios de água doce da região Sudeste e, também, um dos maiores sistemas de abastecimento de água potável do mundo. É responsável pelo abastecimento hídrico de mais de 43 municípios

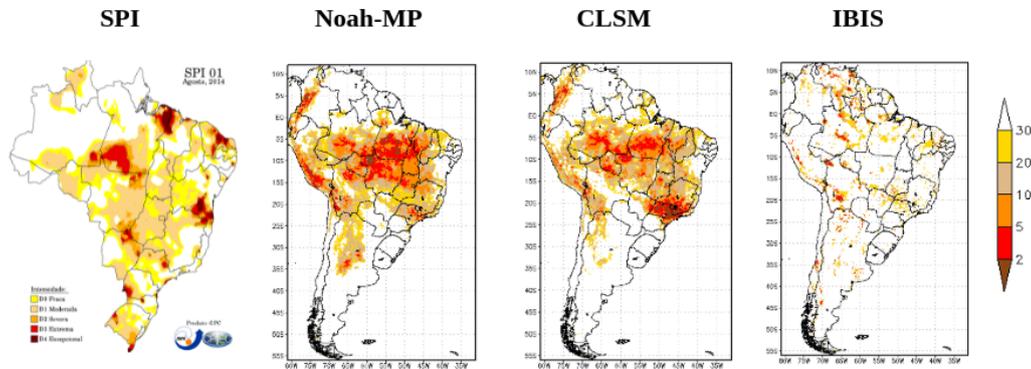
da região, incluindo a cidade de São Paulo, passou pela maior crise hídrica da sua história, e isso foi resultado do volume das chuvas muito inferiores à média histórica e das temperaturas máximas extremas. Portanto, a vazão dos rios que alimentam os reservatórios dos sistemas de abastecimento e das usinas hidrelétricas das regiões Sudeste e Centro-Oeste, de maior consumo de energia, atingiu a menor marca da história (MARENGO et al., 2015).

A crise hídrica iniciada em janeiro de 2014 teve sua causa principal determinada pela presença de um sistema de alta pressão anormalmente intenso e prolongado localizado sobre o Oceano Atlântico, cuja influência se estendeu sobre a Região Sudeste. Sistemas desse tipo são denominados normalmente como “bloqueios”. Já no ano de 2015, a atuação de um novo sistema de alta pressão, embora mais fraco e curto, não permitiu a recuperação da umidade do solo gerando um “círculo vicioso” no ciclo hidrológico (a falta de chuva gerou falta de umidade no solo, que provocou falta de chuva)(MARENGO et al., 2015).

Como discutido no trabalho de (MARENGO et al., 2015), a escassa umidade do solo prejudicou o fluxo de umidade para a atmosfera, provocando a diminuição das chuvas, o que, por sua vez, não permitiu o aumento da umidade no solo.

A Figura 4.27 abaixo mostram o percentil da umidade do solo, comparando com os dados do SPI disponibilizados pelo CPTEC/INPE. Foram utilizados o SPI-1 que representa a seca superficial, assim, é possível a comparação com os dados obtidos nos modelos utilizados neste trabalho. Foram escolhidos os meses de junho pois apresentou o mês de junho de 2014 pois apresentou os menores valores de precipitação segundo o trabalho de (MARENGO et al., 2015) para o período analisado.

Figura 4.27 - Análise da seca de 2014 no Sistema Cantareira (SP) obtida pelo SPI-1, Noah-MP, CLSM e IBIS.



Fonte:Produção do autor.

Podemos perceber pela [Figura 4.27](#) que no SPI-1 é identificada uma seca em toda a extensão do estado de SP, com a presença de seca excepcional em uma pequena região, e secas extremas em grande parte do estado. O CLSM é o modelo que apresenta maior região de seca excepcional, cobrindo quase toda a extensão de SP, apresentando também seca extrema no estado. Já o modelo Noah-MP, na maioria do estado há a presença de seca moderada, com pequenos focos de seca extrema, no entanto, não localizada exatamente na região indicada pelo SPI-1. Já o IBIS mostra pequenas regiões de SP com presença de seca moderada, e regiões que não é identificada a presença da seca em questão.

Portanto vemos que há uma subestimação do modelo CLSM e Noah-MP e, analisando visualmente, o modelo Noah-MP é o que mais se assemelha com os dados do SPI-1, devido ao CLSM apresentar seca excepcional em quase todo o território paulista. O IBIS, no entanto, novamente se mostra como o modelo que tem menor desempenho em identificar a seca que ocorreu em SP, e também a intensidade da mesma. No entanto, os três modelos apresentam capacidade para auxiliar na identificação das secas através da umidade do solo.

Analisando os estudos de casos apresentados acima podemos concluir que a diferença encontradas entre os diferentes modelos e em relação ao SPI pode estar associado com a forma que os modelos particioam a água e a energia em suas configurações. Sabemos que dependendo do particionamento configurado nos modelos, haverá mais

ou menos água disponível nas camadas do solo. Isso significa que devido às limitações das parametrizações e a forma com que os modelos particionam a água e a energia, acarretará em superestima ou subestimação da água na camada, o que influenciará na identificação de secas. Vale ressaltar que as especificações da partição de energia também são importante para contabilizar o calor sensível, latente e a evapotranspiração que são processos interligados aos processos hidrológicos, influenciando, assim, nos resultados obtidos das secas. Logo, é de suma importancia analisar a eficiencia dos modelos em descrever os processos de energia também.

5 CONCLUSÃO

Motivada pela necessidade de um melhor entendimento dos mecanismos que controlam a interação entre a umidade do solo e atmosfera, esta dissertação de mestrado teve como objetivo analisar o balanço de água e energia sobre a AS e seus consequentes impactos nas estimativas de curto prazo dos padrões de secas e precipitação, através dos modelos de superfície terrestre e das diferentes forçantes atmosféricas.

Primeiramente foi analisado o impacto da forçante CERES nas rodadas do modelo, onde observou que o CLSM é o modelo que apresenta maior diferença quando o modelo é rodado com e sem o CERES. Posteriormente, foi analisada através de estatísticas, a performance dos modelos comparando os dados de referência utilizados no estudo (ERA5, ESA-CCI e GLDAS).

Sobre a análise das secas obtidos pelo percentil de umidade do solo dos modelos meteorológicos e o SPI-1 do CPTEC/INPE, observou-se que o modelo Noah-MP e CLSM superestimam as secas, identificando regiões maiores e com secas mais intensas, enquanto que o IBIS subestima essas secas, não identificando-as. Dentre os modelos Noah-MP e CLSM, pela análise visual, notou-se que o CLSM apresenta dados mais semelhantes que os dados obtidos pelo SPI-1. Vale ressaltar que foi escolhido o SPI-1 pois os modelos meteorológicos são analisados no primeiro nível do solo.

A partir dos principais pontos discutidos do capítulo anterior e, considerando-se os objetivos deste trabalho, conclui-se que:

- (a) Ao analisar os padrões de US e sua relação com as forçantes atmosféricas (GDAS, MERGE e CERES) durante os últimos 20 anos sobre a AS utilizando as simulações multimodelos do South American Land Data Assimilation System (SALDAS), verifica-se que os diferentes modelos respondem de forma bem diversa à variações nos campos de radiação e precipitação. Isto se deve ao fato de que os modelos possuem diferentes parametrizações e foram calibrados de forma independente. Ainda assim verifica-se que, a utilização de bases de dados de forçantes atmosféricas derivadas de dados observados, como o caso do CERES (radiação por satélite) e do MERGE (precipitação combinada entre observações in situ e satélite) trazem um impacto positivo nas simulações numéricas sobre a América do Sul, no entanto, com relação ao CLSM, houve pouco impacto positivo na sua performance com a inclusão do CERES.

- (b) Ao avaliar a destreza das simulações do SALDAS durante o período de estudo com relação à referências de modelagem offline, modelagem acoplada e observação de satélite: GLDAS, Reanálise ERA-5 e ESA CCI respectivamente, verifica-se que os modelos numéricos NOAH, IBIS e CLSM (sendo os dois primeiros utilizados operacionalmente no CPTEC) apresentam uma boa performance. Em particular, quando comparados com outro sistema similar que no caso o GLDAS. Note-se que o IBIS por sua vez distancia-se um pouco mais em algumas regiões o que sugere um aumento nos seus ajustes sobre a América do Sul.
- (c) Ao analisar a destreza dos modelos de superfície buscando identificar os eventos de seca ocorridos durante este período, através de metodologia estatística com base nas simulações de conteúdo de água, verifica-se que esta metodologia pode ser empregada em monitores de seca que combinem estatísticas a partir de umidade do solo e SPI. Isso se dá devido à relativa boa destreza dos modelos em estimar os padrões de seca nos diversos eventos estudados neste trabalho, incluindo período, intensidade e extensão. Salientando que este estudo teve como foco somente os eventos de seca de curto prazo, associando SPI-1 com umidade do solo do nível superficial.

Em relação ao último item acima, no presente estudo foi utilizado apenas o SPI-1, no entanto, quando combinado com outros SPI's, como por exemplo o SPI-3 e SPI-6, pode ser realizado um estudo de secas através da US para a escala sazonal ou climática, além da escala de tempo. O estudo visou mostrar que os modelos de superfície permitem acompanhar a evolução da seca em camadas mais profundas, enquanto que a métrica utilizada no SPI (mesmo que seja usado o 3 e o 6) é capaz de representar uma variável geofísica que afeta apenas a superfície, que é a precipitação. Logo, o modelo permite olhar a dinâmica da seca em camadas mais profundas e identificar se ela está se iniciando ou persistindo.

5.1 Sugestões para trabalhos futuros

Para trabalhos futuros, recomenda-se conduzir estudos numéricos semelhantes mas considerando o impacto das características da superfície como heterogeneidade da vegetação e do solo. Também, reproduzir os resultados deste trabalho mas após calibração e ajustes nos modelos de superfície utilizados. Por fim, recomenda-se aprofundar estudos combinando estatísticas a partir da umidade do solo como percentil e métricas baseadas em precipitação como SPI/PDSI, incluindo camadas mais profundas de solo, com o objetivo de melhorar o monitoramento e estimativa de eventos

de seca sobre a América do Sul.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALLEY, W. M. The palmer drought severity index: limitations and assumptions. **Journal of Applied Meteorology and Climatology**, v. 23, n. 7, p. 1100–1109, 1984. 15
- ALVES, E. D. L.; VECCHIA, F. A. S. Análise de diferentes métodos de interpolação para a precipitação pluvial no estado de goiás. **Acta Scientiarum. Human and Social Sciences**, v. 33, n. 2, p. 193–197, 2011. 37, 38
- ANDERSON, M. C.; HAIN, C.; OTKIN, J.; ZHAN, X.; MO, K.; SVOBODA, M.; WARDLOW, B.; PIMSTEIN, A. An intercomparison of drought indicators based on thermal remote sensing and nldas-2 simulations with us drought monitor classifications. **Journal of Hydrometeorology**, v. 14, n. 4, p. 1035–1056, 2013. 2
- ARSENAULT, K. R.; NEARING, G. S.; WANG, S.; YATHEENDRADAS, S.; PETERS-LIDARD, C. D. Parameter sensitivity of the noah-mp land surface model with dynamic vegetation. **Journal of Hydrometeorology**, v. 19, n. 5, p. 815–830, 2018. 25, 26
- ASSOCIAÇÃO BRASILEIRA DE ÁGUAS SUBTERRÂNEAS (ABAS). Águas subterrâneas, o que são? 2021. Disponível em: <https://www.abas.org/aguas-subterraneas-o-que-sao/#:~:text=%C3%81gua%20subterr%C3%A2nea%20%C3%A9%20toda%20a,essencial%20na%20manuten%C3%A7%C3%A3o%20da%20umidade>. Acesso em: 23 mar. 2021. 8, 9
- BASARA, J. B.; CRAWFORD, K. C. Linear relationships between root-zone soil moisture and atmospheric processes in the planetary boundary layer. **Journal of Geophysical Research: Atmospheres**, v. 107, n. D15, p. ACL–10, 2002. 5
- BECHTOLD, M. et al. Peat-clsm: a specific treatment of peatland hydrology in the nasa catchment land surface model. **Journal of Advances in Modeling Earth Systems**, v. 11, n. 7, p. 2130–2162, 2019. 18
- BLAIN, G. C.; BRUNINI, O. Avaliação e adaptação do índice de severidade de seca de palmer (pdsi) e do índice padronizado de precipitação (spi) às condições climáticas do estado de São Paulo. **Bragantia**, v. 64, n. 4, p. 695–705, 2005. 14
- BLONQUIST-JUNIOR, J.; JONES, S. B.; ROBINSON, D. Standardizing characterization of electromagnetic water content sensors: Part 2. evaluation of seven sensing systems. **Vadose Zone Journal**, v. 4, n. 4, p. 1059–1069, 2005. 11

BORGHETTI, N. R. B.; BORGHETTI, J. R.; ROSA-FILHO, E. F. **Aquífero Guaraní: a verdadeira integração dos países do Mercosul**. [S.l.]: Curitiba: Grupo Integrado de Aquicultura e Estudos Ambientais, 2004. 10

CAI, X.; YANG, Z.-L.; DAVID, C. H.; NIU, G.-Y.; RODELL, M. Hydrological evaluation of the noah-mp land surface model for the Mississippi river basin. **Journal of Geophysical Research: Atmospheres**, v. 119, n. 1, p. 23–38, 2014. 18

CHEN, M.; WILLGOOSE, G. R.; SACO, P. M. Evaluation of the hydrology of the ibis land surface model in a semi-arid catchment. **Hydrological Processes**, v. 29, n. 5, p. 653–670, 2015. 20

_____. Investigating the impact of leaf area index temporal variability on soil moisture predictions using remote sensing vegetation data. **Journal of Hydrology**, v. 522, p. 274–284, 2015. 20

COSTA, M. H.; YANAGI, S. N.; SOUZA, P. J.; RIBEIRO, A.; ROCHA, E. J. Climate change in Amazonia caused by soybean cropland expansion, as compared to caused by pastureland expansion. **Geophysical Research Letters**, v. 34, n. 7, 2007. 19

CROW, W. T.; WOOD, E. F. The assimilation of remotely sensed soil brightness temperature imagery into a land surface model using ensemble kalman filtering: a case study based on estar measurements during sgp97. **Advances in Water Resources**, v. 26, n. 2, p. 137–149, 2003. 2

CUNHA, A. P. M.; ALVALÁ, R. C.; SAMPAIO, G.; SHIMIZU, M. H.; COSTA, M. H. Calibration and validation of the integrated biosphere simulator (ibis) for a brazilian semiarid region. **Journal of Applied Meteorology and Climatology**, v. 52, n. 12, p. 2753–2770, 2013. 19

DAFIS, S.; LAGOUVARDOS, K.; KOTRONI, V.; GIANNAROS, T.; BARTZOKAS, A. Observational and modeling study of a mesoscale convective system during the hymex—sop1. **Atmospheric Research**, v. 187, p. 1–15, 2017. 38

DESILETS, D.; ZREDA, M.; FERRÉ, T. P. Nature's neutron probe: land surface hydrology at an elusive scale with cosmic rays. **Water Resources Research**, v. 46, n. 11, 2010. 12

- DIRMEYER, P. A. Using a global soil wetness dataset to improve seasonal climate simulation. **Journal of Climate**, v. 13, n. 16, p. 2900–2922, 2000. 6
- DY, C. Y.; FUNG, J. C. H. Updated global soil map for the weather research model and soil moisture initialization for the noah land surface model. **Journal of Geophysical Research: Atmospheres**, v. 121, n. 15, p. 8777–8800, 2016. 5
- ELTAHIR, E. A. A soil moisture–rainfall feedback mechanism: 1. theory and observations. **Water Resources Research**, v. 34, n. 4, p. 765–776, 1998. 5
- ENGMAN, E. T.; CHAUHAN, N. Status of microwave soil moisture measurements with remote sensing. **Remote Sensing of Environment**, v. 51, n. 1, p. 189–198, 1995. 10
- ENTEKHABI, D. et al. The soil moisture active passive (SMAP) mission. **Proceedings of the IEEE**, v. 98, n. 5, p. 704–716, 2010. 1, 8, 12
- ESA Climate Change Initiative Plus Soil Moisture. [S.l.]: ESA, 2021. 31, 32
- EUROPEAN SPACE AGENCY (ESA). Soil moisture CCI: overview. 2021. Disponível em: <https://esa-soilmoisture-cci.org/node/93>. Acesso em: 04 abr. 2021. 32
- EUROPEAN SPACE AGENCY (ESA). *Overview*. 2021. Disponível em: <https://esa-soilmoisture-cci.org/node/93>. Acesso em: 24 mar. 2021. 31, 32
- FIGUEROA, S. N. et al. The brazilian global atmospheric model (bam): performance for tropical rainfall forecasting and sensitivity to convective scheme and horizontal resolution. **Weather and Forecasting**, v. 31, n. 5, p. 1547–1572, 2016. 19
- FOLEY, J. A.; PRENTICE, I. C.; RAMANKUTTY, N.; LEVIS, S.; POLLARD, D.; SITCH, S.; HAXELTINE, A. An integrated biosphere model of land surface processes, terrestrial carbon balance, and vegetation dynamics. **Global Biogeochemical Cycles**, v. 10, n. 4, p. 603–628, 1996. 27, 28
- FRANZ, T.; ZREDA, M.; ROSOLEM, R.; FERRE, T. A universal calibration function for determination of soil moisture with cosmic-ray neutrons. **Hydrology & Earth System Sciences Discussions**, v. 9, n. 9, 2012. 12
- GAO, F.; HE, T.; WANG, Z.; GHIMIRE, B.; SHUAI, Y.; MASEK, J. G.; SCHAAF, C.; WILLIAMS, C. Multiscale climatological albedo look-up maps

derived from moderate resolution imaging spectroradiometer brdf/albedo products. **Journal of Applied Remote Sensing**, v. 8, n. 1, p. 083532, 2014. 27

