



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

FELLIPE HENRIQUE BORBA ALVES

**MODELAGEM HIDROLÓGICA A PARTIR DA ASSIMILAÇÃO DE DADOS
GEOESPACIAIS E CORREÇÃO DE VIÉS EM PRECIPITAÇÕES ESTIMADAS POR
SENSORIAMENTO REMOTO**

Recife
2024

FELLIPE HENRIQUE BORBA ALVES

**MODELAGEM HIDROLÓGICA A PARTIR DA ASSIMILAÇÃO DE DADOS
GEOESPACIAIS E CORREÇÃO DE VIÉS EM PRECIPITAÇÕES ESTIMADAS POR
SENSORIAMENTO REMOTO**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutor em Engenharia Civil.

Área de concentração: Tecnologia Ambiental e Recursos Hídricos.

Orientador: Prof. Dr. José Almir Cirilo

Recife

2024

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Alves, Fellipe Henrique Borba.

Modelagem hidrológica a partir da assimilação de dados geoespaciais e correção de viés em precipitações estimadas por sensoriamento remoto / Fellipe Henrique Borba Alves. - Recife, 2024.

219f.: il.

Tese (Doutorado) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Engenharia Civil, 2024.

Orientação: José Almir Cirilo.

Inclui referências e anexos.

1. IMERG; 2. CHIRPS; 3. PERSIANN; 4. MapBiomas; 5. HEC-HMS.
I. Cirilo, José Almir. II. Título.

UFPE-Biblioteca Central

FELLIPE HENRIQUE BORBA ALVES

**MODELAGEM HIDROLÓGICA A PARTIR DA ASSIMILAÇÃO DE DADOS
GEOESPACIAIS E CORREÇÃO DE VIÉS EM PRECIPITAÇÕES
ESTIMADAS POR SENSORIAMENTO REMOTO**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para obtenção do título de Doutor em Engenharia Civil, Área de Tecnologia Ambiental e Recursos Hídricos.

Aprovada em 02/08/2024

Orientador: Prof. Dr. José Almir Cirilo – UFPE

BANCA EXAMINADORA

participação por videoconferência
Prof. Dr. Alfredo Ribeiro Neto (examinador interno)
Universidade Federal de Pernambuco

participação por videoconferência
Prof. Dr. Marcos Aurélio Vasconcelos de Freitas (examinador externo)
Universidade do Rio de Janeiro

participação por videoconferência
Prof. Dr. Saulo de Tarso Marques Bezerra (examinador externo)
Universidade Federal de Pernambuco

participação por videoconferência
Prof.^a Dr.^a Leidjane Maria Maciel de Oliveira (examinadora interna)
Universidade Federal de Pernambuco

participação por videoconferência
Prof. Dr. Anderson Luiz Ribeiro de Paiva (examinador interno)
Universidade Federal de Pernambuco

Dedico este trabalho à minha tia Elizabete Borba (*In memorian*) por, de forma adversa, ter ensinado sobre solitude e a importância de viver o presente.

E aos meus sobrinhos Guilherme, Rodrigo e Raquel para algum dia refletirem sobre as recompensas inestimáveis que o caminho da educação proporciona e nunca esquecerem que “hoje é o dia certo para amar, acreditar, fazer e principalmente viver”.

AGRADECIMENTOS

À minha mãe, **Izabel Cristina Borba**, pelo amor incondicional e pelos inesgotáveis exemplos de dedicação à estrutura familiar. Sou eternamente grato pelo seu esforço para me proporcionar uma vida melhor e contribuir na minha trajetória até aqui, pelo senso de responsabilidade e respeito, e por tanto ensinar sobre amor incondicional.

Ao meu pai, **Genival Alves** (*In memoriam*), por ter conseguido dar bons exemplos apesar de suas adversidades, pelas demonstrações de talento, por ter amado sua família durante toda vida e, mesmo depois de tanto tempo sem um abraço, ainda ajudar a compreender minhas forças e fraquezas.

Ao meu orientador acadêmico, o professor **Almir Cirilo**, por tanto ter ensinado sobre hidrologia e recursos hídricos, claro, mas principalmente por ensinar que a vida precisa ser simples e agradável, pois “o inimigo do bom é o ótimo”. Sou grato por me sentir acolhido como um filho, depois por poder perceber que todos os “*desorientados*” são uma família.

À minha mentora profissional, **Lorenzza Leite**, por ter ensinado sobre o serviço público com tanto zelo, por ensinar a cuidar da forma e do conteúdo, e que é importante deixar claro que “a cocada é de coco do coqueiro da praia”. Agradeço a formação profissional enquanto servidor público, por me proporcionar exercitar atributos como lógica, discernimento e sensatez. E por também sempre me acolher como um filho.

Aos contemporâneos de universidade, **Cristiane Ribeiro, Gabriel Oliveira, Livia Fragoso e Mayara Arruda** pelo companheirismo e por sempre proporcionar um ambiente acadêmico agradável e divertido. E um agradecimento extra a Livia pelo apoio computacional no desenvolvimento em Python.

Aos amigos, **Janaína Bráz, Josi Rodrigues, Raimundo Patriota e Vladimir Nascimento**, agradeço o companheirismo que transcende à vida profissional, pelos bons almoços e conversas acompanhadas de café, algumas cervejas, churrascos, *happy hours* e passeios de bicicleta.

Aos vários amigos que não ganharam agradecimentos expressos desta vez, acredito que seja porque já não nos vemos com tanta frequência. Registro que o carinho e afeto por todos continua o mesmo. Acredito que, em parte, a vida vai seguindo por caminhos e mudanças de rotina que inviabilizam a proximidade em muitas circunstâncias. Mas ao terminar esta que foi a última frase deste trabalho, espero poder revê-los e ser mais presente. Até breve!

Sempre acreditei que qualquer pessoa
pode ser um artista em seu ofício,
talvez porque a natureza da arte venha
menos do “o que” se faz
e mais do “como” se faz algo.

A lavadeira ensaboando as roupas no tanque,
o guarda de trânsito acenando para os carros,
a secretária batucando no teclado do computador.

Todos podem exercer suas atividades
com a mesma intensidade que caracteriza
o que chamamos de arte,
apenas pela maneira de se entregarem a elas. ¹

¹ COM A PALAVRA, ARNALDO ANTUNES. Direção: Marcelo Machado. Produção: Giovana Amano. Brasil: Tamanduá, 2018. Acesso on-line. Disponível em: https://tamandua.tv.br/filme/?name=com_a_palavra_arnaldo_antunes.

RESUMO

Produtos de sensoriamento remoto permitem obter características físicas e ambientais do planeta. Um conjunto desses produtos possui finalidade de estimar precipitações visando reduzir custos operacionais e fornecer séries históricas em áreas remotas. A acurácia de dados diários de precipitação estimada por sensoriamento remoto, disponíveis no período entre 1990 e 2020, foi analisada para cinco séries: CHIRPS 2.0, IMERG-F V06, PERSIANN CDR, PERSIANN CCS-CDR e PERSIANN PDIR. O método Delta foi aplicado para correção de viés em 15 bacias hidrográficas considerando duas abordagens ($BIAS_{PIXEL}$ e $BIAS_{AREA}$). A assimilação de dados geoespaciais foi aplicada para redução de parâmetros calibráveis do modelo computacional HEC-HMS em 10 bacias hidrográficas e 49 estações fluviométricas. A assimilação das séries de precipitação estimada e o processamento de dados por conjunto foram aplicados para obtenção de vazões em três bacias hidrográficas com características climáticas distintas. Os principais resultados indicaram que, após correção de viés, desvios relativos de 69% nas precipitações médias anuais e de 25% nas séries mensais foram reduzidos, respectivamente, para 1% e 5%. A assimilação de dados geoespaciais permitiu simulações satisfatórias ou boas em 75% das estações avaliando NSE, P_{BIAS} e RSR. A correção de viés nas precipitações CHIRPS e IMERG-F permitiu gerar vazões diárias com NSE de 0,64 e P_{BIAS} de -4%. O processamento de dados por conjunto resultou em vazões simuladas com NSE de 0,83, P_{BIAS} de 2,2% e RSR de 0,41 e qualidade superior às vazões obtidas com precipitação observada. Conclui-se que as séries de precipitação analisadas possuem acurácia distinta entre regiões de clima úmido e semiárido. A assimilação de dados geoespaciais reduziu a necessidade de calibração de parâmetros no HEC-HMS, calibrando-se apenas a vazão de base. A acurácia das simulações de vazões foi insatisfatória para as bacias litorâneas e satisfatória após a correção de viés em bacia de clima semiárido.

Palavras-chave: IMERG. CHIRPS. PERSIANN. MapBiomass. HEC-HMS.