GESCH, D. B.; VERDIN, K. L.; GREENLEE, S. K. New land surface digital elevation model covers the Earth. **EOS, Transactions American Geophysical Union**, v. 80, n. 6, p. 69–70, 1999. 24

GONCALVES, L. G. G. de et al. The South American land data assimilation system (saldas) 5-yr retrospective atmospheric forcing datasets. **Journal of Hydrometeorology**, v. 10, n. 4, p. 999–1010, 2009. 22

GONCALVES, L. G. G. de; SHUTTLEWORTH, W. J.; CHOU, S. C.; XUE, Y.; HOUSER, P. R.; TOLL, D. L.; MARENGO, J.; RODELL, M. Impact of different initial soil moisture fields on eta model weather forecasts for South America. **Journal of Geophysical Research: Atmospheres**, v. 111, n. D17, 2006. 21

GUO, Z. et al. GLACE: the global land–atmosphere coupling experiment. part ii: analysis. **Journal of Hydrometeorology**, v. 7, n. 4, p. 611–625, 2006. 1, 7

HANSEN, M. C.; DEFRIES, R. S.; TOWNSHEND, J. R.; SOHLBERG, R. Global land cover classification at 1 km spatial resolution using a classification tree approach. **International Journal of Remote Sensing**, v. 21, n. 6-7, p. 1331–1364, 2000. 24

HERSBACH, H. et al. Global reanalysis: goodbye ERA-Interim, hello ERA5. **ECMWF Newsletter**, v. 159, p. 17–24, 2019. 30, 31

HILLEL, D. et al. **Environmental soil physics**. San Diego: Academic Press, 1998. 1

HU, P.; LIU, Q.; HESLOP, D.; ROBERTS, A. P.; JIN, C. Soil moisture balance and magnetic enhancement in loess–paleosol sequences from the Tibetan Plateau and Chinese Loess Plateau. **Earth and Planetary Science Letters**, v. 409, p. 120–132, 2015. 5

JIMÉNEZ-MUÑOZ, J. C.; MATTAR, C.; BARICHIVICH, J.; SANTAMARÍA-ARTIGAS, A.; TAKAHASHI, K.; MALHI, Y.; SOBRINO, J. A.; SCHRIER, G. v. d. Record-breaking warming and extreme drought in the Amazon rainforest during the course of el niño 2015–2016. **Scientific Reports**, v. 6, n. 1, p. 1–7, 2016. 65

JUNG, H. C.; KANG, D.-H.; KIM, E.; GETIRANA, A.; YOON, Y.; KUMAR, S.; PETERS-LIDARD, C. D.; HWANG, E. Towards a soil moisture drought monitoring system for South Korea. **Journal of Hydrology**, v. 589, p. 125176, 2020. 2

KOSTER, R.; SUAREZ, M. GLACE: the Global Land–Atmosphere Coupling Experiment. **Journal of Hydrometeorology**, v. 7, p. 611–625, 2005. 5

KOSTER, R. D. Regions of strong coupling between soil moisture. **Chemical Communications**, v. 517, n. 1986, 1986. 1, 5

KOSTER, R. D. et al. GLACE: the Global Land–Atmosphere Coupling Experiment. part i: overview. **Journal of Hydrometeorology**, v. 7, n. 4, p. 590–610, 2006. 8

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**, v. 105, n. D20, p. 24809–24822, 2000. 18, 27

KUBOTA, P. Y. **Variabilidade da energia armazenada na superfície e o seu impacto na definição do padrão de precipitação na América do Sul**. [S.l.]: São José dos Campos: INPE, 2012. 28

KUCHARIK, C. J.; FOLEY, J. A.; DELIRE, C.; FISHER, V. A.; COE, M. T.; LENTERS, J. D.; YOUNG-MOLLING, C.; RAMANKUTTY, N.; NORMAN, J. M.; GOWER, S. T. Testing the performance of a dynamic global ecosystem model: water balance, carbon balance, and vegetation structure. **Global Biogeochemical Cycles**, v. 14, n. 3, p. 795–825, 2000. 27

KUMAR, S. V. et al. Land information system: an interoperable framework for high resolution land surface modeling. **Environmental Modelling & Software**, v. 21, n. 10, p. 1402–1415, 2006. 21

LIU, Y. Y.; DORIGO, W. A.; PARINUSSA, R.; JEU, R. A. de; WAGNER, W.; MCCABE, M. F.; EVANS, J.; DIJK, A. V. Trend-preserving blending of passive and active microwave soil moisture retrievals. **Remote Sensing of Environment**, v. 123, p. 280–297, 2012. 13

LIU, Y. Y.; PARINUSSA, R.; DORIGO, W. A.; JEU, R. A. D.; WAGNER, W.; DIJK, A. V.; MCCABE, M. F.; EVANS, J. 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. 32

LYNCH-STIEGLITZ, M. The development and validation of a simple snow model for the giss gcm. **Journal of Climate**, v. 7, n. 12, p. 1842–1855, 1994. 27

MA, H.; ZENG, J.; CHEN, N.; ZHANG, X.; COSH, M. H.; WANG, W. Satellite surface soil moisture from smap, smos, amsr2 and esa cci: a comprehensive assessment using global ground-based observations. **Remote Sensing of Environment**, v. 231, p. 111215, 2019. 13

MA, N.; NIU, G.-Y.; XIA, Y.; CAI, X.; ZHANG, Y.; MA, Y.; FANG, Y. A systematic evaluation of Noah-MP in simulating land-atmosphere energy, water, and carbon exchanges over the continental United States. **Journal of Geophysical Research: Atmospheres**, v. 122, n. 22, p. 12–245, 2017. 25

MAGGIONI, V.; HOUSER, P. R. Soil moisture data assimilation. In: PARK S. K.; XU, L. E. (Ed.). **Data assimilation for atmospheric, oceanic and hydrologic applications (Vol. III)**. Berlin: Springer, 2017. p. 195–217. 1

MARENGO, J. A.; NOBRE, C. A.; SELUCHI, M. E.; CUARTAS, A.; ALVES, L. M.; MENDIONDO, E. M.; OBREGÓN, G.; SAMPAIO, G. A seca e a crise hídrica de 2014-2015 em São Paulo. **Revista USP**, n. 106, p. 31–44, 2015. 69

MARENGO, J. A.; SOUZA-JUNIOR, C. M.; THONICKE, K.; BURTON, C.; HALLADAY, K.; BETTS, R. A.; ALVES, L. M.; SOARES, W. R. Changes in climate and land use over the Amazon region: current and future variability and trends. **Frontiers in Earth Science**, v. 6, p. 228, 2018. 65

MASKE, B. B. **Assimilação de dados de umidade do solo derivada de satélite no modelo SSIB acoplado ao MCGA/CPTEC**. Dissertao (Dissertação de Mestrado em Meteorologia) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016. Disponível em: <<http://mtc-m21b.sid.inpe.br/col/sid.inpe.br/mtc-m21b/2016/05.03.20.12/doc/publicacao.pdf>>. Acesso em: 07 maio 2021. 10

MCKEE, T. B. et al. The relationship of drought frequency and duration to time scales. In: **CONFERENCE ON APPLIED CLIMATOLOGY**, 8. Boston: [s.n.], 1993. p. 179–183. 15, 16

MILOVAC, J. **Studies of soil-vegetation-atmosphere feedback processes with WRF on the convection permitting scale**. 149 p. Dissertation (Master in Meteorology) — Universität Hohenheim, Stuttgart - Alemanha, 2017. 6

MONACELLI, G.; GALLUCCIO, M.; ABBAFATI, M. **Drought within the context of the Region VI**. Italia: World Meteorological Organization (WMO), 2005. 14

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. 16

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION (NASA). **GLDAS specifications**. 2021. Disponível em: <https://ldas.gsfc.nasa.gov/gldas/specifications>. Acesso em: 09 abr. 2021. 30

_____. **GLDAS specifications**. 2021. Disponível em: <https://ldas.gsfc.nasa.gov/gldas/specifications>. Acesso em: 24 fev. 2021. 30

_____. **Global Data Assimilation System (GDAS)**. 2021. Disponível em: <https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/global-data-assimilation-system-gdas>. Acesso em: 09 abr. 2021. 28

_____. **Land information system**. 2021. Disponível em: <https://lis.gsfc.nasa.gov/software/lis>. Acesso em: 25 fev. 2021. 23, 24

_____. _____. 2021. Disponível em: <https://lis.gsfc.nasa.gov/software/lis>. Acesso em: 18 fev. 2021. 24

_____. **Land information system framework**. 2021. Disponível em: <https://lis.gsfc.nasa.gov/>. Acesso em: 16 mar. 2021. 20, 21

_____. **What is CERES?** 2021. Disponível em: <https://ceres.larc.nasa.gov/>. Acesso em: 08 abr. 2021. 29

NIU, G.-Y. et al. The community Noah land surface model with multiparameterization options (Noah-MP): 1. model description and evaluation with local-scale measurements. **Journal of Geophysical Research: Atmospheres**, v. 116, n. D12, 2011. 17, 18, 25

NIU, G.-Y.; YANG, Z.-L. An observation-based formulation of snow cover fraction and its evaluation over large North American river basins. **Journal of Geophysical Research: Atmospheres**, v. 112, n. D21, 2007. 25

- NJOKU, E. G.; ENTEKHABI, D. Passive microwave remote sensing of soil moisture. **Journal of Hydrology**, v. 184, n. 1-2, p. 101–129, 1996. 12
- NJOKU, E. G.; JACKSON, T. J.; LAKSHMI, V.; CHAN, T. K.; NGHIEM, S. V. Soil moisture retrieval from AMSR-E. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 2, p. 215–229, 2003. 12
- NYS, E. D.; ENGLE, N. L.; MAGALHÃES, A. R. **Secas no Brasil: política e gestão proativas**. Brasília, DF: Centro de Gestão e Estudos Estratégicos-CGEE: [s.n.], 2016. 16, 17
- OKI, T.; ENTEKHABI, D.; HARROLD, T. I. The global water cycle. **Global Energy and Water Cycles**, v. 10, p. 27, 1999. 1, 5
- OWE, M.; GRIEND, A. Van de; JEU, R. D.; VRIES, J. D.; SEYHAN, E.; ENGMAN, E. Estimating soil moisture from satellite microwave observations: past and ongoing projects, and relevance to gcip. **Journal of Geophysical Research: Atmospheres**, v. 104, n. D16, p. 19735–19742, 1999. 13
- PALMER, W. C. **Meteorological drought**. [S.l.]: US Department of Commerce, Weather Bureau, 1965. 15
- PETERS-LIDARD, C. D. et al. High-performance earth system modeling with NASA/GSFC's Land Information System. **Innovations in Systems and Software Engineering**, v. 3, n. 3, p. 157–165, 2007. 20, 21, 23, 24
- PETROPOULOS, G. P.; GRIFFITHS, H. M.; DORIGO, W.; XAVER, A.; GRUBER, A. Surface soil moisture estimation: significance, controls and conventional measurement techniques. In: PETROPOULOS, G. E. (Ed.). **Remote sensing of energy fluxes and soil moisture content**. [S.l.]: CRC Press, 2013. p. 29–48. 5
- REICHLE, R. H.; KOSTER, R. D.; DONG, J.; BERG, A. A. Global soil moisture from satellite observations, land surface models, and ground data: implications for data assimilation. **Journal of Hydrometeorology**, v. 5, n. 3, p. 430–442, 2004. 2
- ROBINSON, D.; CAMPBELL, C.; HOPMANS, J.; 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. 11, 12

- ROBOCK, A.; VINNIKOV, K. Y.; SRINIVASAN, G.; ENTIN, J. K.; HOLLINGER, S. E.; SPERANSKAYA, N. A.; LIU, S.; NAMKHAI, A. The global soil moisture data bank. **Bulletin of the American Meteorological Society**, v. 81, n. 6, p. 1281–1300, 2000. 11
- RODELL, M.; HOUSER, P.; BERG, A.; FAMIGLIETTI, J. Evaluation of 10 methods for initializing a land surface model. **Journal of Hydrometeorology**, v. 6, n. 2, p. 146–155, 2005. 17
- RODELL, M. et al. The global land data assimilation system. **Bulletin of the American Meteorological Society**, v. 85, n. 3, p. 381–394, 2004. 3, 21, 28, 30
- ROZANTE, J. R.; MOREIRA, D. S.; GONCALVES, L. G. G. de; VILA, D. A. Combining TRMM and surface observations of precipitation: technique and validation over South America. **Weather and Forecasting**, v. 25, n. 3, p. 885–894, 2010. 29
- RUI, H.; BEAUDOING, H.; LOESER, C. **Readme document for NASA GLDAS version 2 data products**. Washington: NASA, 2018. 27
- SAATCHI, S.; ASEFI-NAJAFABADY, S.; MALHI, Y.; ARAGÃO, L. E.; ANDERSON, L. O.; MYNENI, R. B.; NEMANI, R. Persistent effects of a severe drought on amazonian forest canopy. **Proceedings of the National Academy of Sciences**, v. 110, n. 2, p. 565–570, 2013. 66
- SCHMUGGE, T. J. Remote sensing of soil moisture: recent advances. **IEEE Transactions on Geoscience and Remote Sensing**, n. 3, p. 336–344, 1983. 2, 12
- SEHLER, R.; LI, J.; REAGER, J.; YE, H. Investigating relationship between soil moisture and precipitation globally using remote sensing observations. **Journal of Contemporary Water Research & Education**, v. 168, n. 1, p. 106–118, 2019. 2
- SELLERS, P.; DORMAN, J. Testing the simple biosphere model (sib) using point micrometeorological and biophysical data. **Journal of Applied Meteorology and Climatology**, v. 26, n. 5, p. 622–651, 1987. 7
- SENEVIRATNE, S. I.; CORTI, T.; DAVIN, E. L.; HIRSCHI, M.; JAEGER, E. B.; LEHNER, I.; ORLOWSKY, B.; TEULING, A. J. Investigating soil moisture–climate interactions in a changing climate: a review. **Earth-Science Reviews**, v. 99, n. 3-4, p. 125–161, 2010. 1, 2, 5, 7, 11, 12, 13

SILVA, M. C. L. d.; MENDONÇA, A. M.; BONATTI, J. P. Determinação das previsões de temperaturas mínimas e máximas a partir do histórico das previsões de tempo por conjunto do CPTEC. **Revista Brasileira de Meteorologia**, v. 23, n. 4, p. 431–449, 2008. 38

ŚLIWIŃSKA, J.; WIŃSKA, M.; NASTULA, J. Terrestrial water storage variations and their effect on polar motion. **Acta Geophysica**, v. 67, n. 1, p. 17–39, 2019. 26

SMITH, K. A. **Soil and environmental analysis: physical methods, revised, and expanded**. [S.l.]: CRC Press, 2000. 11

TAO, J.; REICHLER, R. H.; KOSTER, R. D.; FORMAN, B. A.; XUE, Y. Evaluation and enhancement of permafrost modeling with the NASA catchment land surface model. **Journal of Advances in Modeling Earth Systems**, v. 9, n. 7, p. 2771–2795, 2017. 18, 19

TAYLOR, C. M. Detecting soil moisture impacts on convective initiation in europe. **Geophysical Research Letters**, v. 42, n. 11, p. 4631–4638, 2015. 1

THORNTHWAITE, C. W.; MATHER, J. R.; CARTER, D. B. **Three water-balance maps of eastern north america**. [S.l.]: LWW, 1959. 15

TOPP, G. C. State of the art of measuring soil water content. **Hydrological Processes**, v. 17, n. 14, p. 2993–2996, 2003. 13

TOPP, G. C.; REYNOLDS, W. D. Time domain reflectometry: a seminal technique for measuring mass and energy in soil. **Soil and Tillage Research**, v. 47, n. 1-2, p. 125–132, 1998. 11