ABSTRACT

Remote sensing products make it possible to obtain physical and environmental characteristics of the planet. A set of these products is intended to estimate precipitation in order to reduce operational costs and provide historical series in remote areas. The accuracy of daily precipitation data estimated by remote sensing, available in the period between 1990 and 2020, was analyzed for five series: CHIRPS 2.0, IMERG-F V06, PERSIANN CDR, PERSIANN CCS-CDR and PERSIANN PDIR. The Delta method was applied to correct bias in 15 river basins considering two approaches ($BIAS_{PIXEL}$ and $BIAS_{AREA}$). Geospatial data assimilation was applied to reduce calibratable parameters of the HEC-HMS computational model in 10 river basins and 49 fluviometric stations. The assimilation of estimated precipitation series and data processing per set were applied to obtain flows in three river basins with different climatic characteristics. The main results indicated that, after bias correction, relative deviations of 69% in the average annual precipitation and 25% in the monthly series were reduced to 1% and 5%, respectively. The assimilation of geospatial data allowed satisfactory or good simulations in 75% of the stations evaluating NSE, PBIAS and RSR. Bias correction in CHIRPS and IMERG-F precipitation allowed generating daily flows with NSE of 0.64 and PBIAS of -4%. Data processing by set resulted in simulated flows with NSE of 0.83, PBIAS of 2.2% and RSR of 0.41 and higher quality than flows obtained with observed precipitation. It is concluded that the analyzed precipitation series have different accuracy between regions with humid and semi-arid climates. The assimilation of geospatial data reduced the need for parameter calibration in the HEC-HMS, only calibrating the base flow. The accuracy of flow simulations was unsatisfactory for coastal basins and satisfactory after bias correction in basins with a semi-arid climate.

Keywords: IMERG. CHIRPS. PERSIANN. MapBiomas. HEC-HMS.

LISTA DE FIGURAS

Figura 1 – Imagens do satélite GOES-16 em 11-04-2021, às 18:00 GMT.....	28
Figura 2 – Número de estações por célula do produto GPCC de precipitação mensal com resolução de 100 km, (a) em 2012 e (b) em 2021.....	29
Figura 3 – Exemplo de produto IMERG-E.....	32
Figura 4 – Fluxo de processamento da base de dados CHIRPS.....	34
Figura 5 – Portal de acesso aos produtos PERSIANN.....	36
Figura 6 – Fluxo de processamento da base de dados PERSIANN-CCS.....	37
Figura 7 – Principais bandas SAR, faixas de frequência e comprimentos de onda. .	40
Figura 8 – Perfil vertical de precipitação sólida e líquida obtido através da missão GPM e observado em 02 de outubro de 2016 (Furacão Matthew).....	41
Figura 9 – Exemplos esquemático da composição dos planos PPI e CAPPI (a) e refletividade (b) do radar meteorológico Doppler.	43
Figura 10 – Ambiente de desenvolvimento Google Earth Engine.	48
Figura 11 – Biomas, áreas temáticas e fluxo de processamento simplificado MapBiomas.	50
Figura 12 – Infográfico da evolução anual da cobertura e uso da terra no Brasil a partir do MapBiomas.....	50
Figura 13 – Relação entre dados observados, assimilação de dados e simulações.	51
Figura 14 – Exemplo de resultados de processamento de dados por conjunto tipo <i>ensemble</i>	53
Figura 15 – Diferenças entre a separação da precipitação efetiva em modelos concentrados, semidistribuído e distribuídos.....	56
Figura 16 – Malha computacional de modelo hidrológico distribuído.....	58
Figura 17 – Esquema computacional do método quase-distribuído ModClark.	61
Figura 18 – Janela de edição e seleção de ferramentas do modelo hidrológico HEC-HMS.	63
Figura 19 – Esquema gráfico do balanço hídrico no modelo CAWM V.....	64
Figura 20 – Erros sistemáticos em função da latitude para a base de dados CHIRP e CHIRPS.....	66
Figura 21 – Variação de erros sistemáticos da base de dados CHIRP e CHIRPS por regiões e períodos trimestrais.	66
Figura 22 – Indicador de eficiência Kling-Gupta (KGE) para 26 séries de precipitação estimadas por sensoriamento remoto.	67

Figura 23 – Fluxo de processamento de ferramenta computacional GIS para inicialização rápida do modelo hidrológico HEC-HMS.....	68
Figura 24 – Modelagem hidrológica com diferentes bases de precipitação e valores de R^2 e NSE. (a) calibração (2003-2006) de períodos diários; (b) validação (2007-2010) de períodos diários; (c) calibração de períodos mensais e (d) validação de períodos mensais.	69
Figura 25 – Indicadores de Nash-Sutcliffe para vazões simuladas a partir de oito bases de precipitações derivadas de satélite. S – Satisfatório. G – Bom. VG – Muito bom.....	70
Figura 26 – Dados de vazão observada e simulada a partir de diferentes bases de dados de precipitações derivadas de satélite. Vazões simuladas com (a) dados de chuva observados, (b) TRMM-TMPA, (c) IMERG, (d) CHIRP e (e) PERSIANN.	71
Figura 27 – Esquema geral de análise de precipitações estimadas por sensoriamento remoto e modelagem hidrológica no SWAT para bacia hidrográfica na China.	72
Figura 28 – Esquema geral de processamento por conjunto de precipitações estimadas por sensoriamento remoto e modelagem hidrológica através de inteligência artificial.	73
Figura 29 - Fluxo geral de processamento de dados de precipitação, extração de parâmetros geoespaciais e modelagem hidrológica.....	74
Figura 30 – Área de estudo e unidades de planejamento hídrico avaliadas.	76
Figura 31 – Regiões climáticas do estado de Pernambuco e área de estudo.....	77
Figura 32 – Precipitações médias anuais em Pernambuco, entre os anos de 1977 e 2006.	78
Figura 33 – Rede de postos pluviométricos da Apac.	79
Figura 34 – Fluxo de processamento dos dados de precipitação de estações pluviométricas.....	81
Figura 35 – Fluxo de processamento de dados de precipitação da série CHIRPS 2.0.	82
Figura 36 – Configuração do <i>Model Builder</i> para conversão de arquivos NC4 em TIFF.	84
Figura 37 – Fluxo de processamento para correção de viés em séries de precipitação estimada por sensoriamento remoto.	85

Figura 38 – Evapotranspiração potencial anual sobre a área de estudo.....	89
Figura 39 – Postos fluviométricos e barragens monitoradas sobre a área de estudo.	90
Figura 40 – Uso e ocupação do solo a partir do MapBiomass e percentuais das classes.	94
Figura 41 – Linha de tendência das relações declividade x armazenamento na superfície.....	97
Figura 42 – Principais processos físicos de perdas de precipitação no balanço hídrico.	98
Figura 43 – Componentes do balanço hídrico no método de perdas de Déficit Constante.	98
Figura 44 – Classificação de solos. A) Classificação SiBCS e B) Classificação hidrológica.	100
Figura 45 – Relação Curve Number (CN) para a área de estudo na condição de umidade II.....	102
Figura 46 – Relação entre Curve Number (CN) nas condições de umidade I, II e III.	102
Figura 47 – Classificação de Água Disponível no Solo (AD) para a área de estudo.	103
Figura 48 – Fluxo de interação da vazão de base aos demais componentes do balanço hídrico adotados na modelagem do HEC-HMS.....	108
Figura 49 – Separação do escoamento direto, interfluxo e vazão de base em hidrogramas.	109
Figura 50 – Esquema geral de vertedouro tipo Creager.	112
Figura 51 – Exemplo de curva de descarga de vertedouro.....	113
Figura 52 – Exemplo de relação cota área e volume para reservatórios simulados.	114
Figura 53 – Principais parâmetros configurados para simulação de reservatórios e vertedouros simulados no HEC-HMS.....	114
Figura 54 – Resultado de processamento de precipitações diárias observadas em pluviômetros.	119
Figura 55 – Precipitação diária da base de dados CHIRPS 2.0. A) dia 17/06/2010 e B) dia 18/06/2010.....	120

Figura 56 - Precipitação diária da base de dados PERSIANN em 17 de junho de 2010.	121
Figura 57 - Precipitação diária da base de dados GPM, série IMERG-F V06.	122
Figura 58 – Bacias hidrográficas e mesorregiões de Pernambuco.	123
Figura 59 – Comparativo de precipitações anuais médias com dados CPRM (1977-2006) e APAC (1990-2020).	124
Figura 60 – Precipitação anual média observada em pluviômetros pela APAC e dos produtos de sensoriamento remoto CHIRPS, IMERG-F, CDR, CCS-CDR e PDIR.	125
Figura 61 – Desvio relativo entre a precipitação média anual observada em pluviômetros e nas séries CHIRPS, IMERG-F, CDR, CCS-CDR e PDIR.	125
Figura 62 – Desvio relativo entre a precipitação mensal média observada e a série CHIRPS.	127
Figura 63 – Desvio relativo entre a precipitação mensal média observada e a série IMERG-F	127
Figura 64 – Desvio relativo entre a precipitação mensal média observada e a série CDR.	128
Figura 65 – Desvio relativo entre a precipitação mensal média observada e a série CCSCDR	128
Figura 66 – Desvio relativo entre a precipitação mensal média observada e a série PDIR.	128
Figura 67 – Probabilidade de Detecção (POD) de eventos de precipitação diária nas séries estimadas por sensoriamento remoto analisadas.	131
Figura 68 – Taxa de Alarme Falso (FAR) de eventos de precipitação diária nas séries estimadas por sensoriamento remoto analisadas.	131
Figura 69 – Razão de Acurácia (AR) de eventos de precipitação diária nas séries estimadas por sensoriamento remoto analisadas.	131
Figura 70 – Coeficiente de Correlação (CC) de eventos de precipitação diária nas séries estimadas por sensoriamento remoto analisadas.	132
Figura 71 – Viés de Frequência (BIAS _f) de eventos de precipitação diária nas séries estimadas por sensoriamento remoto analisadas.	132
Figura 72 – Raiz do Erro Quadrático Médio (RMSE) de eventos de precipitação diária nas séries estimadas por sensoriamento remoto analisadas.	132