UNIVERSITY OF TEXAS. **Noah-MP users' site**. 2021. Disponível em: <https://www.jsg.utexas.edu/noah-mp/>. Acesso em: 26 fev. 2021. 26

WAHR, J.; SWENSON, S.; VELICOGNA, I. Accuracy of grace mass estimates. **Geophysical Research Letters**, v. 33, n. 6, 2006. 13

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. 16

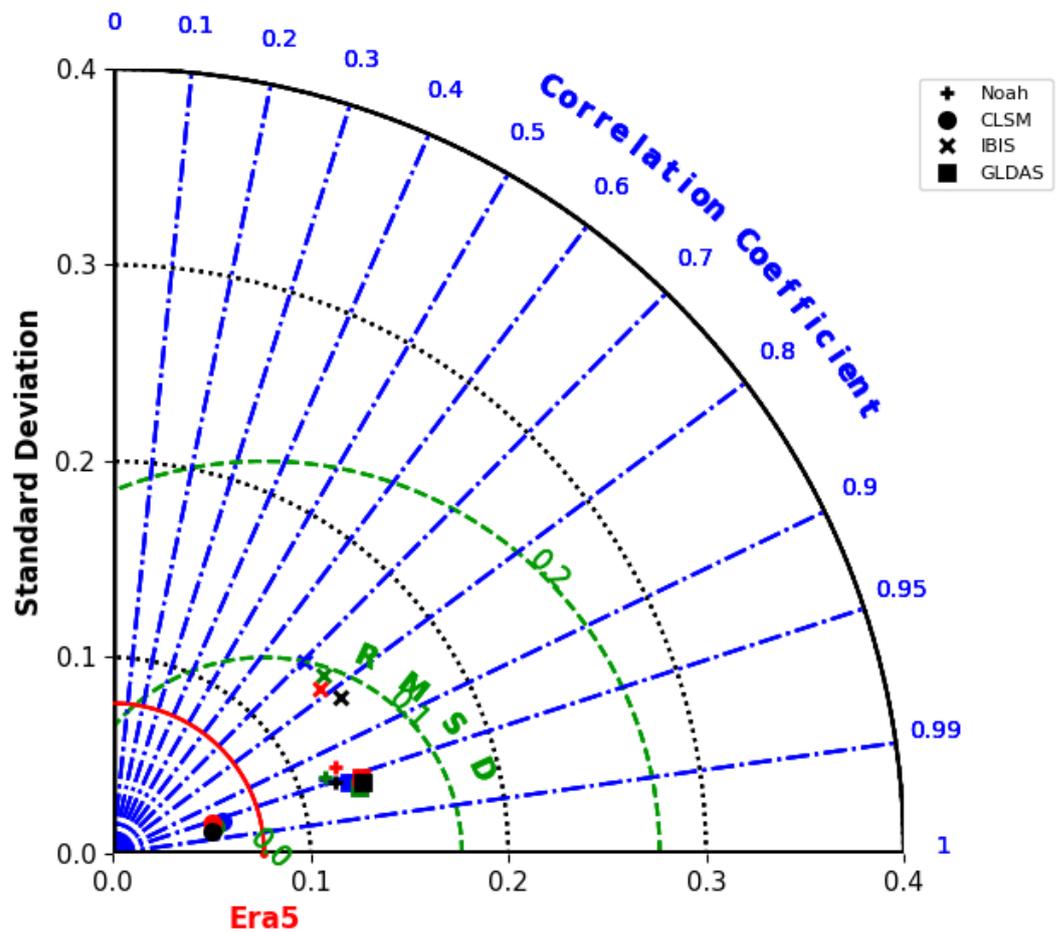
WIGNERON, J.-P. et al. Modelling the passive microwave signature from land surfaces: a review of recent results and application to the l-band smos / smap soil moisture retrieval algorithms. **Remote Sensing of Environment**, v. 192, p. 238–262, 2017. 12

- WILHITE, D. A. **Drought as a natural hazard: concepts and definitions.** [S.l.]: University of Nebraska, 2000. 14
- WILHITE, D. A.; GLANTZ, M. H. Understanding: the drought phenomenon: the role of definitions. **Water International**, v. 10, n. 3, p. 111–120, 1985. 2, 14
- XIA, Y.; MOCKO, D.; HUANG, M.; LI, B.; RODELL, M.; MITCHELL, K. E.; CAI, X.; EK, M. B. Comparison and assessment of three advanced land surface models in simulating terrestrial water storage components over the united states. **Journal of Hydrometeorology**, v. 18, n. 3, p. 625–649, 2017. 27
- YANG, L.; SUN, G.; ZHI, L.; ZHAO, J. Negative soil moisture–precipitation feedback in dry and wet regions. **Scientific Report**, v. 8, e 4026, 2018. 5
- YANG, Z.-L. et al. The community noah land surface model with multiparameterization options (noah-mp): 2. evaluation over global river basins. **Journal of Geophysical Research: Atmospheres**, v. 116, n. D12, 2011. 17, 18
- YE, X.; ZHANG, Q.; LIU, J.; LI, X.; XU, C.-y. Distinguishing the relative impacts of climate change and human activities on variation of streamflow in the poyang lake catchment, China. **Journal of Hydrology**, v. 494, p. 83–95, 2013. 11
- ZHAO, C.; QUIRING, S. M.; YUAN, S.; MCROBERTS, D. B.; ZHANG, N.; LEASOR, Z. Developing and evaluating national soil moisture percentile maps. **Soil Science Society of America Journal**, v. 84, n. 2, p. 443–460, 2020. 16
- ZHOU, X.; GEERTS, B. The influence of soil moisture on the planetary boundary layer and on cumulus convection over an isolated mountain. part i: observations. **Monthly Weather Review**, v. 141, n. 3, p. 1061–1078, 2013. 5
- ZREDA, M.; DESILETS, D.; FERRÉ, T.; SCOTT, R. L. Measuring soil moisture content non-invasively at intermediate spatial scale using cosmic-ray neutrons. **Geophysical Research Letters**, v. 35, n. 21, 2008. 12
- ZREDA, M.; SHUTTLEWORTH, W.; ZENG, X.; ZWECK, C.; DESILETS, D.; FRANZ, T.; ROSOLEM, R. COSMOS: the cosmic-ray soil moisture observing system. **Hydrology and Earth System Sciences**, v. 16, n. 11, p. 4079–4099, 2012. 8, 12, 13

APÊNDICE A- DIAGRAMA DE TAYLOR

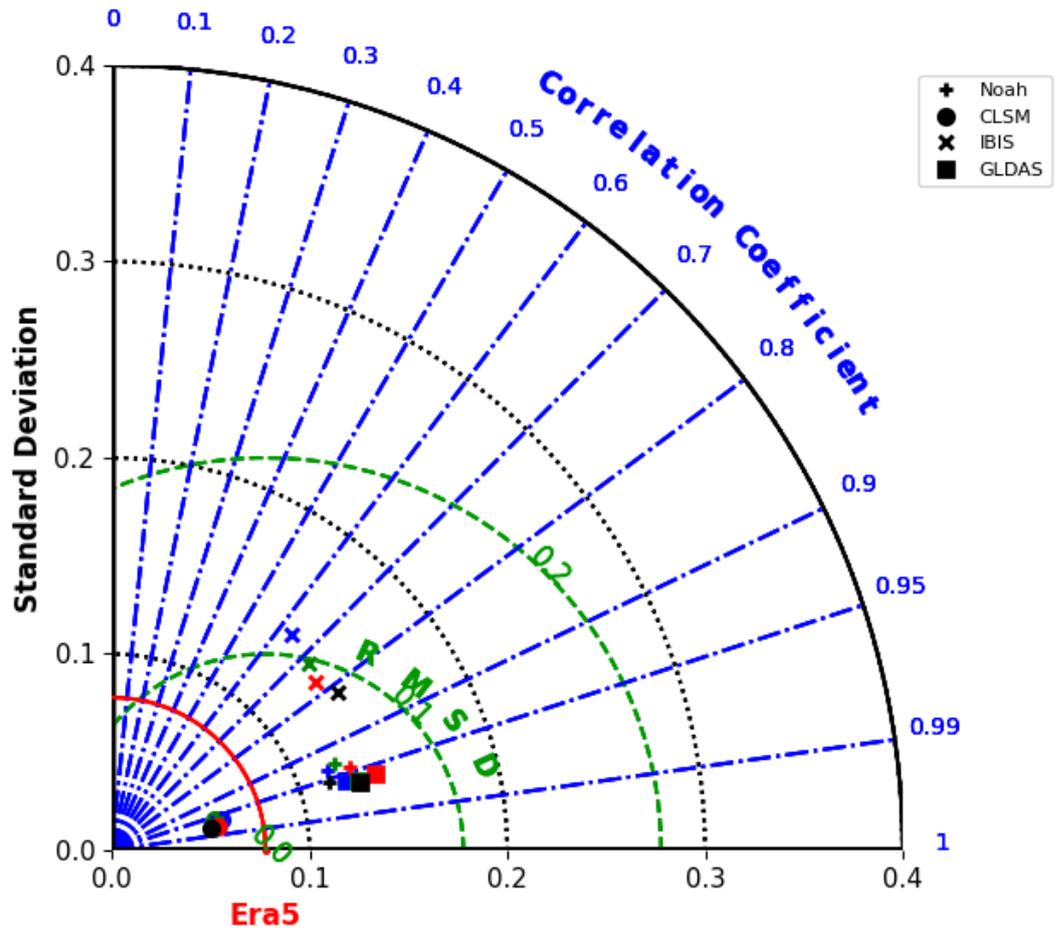
A.1 Diagrama de Taylor para as rodadas dos modelos com GDAS e MERGE

Figura A.1 - Diagrama de Taylor - ERA-5 - Região NE.



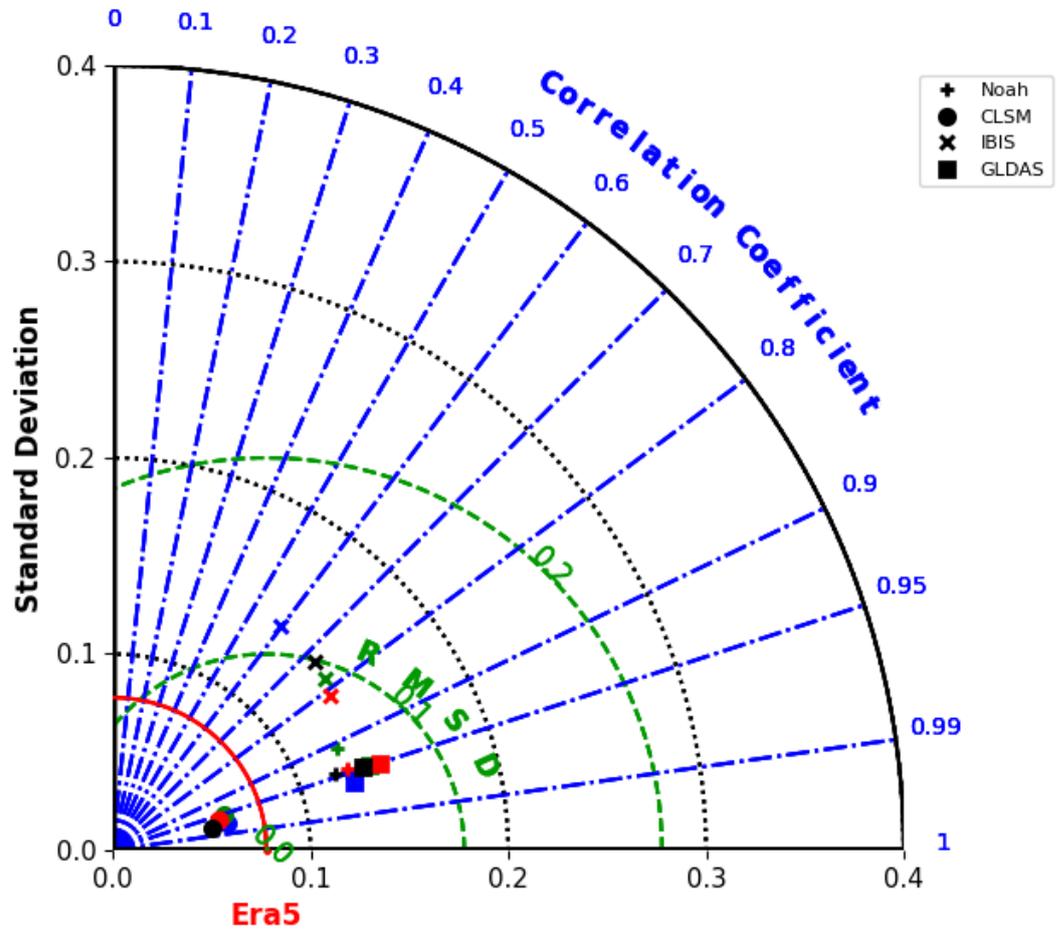
Fonte:Produção do autor.

Figura A.2 - Diagrama de Taylor - ERA-5 - Região NO.



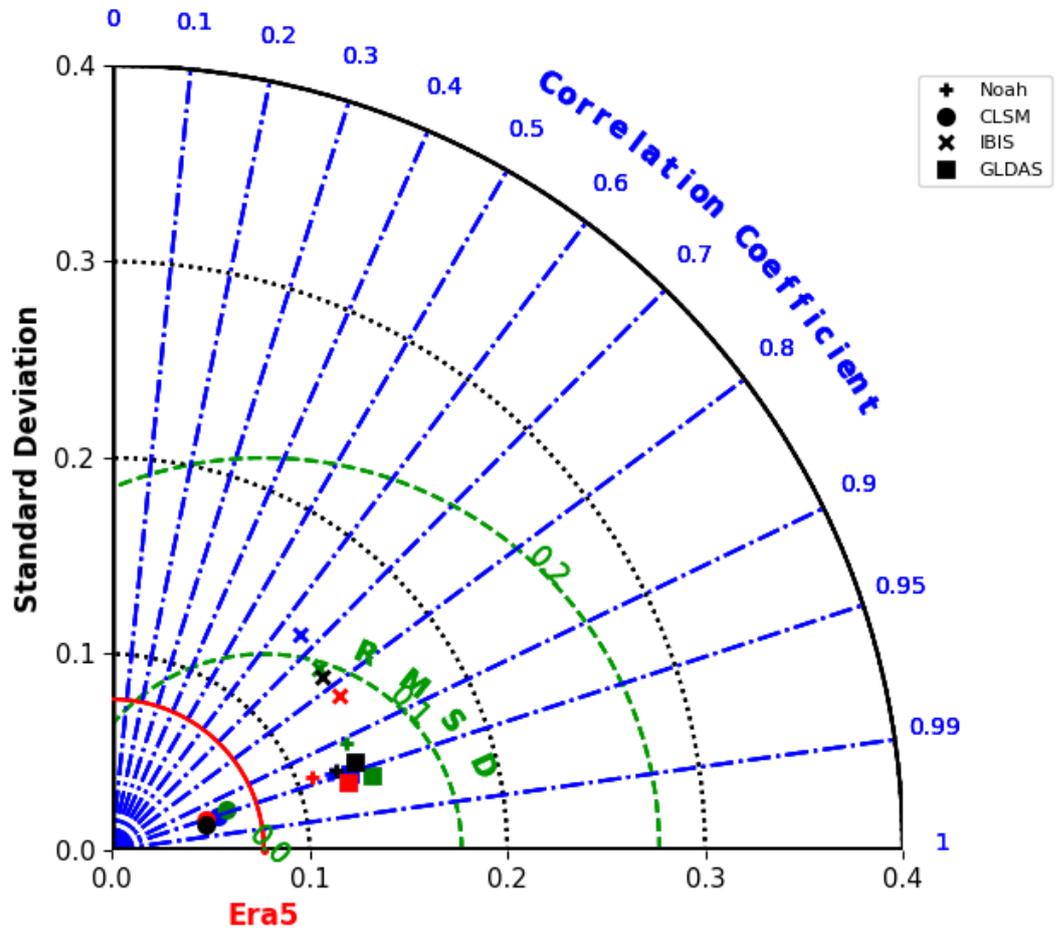
Fonte:Produção do autor.

Figura A.3 - Diagrama de Taylor - ERA-5 - Região AM.



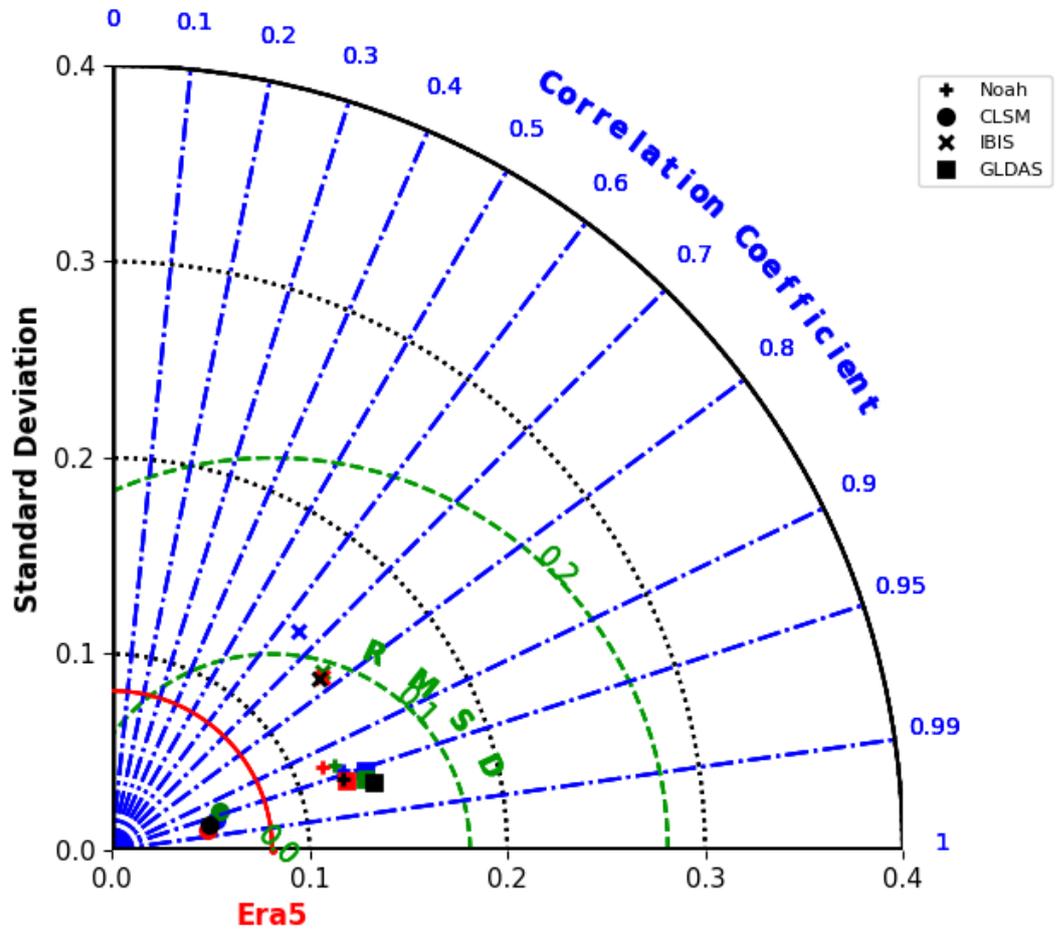
Fonte:Produção do autor.

Figura A.4 - Diagrama de Taylor - ERA-5 - Região SU.



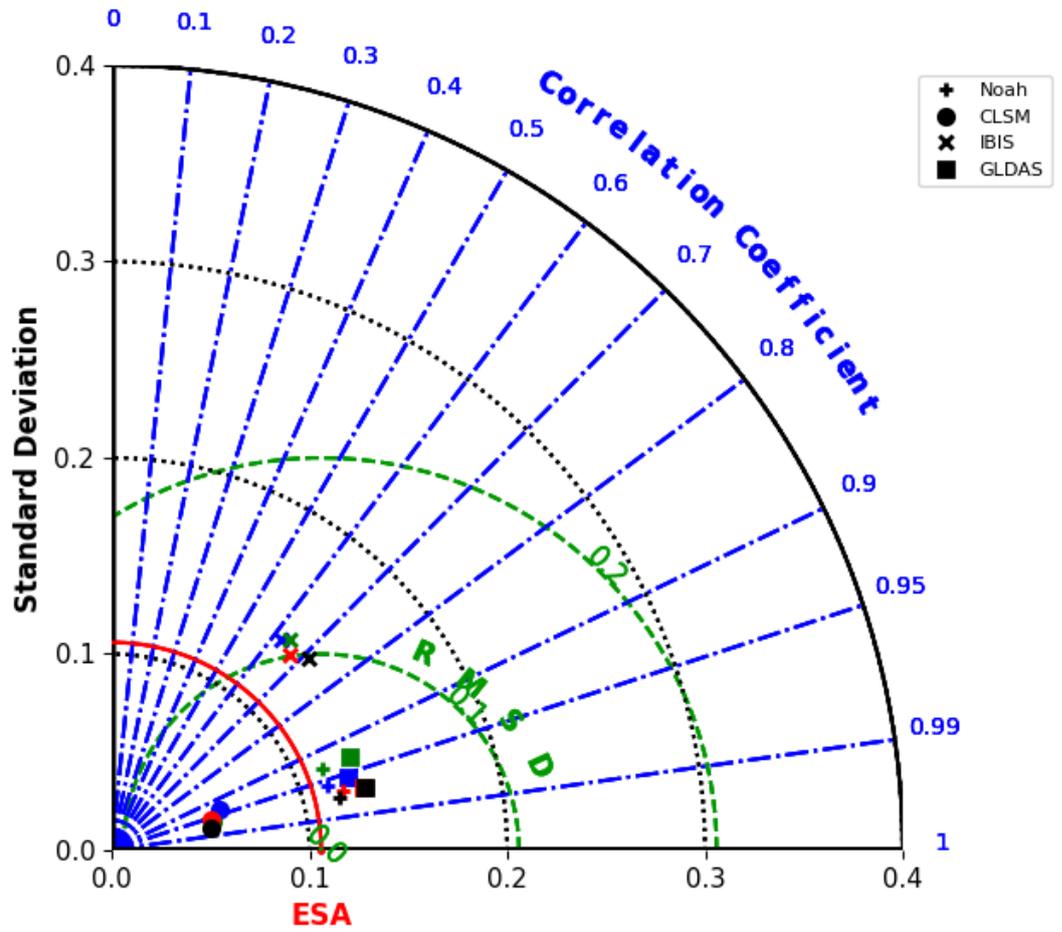
Fonte:Produção do autor.

Figura A.5 - Diagrama de Taylor - ERA-5 - Região PA.



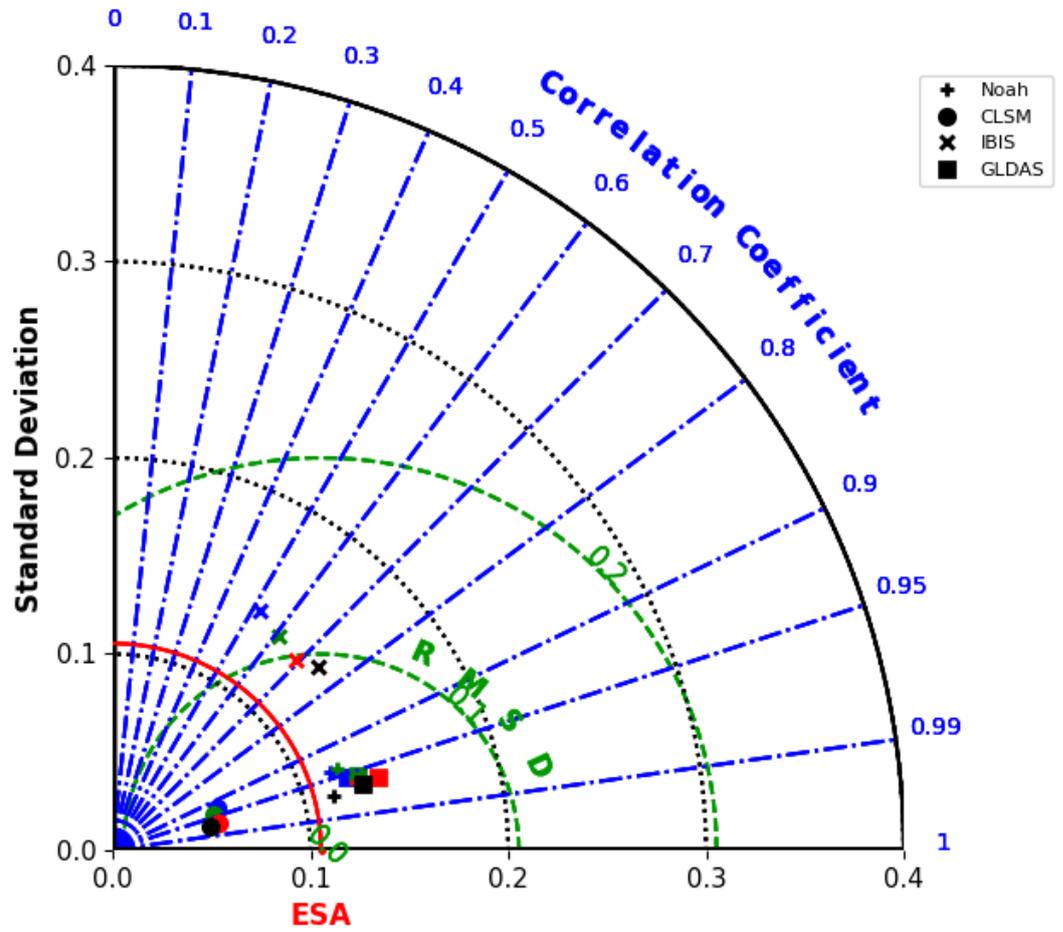
Fonte:Produção do autor.

Figura A.6 - Diagrama de Taylor - ESA-CCI - Região NE.



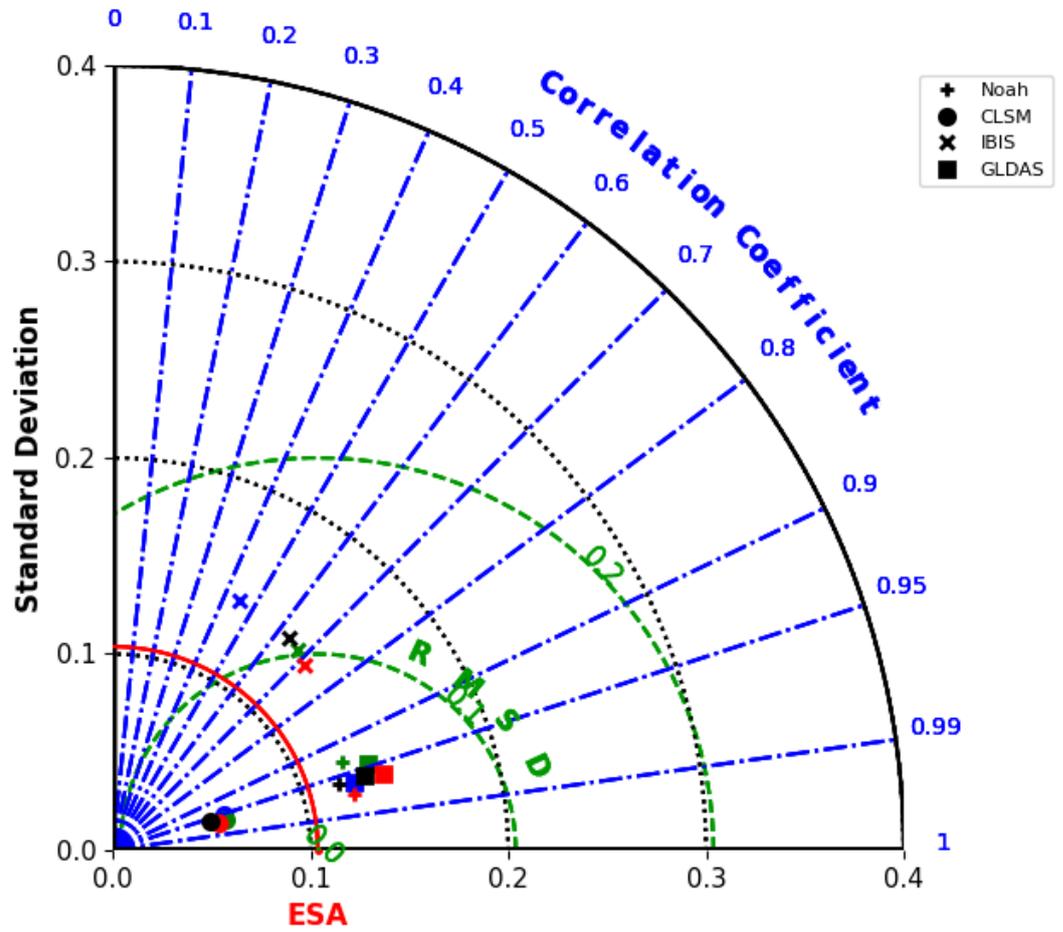
Fonte:Produção do autor.

Figura A.7 - Diagrama de Taylor - ESA-CCI - Região NO.



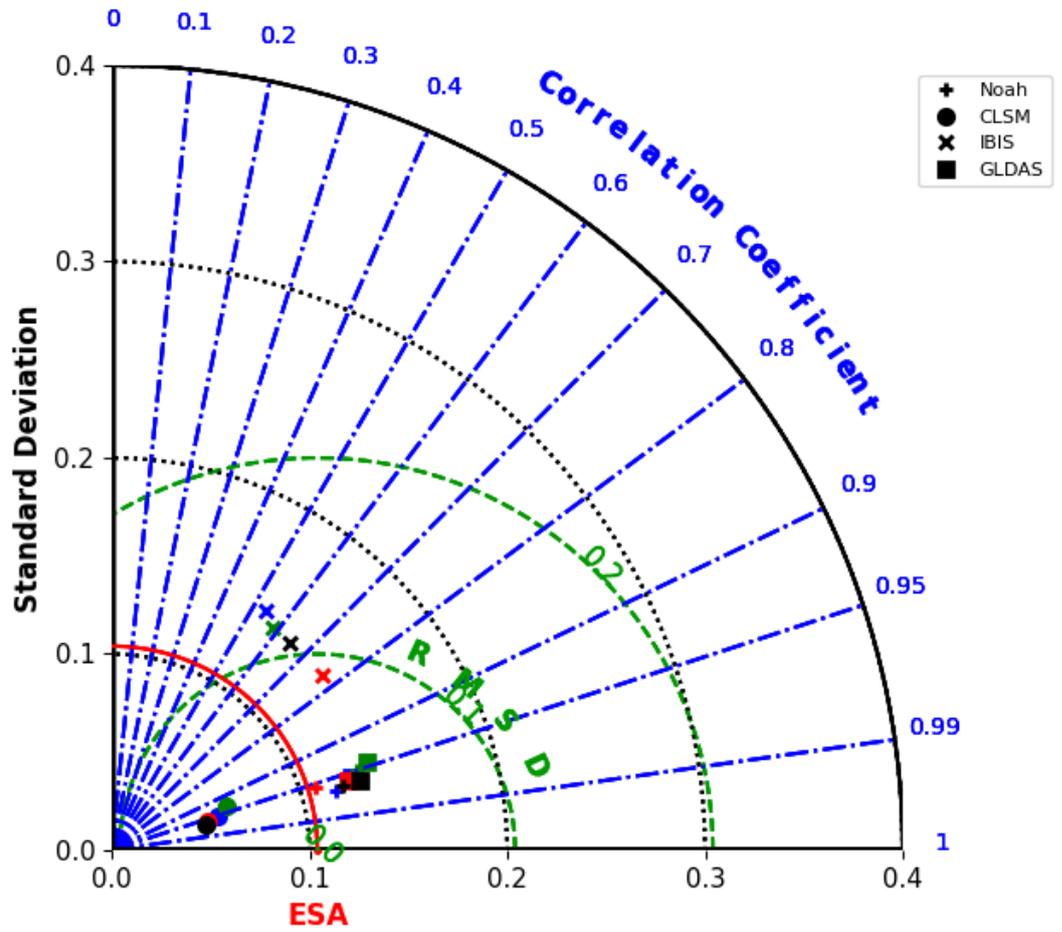
Fonte:Produção do autor.

Figura A.8 - Diagrama de Taylor - ESA-CCI - Região AM.