Figura 73 – Desvio relativo de precipitação anual média (DPA). (a) Séries de precipitações sem correção; (b) Correção por $BIAS_{PIXEL}$ e (c) Correção por $BIAS_{AREA}$	134
Figura 74 – Desvio relativo de precipitação mensal (DPM) da série CHIRPS original e após correção por $BIAS_{PIXEL}$ e $BIAS_{AREA}$	135
Figura 75 – Desvio relativo de precipitação mensal (DPM) da série IMERG original e após correção por $BIAS_{PIXEL}$ e $BIAS_{AREA}$	135
Figura 76 – Desvio relativo de precipitação mensal (DPM) das séries PERSIANN originais e após correção por $BIAS_{PIXEL}$ e $BIAS_{AREA}$	136
Figura 77 – Probabilidade de detecção (POD) de eventos de precipitação diária. .	139
Figura 78 – Gráfico de dispersão entre precipitações diárias observadas e estimadas por sensoriamento remoto na bacia do Sirinhaém, para as séries CHIRPS e IMERG sem correção, ajustadas por $BIAS_{PIXEL}$ e $BIAS_{AREA}$	140
Figura 79 – Gráfico de dispersão entre precipitações diárias observadas e estimadas por sensoriamento remoto na bacia do Una, para as séries CHIRPS e IMERG sem correção, ajustadas por $BIAS_{PIXEL}$ e $BIAS_{AREA}$	141
Figura 80 – Gráfico de dispersão entre precipitações diárias observadas e estimadas por sensoriamento remoto na bacia do Pajeú, para as séries CHIRPS e IMERG sem correção, ajustadas por $BIAS_{PIXEL}$ e $BIAS_{AREA}$	142
Figura 81 – Modelo digital do terreno (MDT) da base cartográfica PE3D sobre a área de estudo.....	145
Figura 82 – Bacias modeladas no HEC-HMS. A) Sub-bacias e B) Rede de drenagem.	146
Figura 83 – Armazenamento de água na cobertura vegetal a partir do MapBiomass.	148
Figura 84 – Armazenamento de água na superfície. A) Mapa de declividade, e B) Armazenamento de água na superfície em cada sub-bacia.....	149
Figura 85 – Armazenamento de água no solo.....	151
Figura 86 – Relação entre A) classificação textural dos solos e B) condutividade hidráulica saturada.	153
Figura 87 – Classificação de áreas impermeáveis.	154
Figura 88 – Bacias hidrográficas com vazões simuladas no HEC-HMS.	156
Figura 89 – Vazões diárias médias de longo termo na estação fluviométrica Engenho Mato Grosso, bacia do rio Sirinhaém.	157

Figura 90 – Performance geral do indicador NSE sobre vazões diárias médias simuladas no HEC-HMS.....	161
Figura 91 – Performance geral do indicador BIAS sobre vazões diárias médias simuladas no HEC-HMS.....	162
Figura 92 – Performance geral do indicador RSR sobre vazões diárias médias simuladas no HEC-HMS.....	163
Figura 93 – Vazões diárias médias de longo termo simuladas através dos modelos hidrológicos HEC-HMS e CAWM V para a bacia hidrográfica do rio Sirinhaém.	164
Figura 94 – Vazões diárias médias de longo termo simuladas através dos modelos hidrológicos HEC-HMS e CAWM V para a bacia hidrográfica do rio Una.	165
Figura 95 – Vazões diárias médias de longo termo geradas em cenários sem barragens e com principais existentes na bacia hidrográfica do rio Pajeú, estação fluviométrica Serra Talhada.	166
Figura 96 – Vazões diárias médias de longo termo geradas em cenários sem barragens e com principais existentes na bacia hidrográfica do rio Pajeú, estação fluviométrica Floresta.	167
Figura 97 – Vazões diárias médias de longo termo observadas e geradas para a bacia hidrográfica do rio Pajeú com séries de precipitação CHIRPS e IMERG-F.	168
Figura 98 – Vazões diárias médias de longo termo observadas e geradas para a bacia hidrográfica do rio Pajeú com séries de precipitação CHIRPS ajustadas por $BIAS_{AREA}$	170
Figura 99 – Vazões diárias médias de longo termo geradas com precipitações estimadas por sensoriamento remoto sem correção de BIAS, e com ajuste por $BIAS_{PIXEL}$ e $BIAS_{AREA}$, na bacia do rio Sirinhaém.	171
Figura 100 – Vazões diárias médias de longo termo geradas com precipitações estimadas por sensoriamento remoto sem correção de BIAS, e com ajuste por $BIAS_{PIXEL}$ e $BIAS_{AREA}$, na bacia do rio Una.....	172
Figura 101 – Vazões diárias médias de longo termo geradas com precipitações estimadas por sensoriamento remoto sem correção de BIAS, e com ajuste por $BIAS_{PIXEL}$ e $BIAS_{AREA}$, na bacia do rio Pajeú.	173