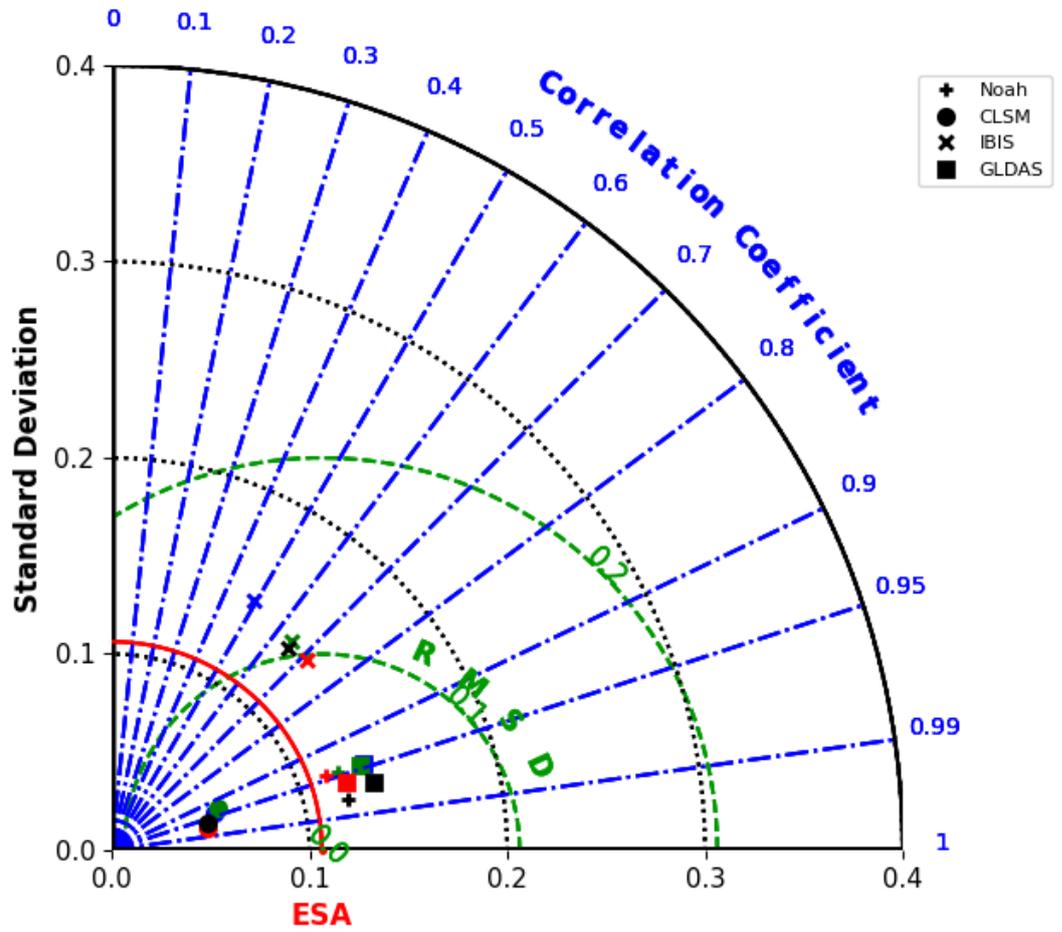
Fonte:Produção do autor.

Figura A.9 - Diagrama de Taylor - ESA-CCI - Região SU.



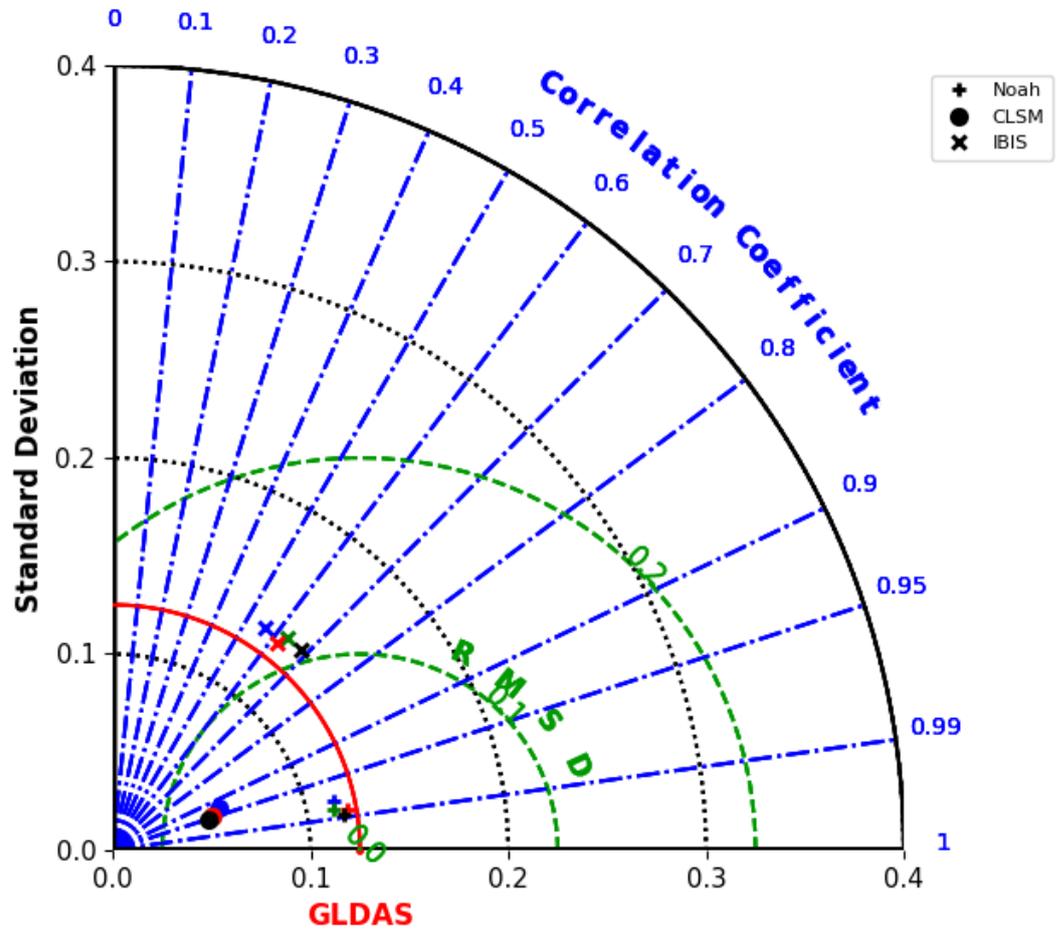
Fonte:Produção do autor.

Figura A.10 - Diagrama de Taylor - ESA-CCI - Região PA.



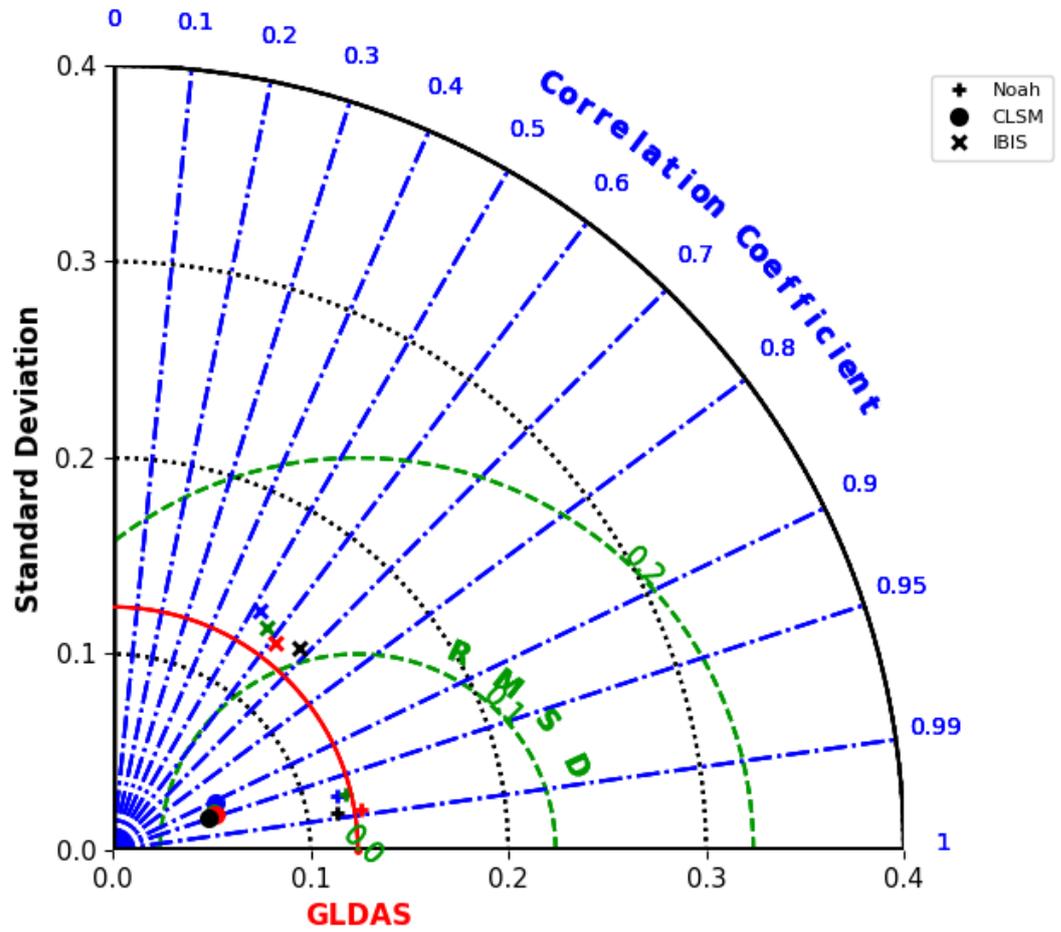
Fonte:Produção do autor.

Figura A.11 - Diagrama de Taylor - GLDAS- Região NE.



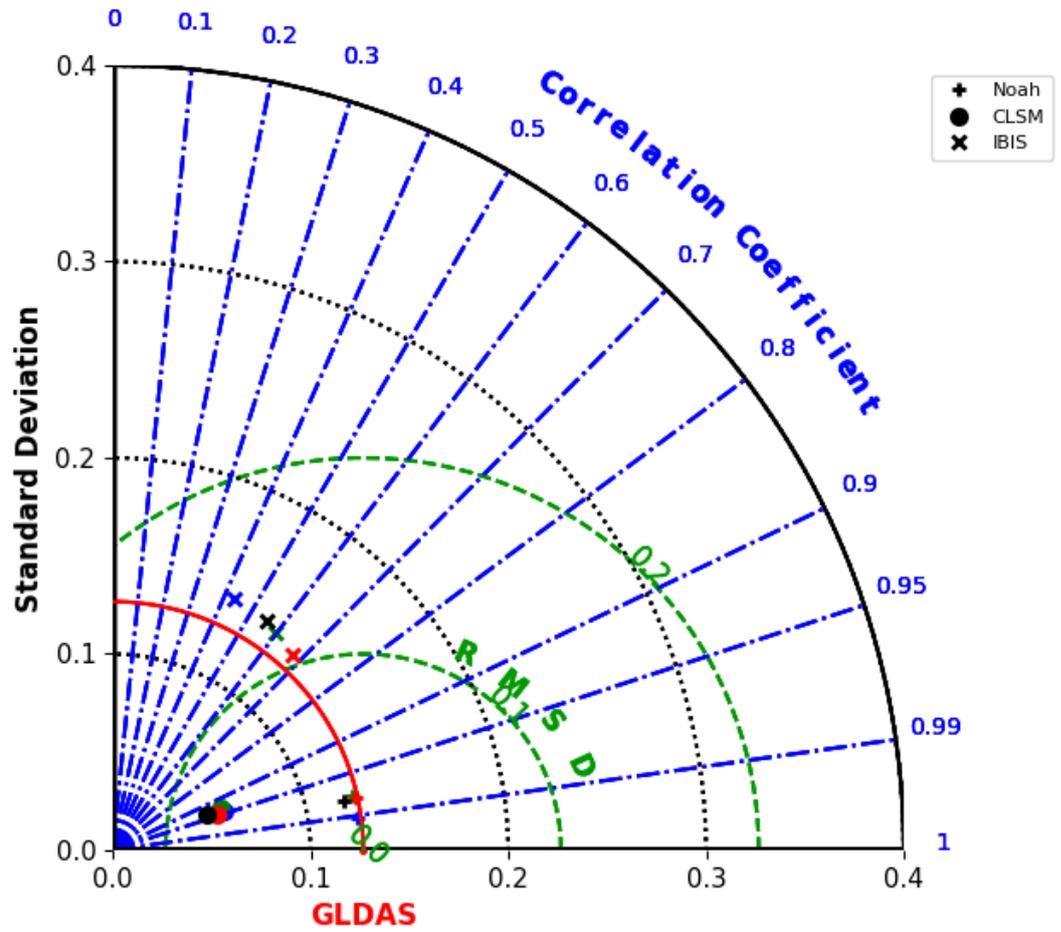
Fonte:Produção do autor.

Figura A.12 - Diagrama de Taylor - GLDAS- Região NO.



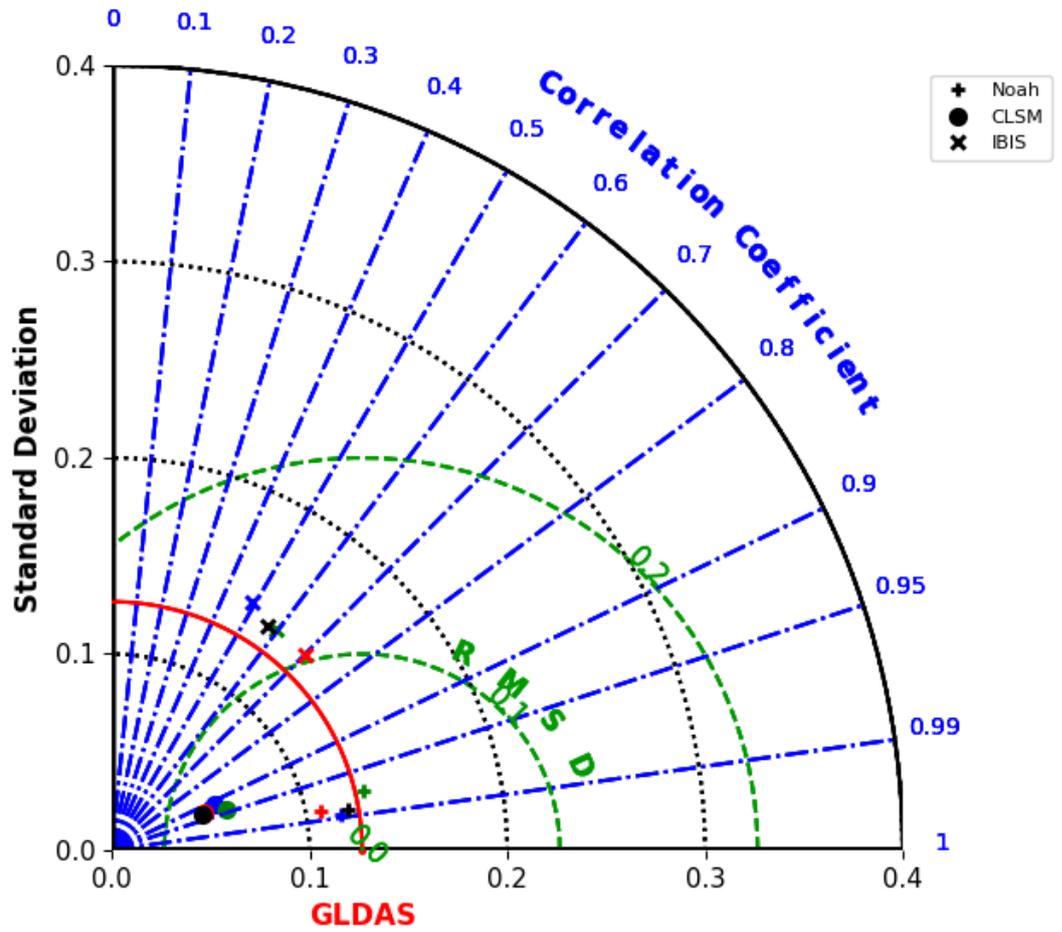
Fonte:Produção do autor.

Figura A.13 - Diagrama de Taylor - GLDAS- Região AM.



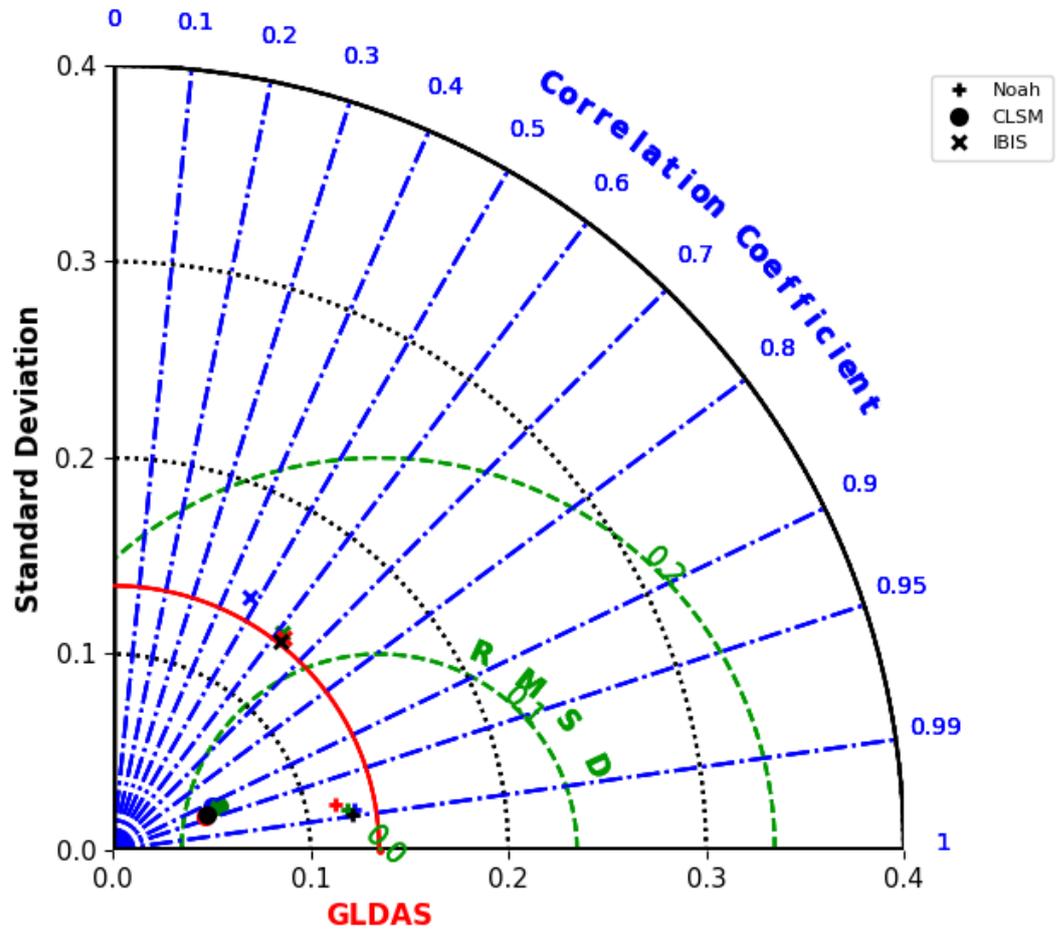
Fonte:Produção do autor.

Figura A.14 - Diagrama de Taylor - GLDAS- Região SU.



Fonte:Produção do autor.

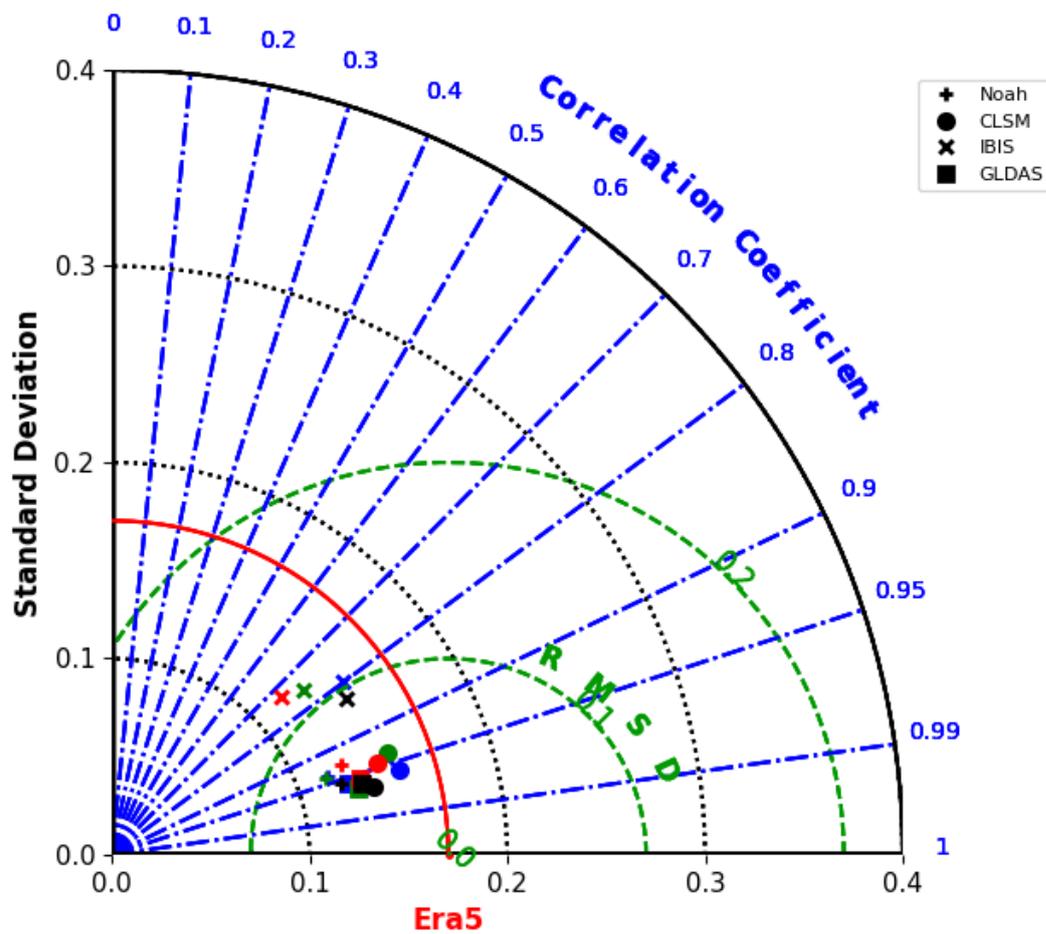
Figura A.15 - Diagrama de Taylor - GLDAS- Região PA.



Fonte:Produção do autor.

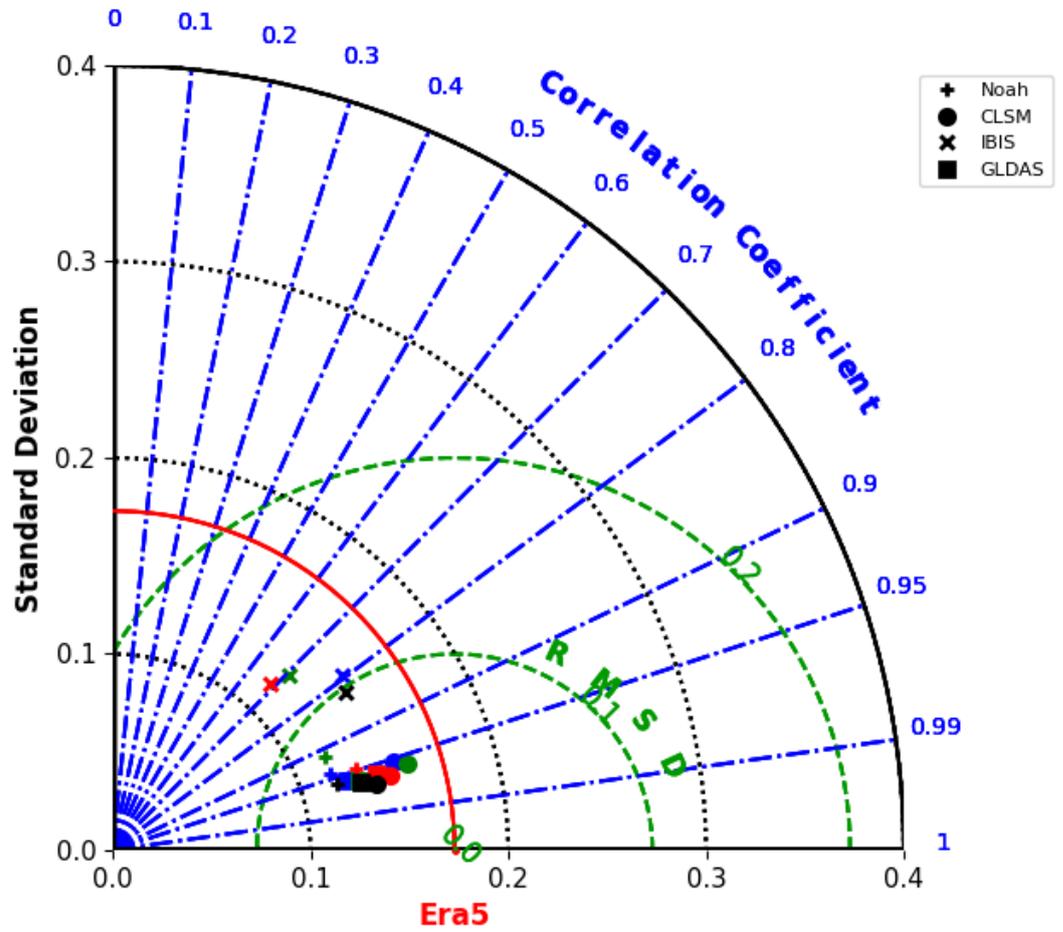
A.2 Diagrama de Taylor para as rodadas dos modelos com GDAS, MERGE E CERES

Figura A.16 - Diagrama de Taylor - ERA-5 - Região NE.



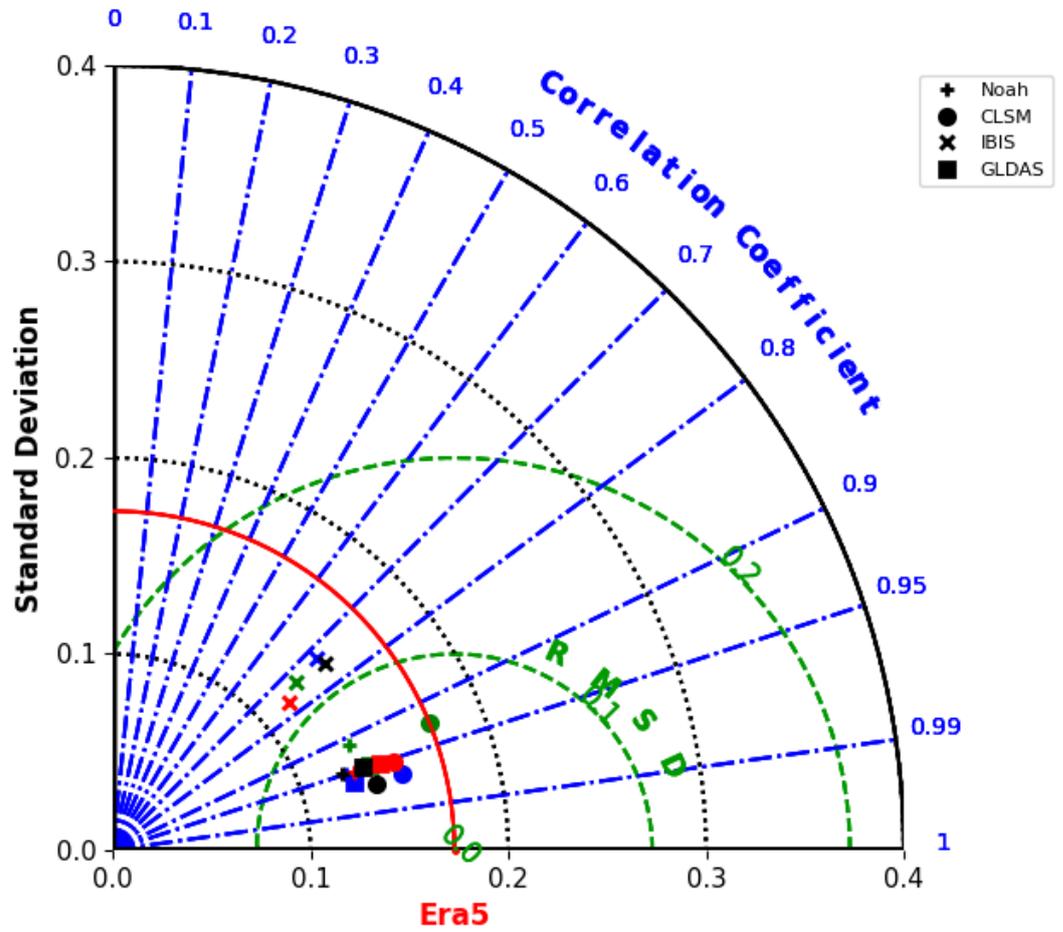
Fonte:Produção do autor.

Figura A.17 - Diagrama de Taylor - ERA-5 - Região NO.



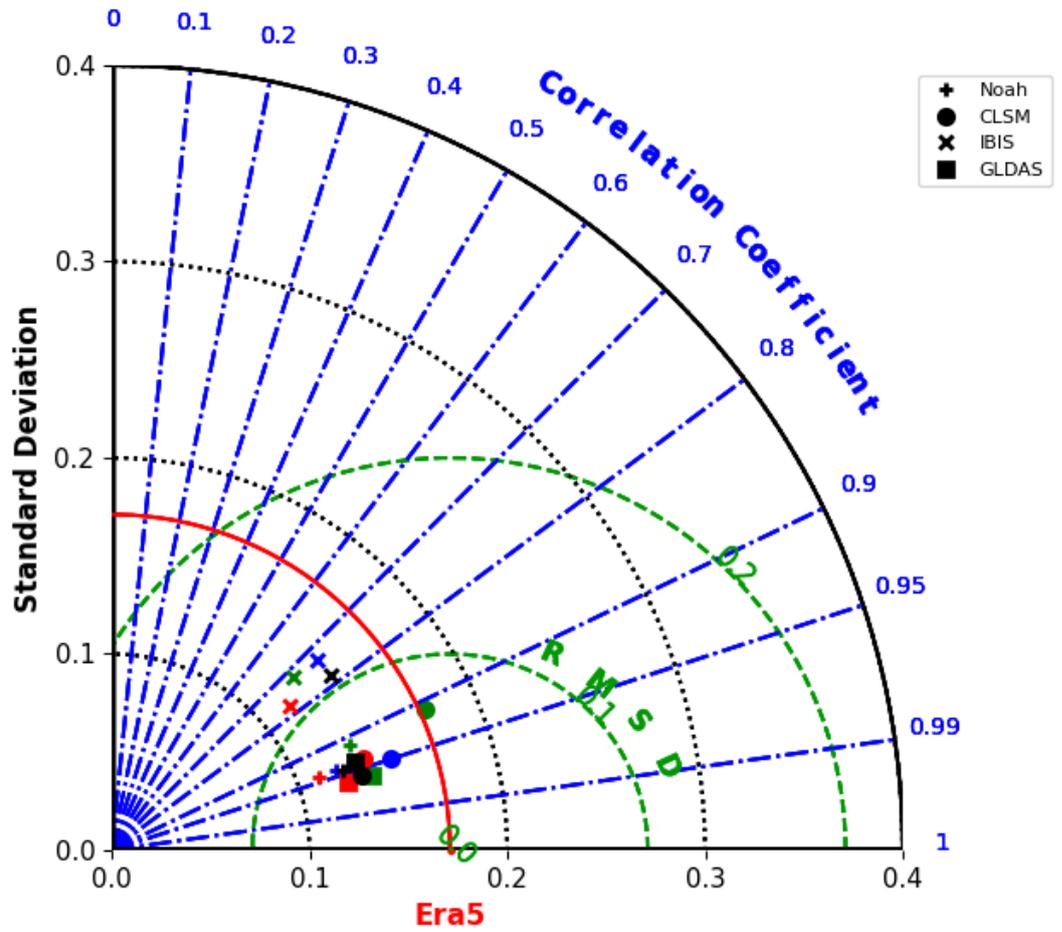
Fonte:Produção do autor.

Figura A.18 - Diagrama de Taylor - ERA-5 - Região AM.



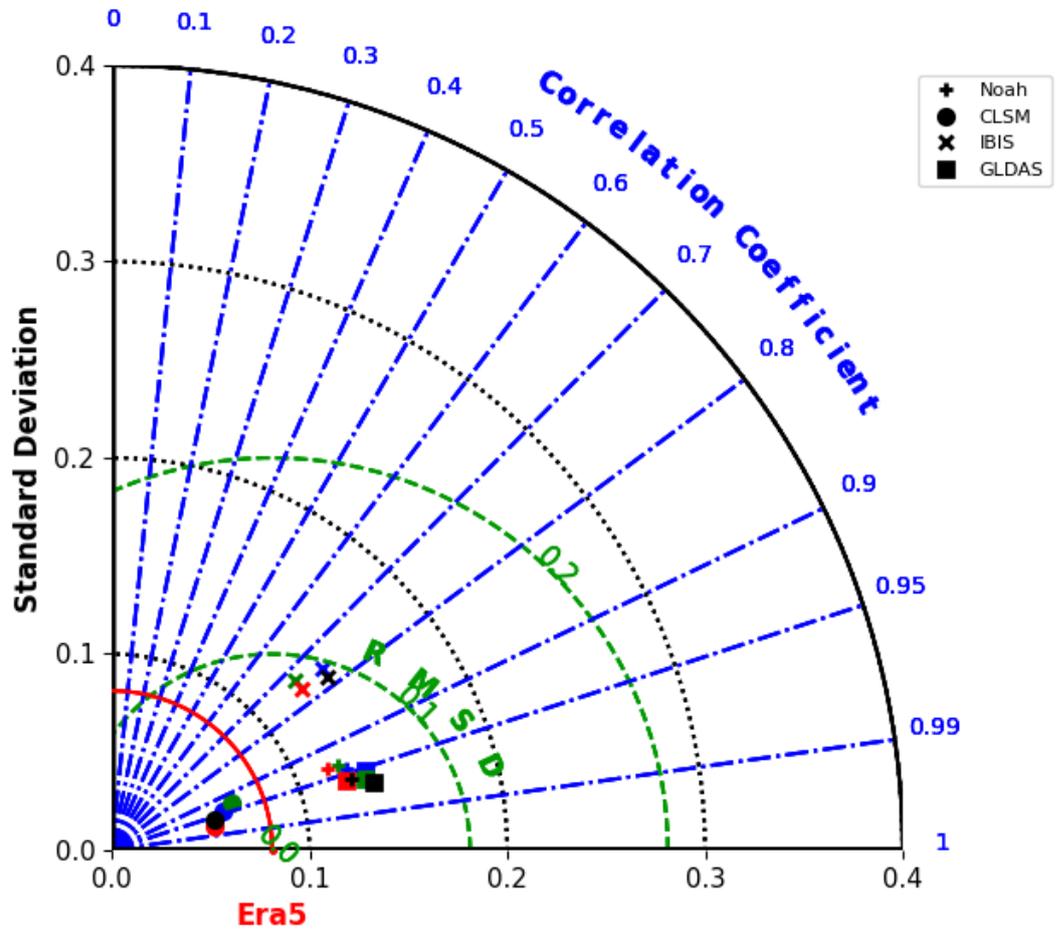
Fonte:Produção do autor.