Figura 102 – Percentuais de vazões adotados no processamento de dados por conjunto ensemble nas bacias hidrográficas do Sirinhaém, Una e Pajeú.	178
Figura 103 – Percentuais de vazões adotados no processamento de dados por conjunto ensemble na bacia hidrográfica do Pajeú.	180
Figura 104 – Amplitude de vazões diárias médias de longo termo calculadas com precipitações estimadas por sensoriamento remoto, vazão média observada e vazão corrigida por ensemble na bacia hidrográfica do rio Sirinhaém, estação fluviométrica Engenho Mato Grosso.	181
Figura 105 – Amplitude de vazões diárias médias de longo termo calculadas com precipitações estimadas por sensoriamento remoto, vazão média observada e vazão corrigida por ensemble na bacia hidrográfica do rio Una, estação fluviométrica Barreiros.	181
Figura 106 – Amplitude de vazões diárias médias de longo termo calculadas com precipitações estimadas por sensoriamento remoto, vazão média observada e vazão corrigida por ensemble na bacia hidrográfica do rio Pajeú, estação fluviométrica Floresta.	182

LISTA DE TABELAS

Tabela 1 – Características técnicas dos produtos PERSIANN.....	38
Tabela 2 – Frequência, comprimento de onda e principais aplicações das bandas imageadas por radar.	40
Tabela 3 – Classes e identificadores do MapBiomass Coleção 8.....	49
Tabela 4 – Exemplos de modelos hidrológicos, autores e ano de publicação.	57
Tabela 5 – Características técnicas dos produtos do Pernambuco Tridimensional. .	92
Tabela 6 – Classes MapBiomass e relação de armazenamento de água na cobertura vegetal.....	95
Tabela 7 – Armazenamento de precipitação na cobertura vegetal em função do porte da vegetação.....	96
Tabela 8 – Relações de declividades e armazenamento de água na superfície no modelo hidrológico HEC-HMS.....	96
Tabela 9 – Relação entre MapBiomass e Curve Number (CN II) para a classificação hidrológica dos solos.....	101
Tabela 10 – Relação entre classificação de textura dos solos e estimativa da condutividade hidráulica saturada.....	104
Tabela 11 – Performance geral dos indicadores estatísticos para simulações de vazão.	116
Tabela 12 – Precipitações médias mensais para as bacias hidrográficas estudadas.	126
Tabela 13 – Indicadores de performance para precipitações diárias estimadas por sensoriamento remoto, na bacia do Sirinhaém, para as séries sem correção, ajustadas por $BIAS_{PIXEL}$ e $BIAS_{AREA}$	138
Tabela 14 – Indicadores de performance para precipitações diárias estimadas por sensoriamento remoto, na bacia do Pajeú, para as séries sem correção, ajustadas por $BIAS_{PIXEL}$ e $BIAS_{AREA}$	138
Tabela 15 – Áreas totais, sub-bacias e rede de drenagem das bacias hidrográficas simuladas.	147
Tabela 16 – Textura dos solos, condutividade hidráulica saturada teórica e ajustada.	152
Tabela 17 – Indicadores de desempenho sobre séries de vazões simuladas no HEC-HMS.	159

Tabela 18 – Indicadores de performance para vazões geradas com precipitações estimadas por sensoriamento remoto com e sem métodos de correção de viés (BIAS).	169
Tabela 19 – Coeficientes de ponderação aplicados às séries vazões geradas com precipitações estimadas por sensoriamento remoto no processamento por conjunto.	176
Tabela 20 – Coeficientes de ajuste mensal aplicados à correção de viés em vazões geradas com precipitações estimadas por sensoriamento remoto.	176
Tabela 21 – Coeficientes de ajuste de magnitude aplicados à correção de viés em vazões geradas com precipitações estimadas por sensoriamento remoto.	177
Tabela 22 – Indicadores de desempenho sobre séries de vazões calculadas a partir de processamento por conjunto ensemble.	179