Figura A.19 - Diagrama de Taylor - ERA-5 - Região SU.



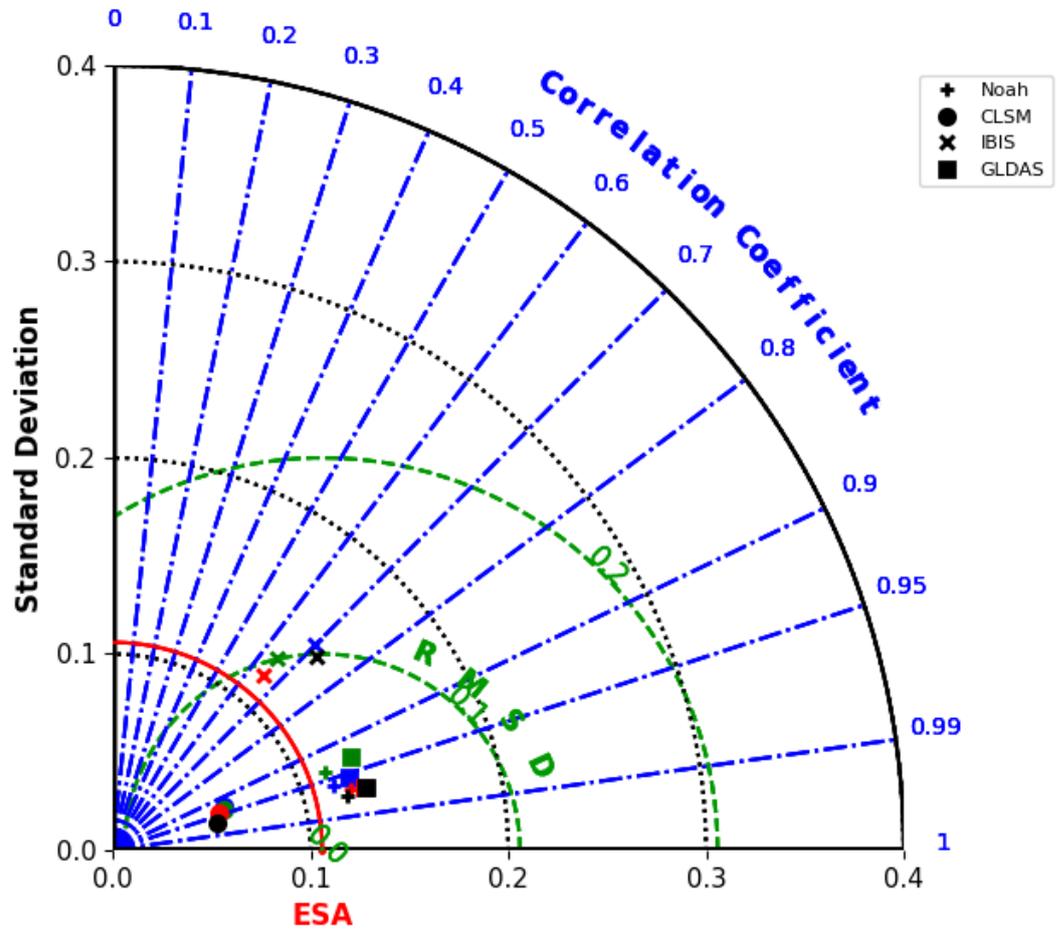
Fonte:Produção do autor.

Figura A.20 - Diagrama de Taylor - ERA-5 - Região PA.



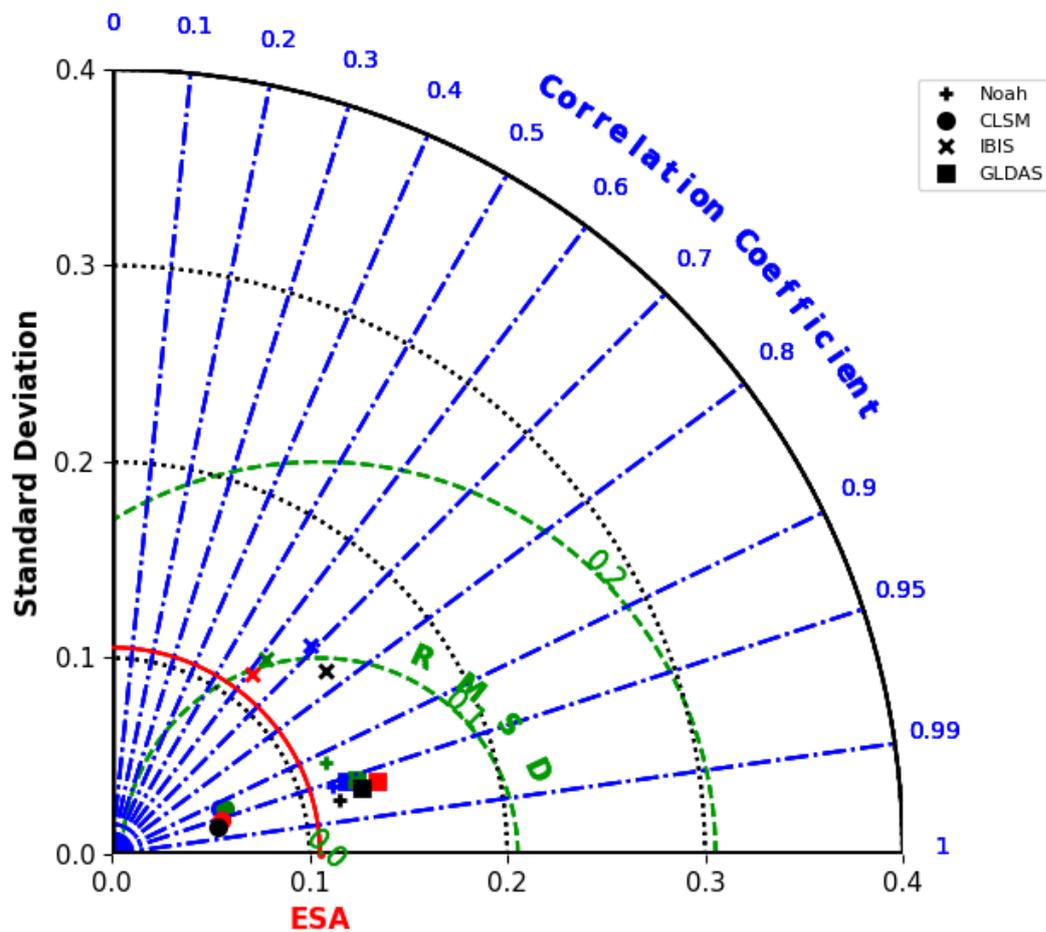
Fonte:Produção do autor.

Figura A.21 - Diagrama de Taylor - ESA-CCI - Região NE.



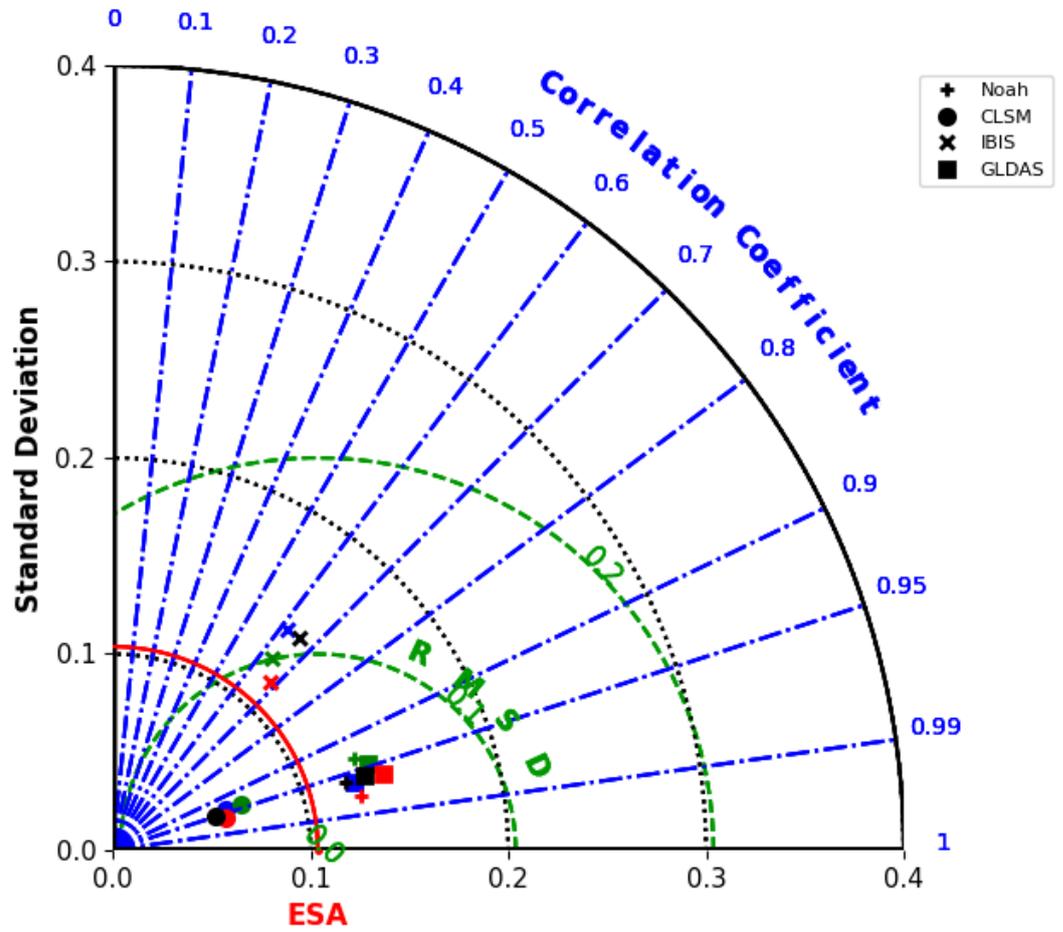
Fonte:Produção do autor.

Figura A.22 - Diagrama de Taylor - ESA-CCI - Região NO.



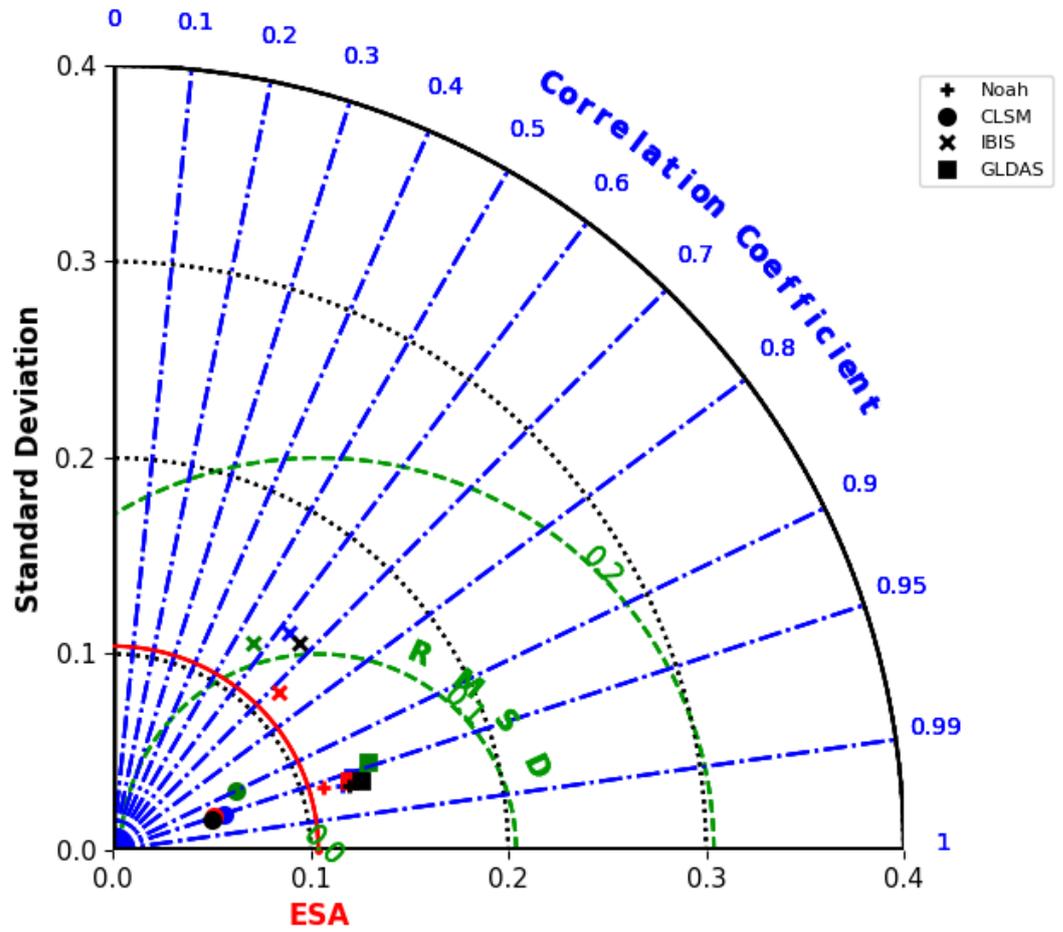
Fonte:Produção do autor.

Figura A.23 - Diagrama de Taylor - ESA-CCI - Região AM.



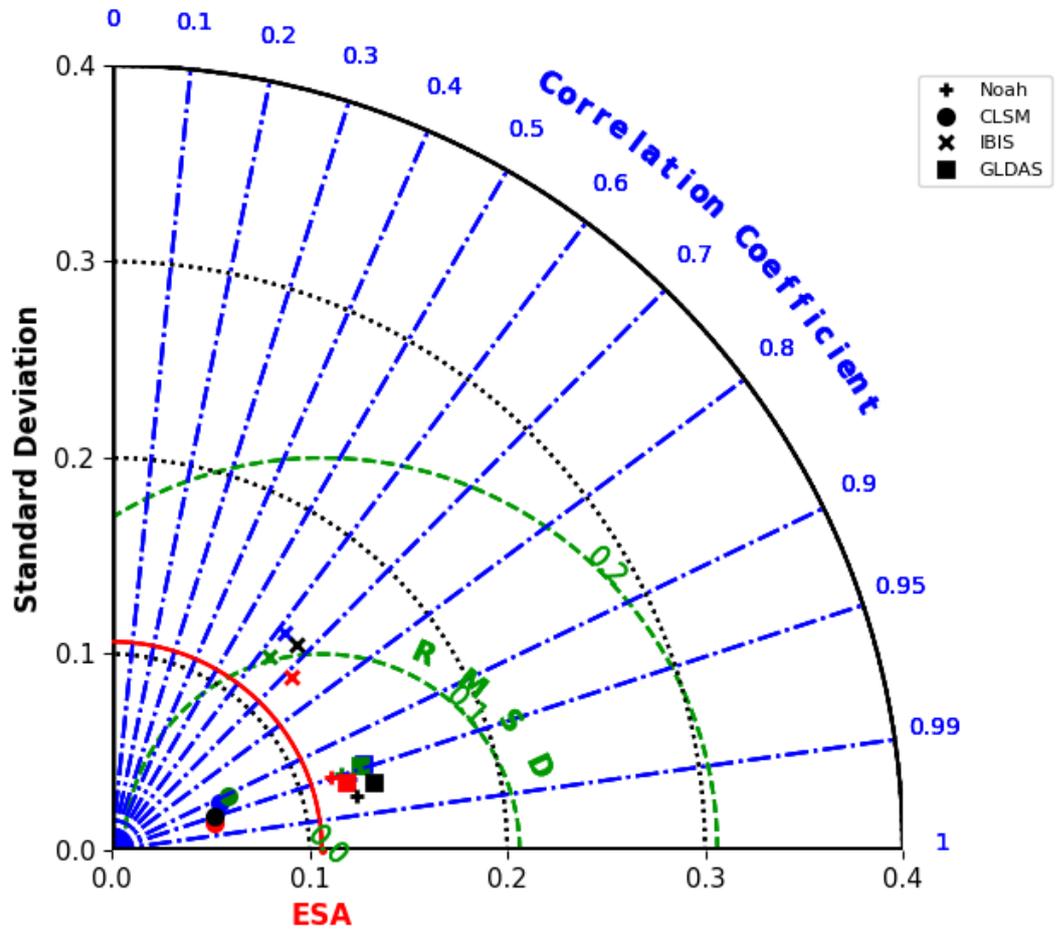
Fonte:Produção do autor.

Figura A.24 - Diagrama de Taylor - ESA-CCI - Região SU.



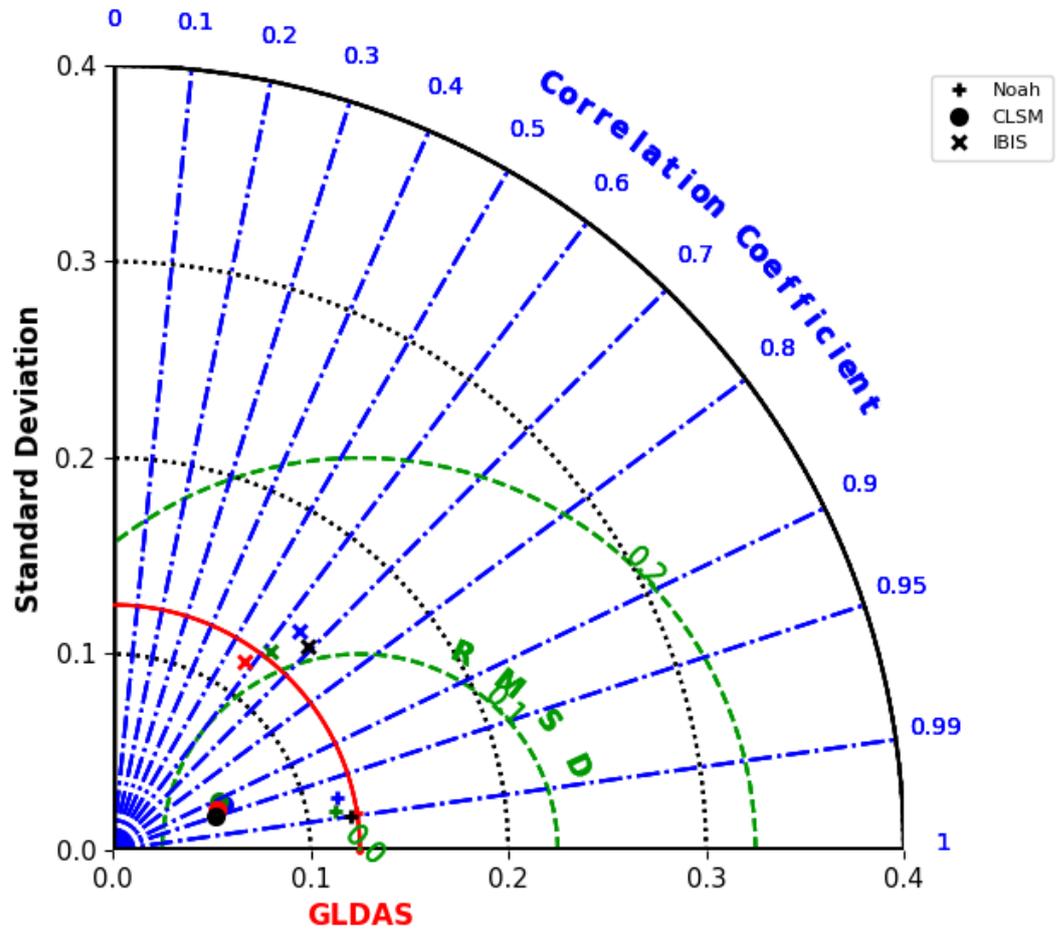
Fonte:Produção do autor.

Figura A.25 - Diagrama de Taylor - ESA-CCI - Região PA.



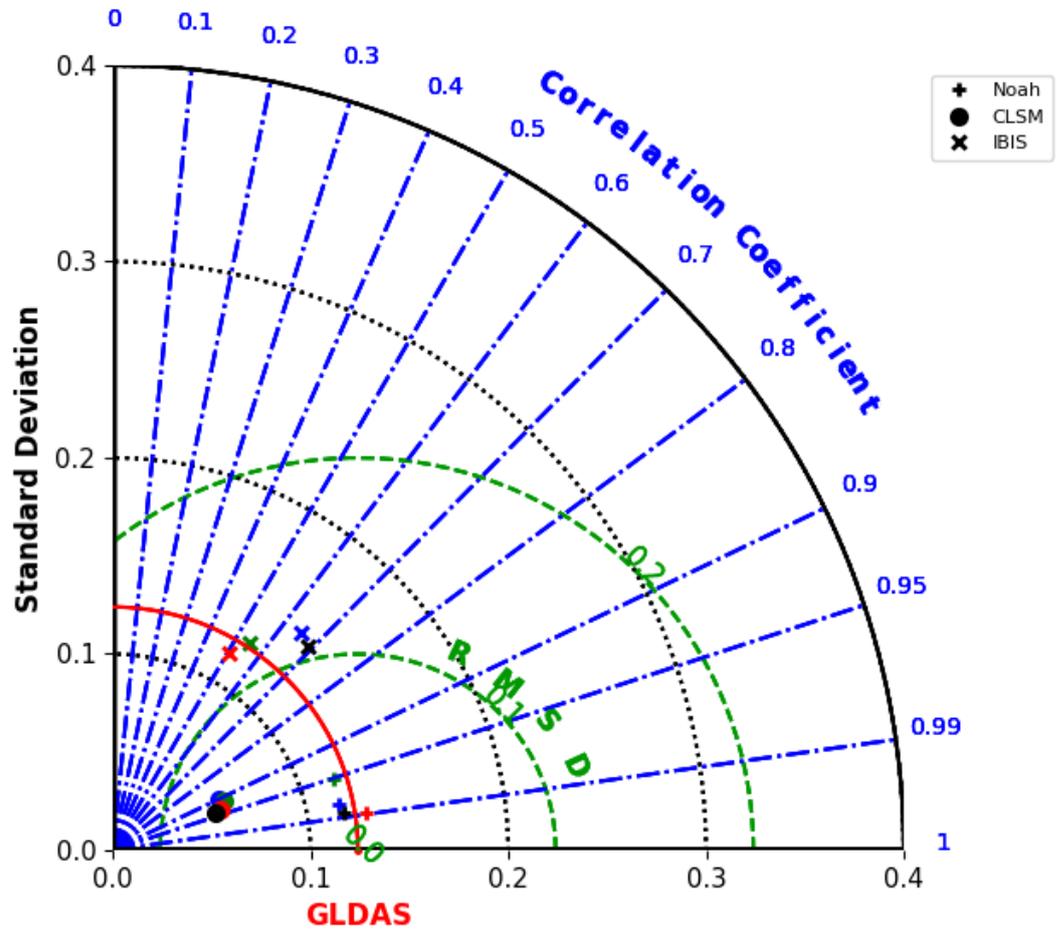
Fonte:Produção do autor.

Figura A.26 - Diagrama de Taylor - GLDAS- Região NE.



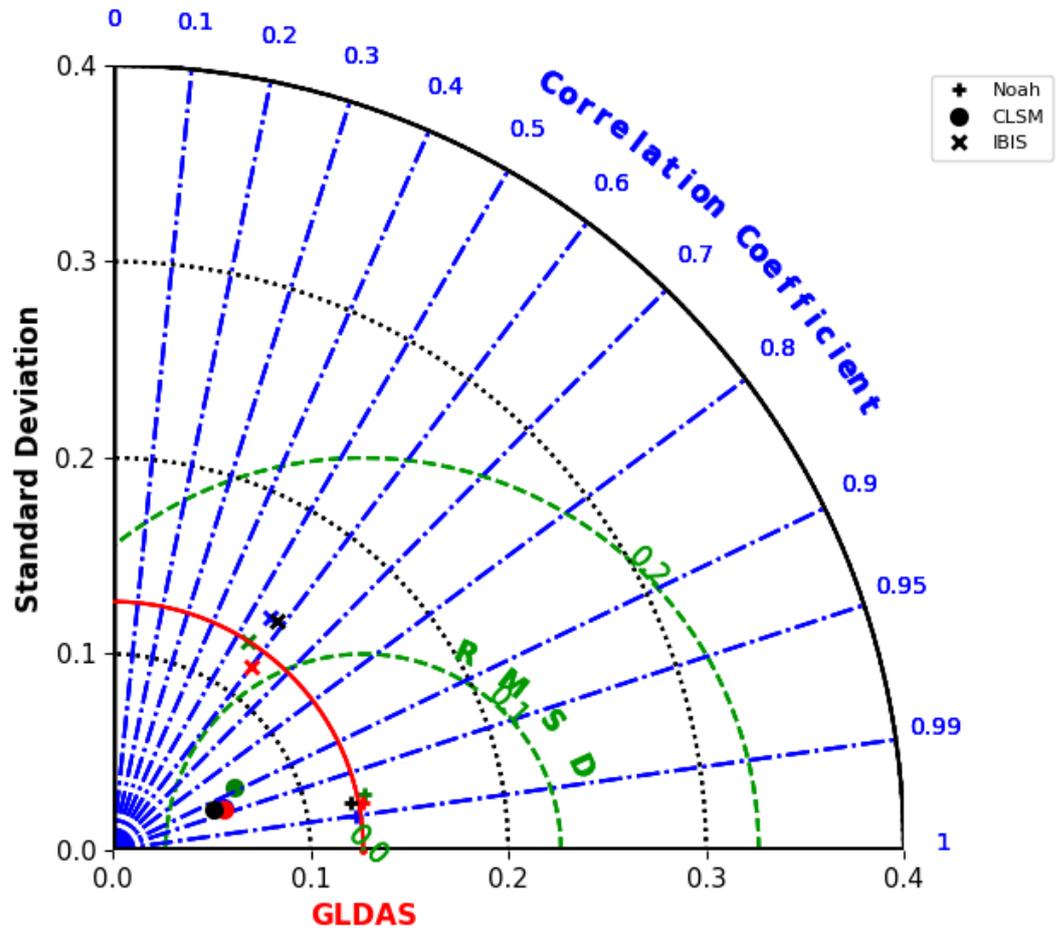
Fonte:Produção do autor.

Figura A.27 - Diagrama de Taylor - GLDAS- Região NO.



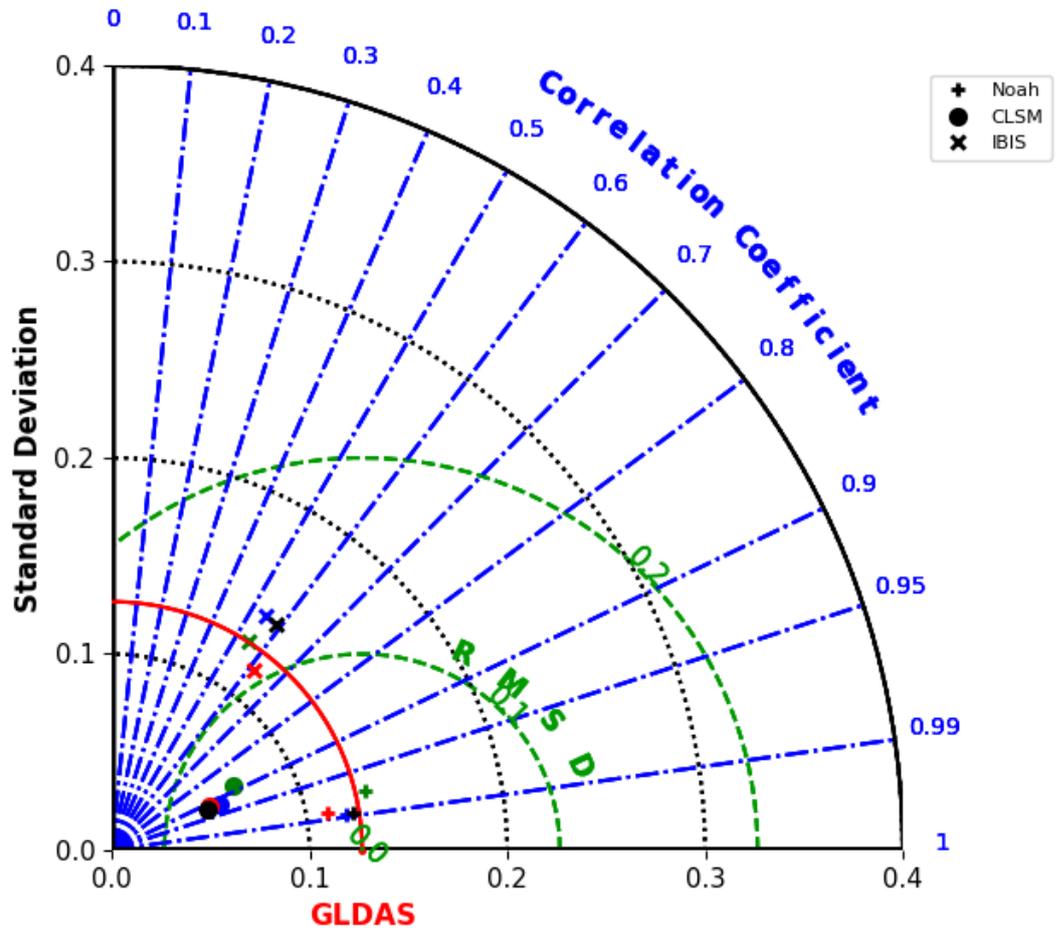
Fonte:Produção do autor.

Figura A.28 - Diagrama de Taylor - GLDAS- Região AM.



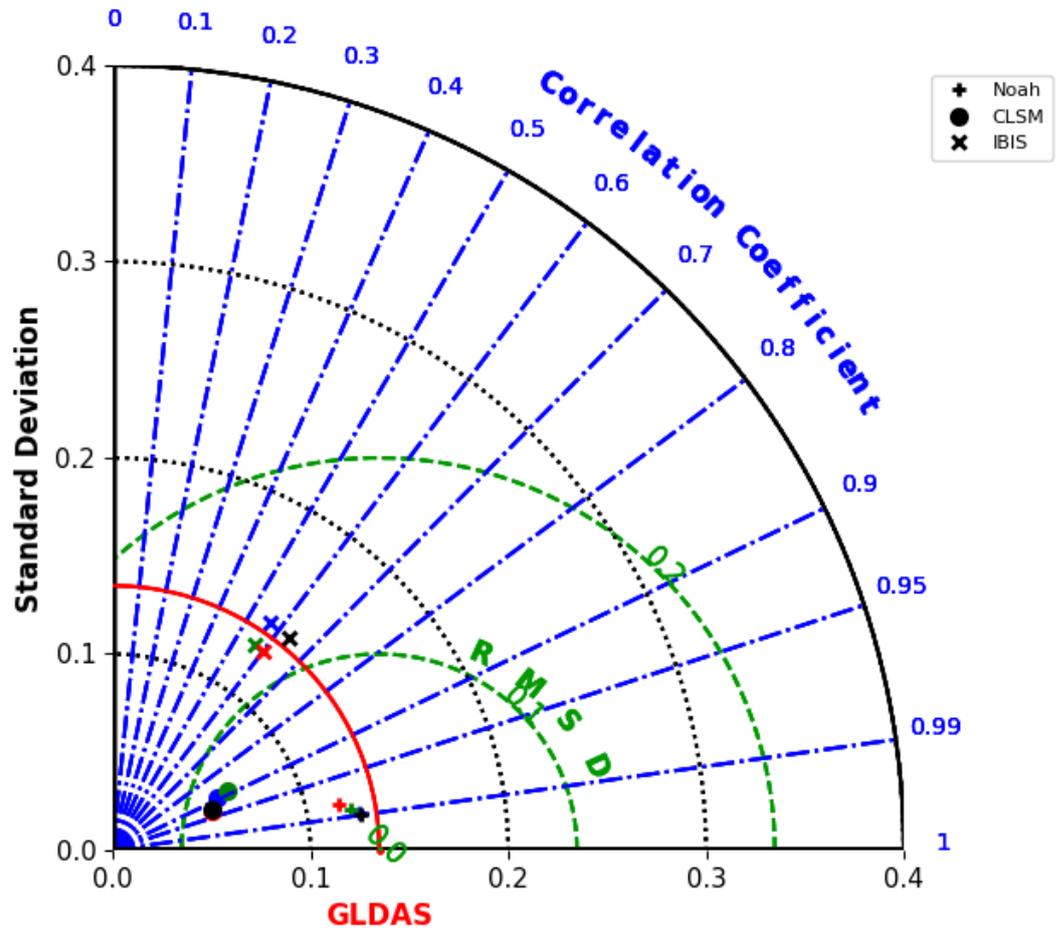
Fonte:Produção do autor.

Figura A.29 - Diagrama de Taylor - GLDAS- Região SU.



Fonte:Produção do autor.

Figura A.30 - Diagrama de Taylor - GLDAS- Região PA.



Fonte:Produção do autor.