LISTA DE ABREVIATURAS E SIGLAS

ASCII – American Standard Code for Information Interchange
ANA – Agência Nacional de Águas e Saneamento Básico
Apac – Agência Pernambucana de Águas e Clima
API – *Application Programming Interface*
AR – Taxa de Acurácia
BIAS_f – Viés de Frequência
CAPPI – Indicador de Plano Posicional de Altitude Constante
CAWM – *Campus Agreste Watershed Model*
CCD – Clod Cloud Duration
CCS – *Cloud Classification System*
CDR – *Climate Data Record*
CHC – *Climate Hazards Center*
CHIRP – *Climate Hazards Group Infrared Precipitation*
CHIRPS – *Climate Hazards Group Infrared Precipitation with Stations*
CHRS – Center for Hydrometeorology and Remote Sensing
CEMADEN – Centro Nacional de Monitoramento e Alertas de Desastres Naturais
CN – *Curve Number*
CSV – *Character-Separated Values*
DPR – *Dual-Frequency Precipitation Radar*
DSS – *Data Storage System*
ETP – Evapotranspiração Potencial
FAR – Taxa de Alarme Falso
GEE – *Google Earth Engine*
GeoTIFF – *Georeferenced Tagged Image File Format*
GIOVANNI – *Geospatial Interactive Online Visualization and Analysis Infrastructure*
GOES – *Geostationary Operational Environmental Satellite*
GPCC – *Global Precipitation Climatology Center*
GPCP – *Global Precipitation Climatology Project*
GPM – *Global Precipitation Measurement*
HEC – *Hydrologic Engineering Center*
HMS – *Hydrologic Modeling System*
IDE – Ambiente de Desenvolvimento Interativo

IDW – *Inverse Distance Weighting*

IMERG – *Integrated Multi-Satellite Retrievals for GPM*

INMET – Instituto Nacional de Meteorologia

INPE – Instituto Nacional de Pesquisas Espaciais

JAXA – *Japan Aerospace Exploration Agency*

MDT – Modelo Digital do Terreno

NASA – *National Aeronautics and Space Administration*

NetCDF – *Network Common Data Form*

NOAA – *National Oceanic and Atmospheric Administration*

NEXRAD – *Next-Generation Radar*

NSE – Eficiência de Nash-Sutcliffe

OMM – Organização Meteorológica Mundial

PDIR – *Dynamic Infrared Rain Rate Near real-time*

PE3D – Programa Pernambuco Tridimensional

PERSIANN – *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks*

PMW – Micro-onda passiva

POD – Probabilidade de Detecção

PPI – Indicador de Plano Posicional

PR – Precipitação por Radar

RADAR – *RAdio Detecting And Ranging*

RMSE – Raiz do Erro Quadrático Médio

SAR – Radar de Abertura Sintética

SCS – *Soil Conservation Service*

SEBAL – *Surface Energy Balance Algorithm for Land*

SiBCS – Sistema Brasileiro de Classificação de Solos

SRTM – *Shuttle Radar Topography Mission*

TIR – Infravermelho Termal

TRMM – *Tropical Rainfall Measuring Mission*

TMPA – *Multisatellite Precipitation Analysis*

UP – Unidade de Planejamento Hídrico

USDA – *United States Department of Agriculture*

USGS – *United States Geological Survey*

USACE – *United States Army Corps of Engineers*

SUMÁRIO

1	INTRODUÇÃO	23
1.1	HIPÓTESE	25
1.2	OBJETIVOS GERAIS	25
1.3	OBJETIVOS ESPECÍFICOS	26
2	REFERENCIAL TEÓRICO	26
2.1	ESTIMATIVAS DE PRECIPITAÇÃO POR SENSORIAMENTO REMOTO...	26
2.1.1	Global Precipitation Climatology Centre (GPCC)	28
2.1.2	<i>Tropical Rainfall Measuring Mission</i> (TRMM)	30
2.1.3	Global Precipitation Measurement (GPM)	31
2.1.4	Hidroestimador	32
2.2	ESTIMATIVA DE PRECIPITAÇÃO COM INFRAVERMELHO E ESTAÇÕES PLUVIOMÉTRICAS (CHIRPS)	33
2.3	ESTIMATIVA DE PRECIPITAÇÃO A PARTIR DE SENSORIAMENTO REMOTO E REDES NEURAIS ARTIFICIAIS (PERSIANN)	35
2.4	ESTIMATIVAS DE PRECIPITAÇÃO POR RADAR	39
2.4.1	Radar de abertura sintética	39
2.4.2	Radar meteorológico doppler	42
2.5	AQUISIÇÃO, ASSIMILAÇÃO E PROCESSAMENTO DE DADOS GEOESPACIAIS.....	45
2.5.1	Dados abertos	45
2.5.2	Plataforma GIOVANNI (Geospatial Interactive Online Visualization and Analysis Infrastructure)	46
2.5.3	Plataforma Google Earth Engine (GEE)	47
2.5.4	O Projeto MapBiomass.....	48
2.5.5	Assimilação de dados.....	51
2.5.6	Método de processamento de dados por conjunto (<i>Ensemble</i>).....	52
2.6	MODELOS HIDROLÓGICOS.....	55

2.6.1	Conceitos gerais	55
2.6.2	Modelagem hidrológica quase-distribuída	58
2.6.3	Modelo hidrológico HEC-HMS	61
2.6.4	Modelo hidrológico CAWM V	63
2.7	TRABALHOS CORRELATOS	65
3	MATERIAIS E MÉTODOS	74
3.1	ÁREA DE ESTUDO	75
3.1.1	Unidades de planejamento hídrico	75
3.1.2	Clima	76
3.1.3	Precipitações	78
3.2	BASES DE DADOS DE PRECIPITAÇÃO E GEOPROCESSAMENTO	79
3.2.1	Precipitação de estações pluviométricas	79
3.2.2	Precipitação CHIRPS	82
3.2.3	Precipitação PERSIANN.....	83
3.2.4	Precipitação IMERG	83
3.3	CORREÇÃO DE VIÉS (<i>BIAS</i>) EM PRECIPITAÇÕES ESTIMADAS POR SENSORIAMENTO REMOTO	84
3.4	INDICADORES DE EFICIÊNCIA APLICADOS AOS DADOS DE PRECIPITAÇÃO	86
3.5	EVAPOTRANSPIRAÇÃO POTENCIAL.....	89
3.6	VAZÕES OBSERVADAS E RESERVATÓRIOS MONITORADOS	90
3.7	PERNAMBUCO TRIDIMENSIONAL E MODELO DIGITAL DO TERRENO .	91
3.8	DELIMITAÇÃO DE SUB-BACIAS E REDE DE DRENAGEM.....	93
3.9	USO E OCUPAÇÃO DO SOLO – MAPBIOMAS	93
3.10	CARACTERIZAÇÃO DA COBERTURA VEGETAL.....	94
3.11	CARACTERIZAÇÃO DO ARMAZENAMENTO DE ÁGUA NA SUPERFÍCIE	96
3.12	CARACTERIZAÇÃO DE PERDAS – MÉTODO DÉFICIT CONSTANTE	97

3.12.1	Déficit inicial (<i>Inicial Deficit</i>)	99
3.12.2	Déficit máximo (<i>Maximum Deficit</i>)	99
3.12.3	Taxa de infiltração (Constant rate).....	104
3.12.4	Áreas impermeáveis (Impervious)	105
3.13	MÉTODO DE TRANSFORMAÇÃO CHUVA x VAZÃO	105
3.13.1	Método ModClark	105
3.13.2	Tempo de concentração e tempo de armazenamento	107
3.14	VAZÃO DE BASE	107
3.15	PROPAGAÇÃO DE VAZÃO NO CANAL DO RIO	109
3.16	OPERAÇÃO DE RESERVATÓRIOS.....	111
3.17	INDICADORES DE EFICIÊNCIA APLICADOS ÀS SIMULAÇÕES HIDROLÓGICAS	115
3.18	CORREÇÃO DE VIÉS EM VAZÕES GERADAS COM PRECIPITAÇÕES ESTIMADAS POR SENSORIAMENTO REMOTO	117
4	RESULTADOS E DISCUSSÕES	118
4.1	ACURÁCIA DE PRECIPITAÇÕES ESTIMADAS POR SENSORIAMENTO REMOTO	118
4.1.1	Geoprocessamento de dados de precipitação	118
4.1.2	Acurácia das precipitações anuais médias estimadas por sensoriamento remoto	123
4.1.3	Acurácia das precipitações mensais médias estimadas por sensoriamento remoto	126
4.1.4	Acurácia de precipitações diárias estimadas por sensoriamento remoto ...	129
4.2	CORREÇÃO DE VIÉS EM PRECIPITAÇÕES ESTIMADAS POR SENSORIAMENTO REMOTO	133
4.2.1	Acurácia de precipitações médias anuais estimadas por sensoriamento remoto após correção de viés (BIAS)	133
4.2.2	Acurácia de precipitações médias mensais estimadas por sensoriamento remoto após correção de viés (BIAS)	134

4.2.3	Acurácia de precipitações diárias estimadas por sensoriamento remoto após correção de viés (BIAS)	137
4.3	PROCESSAMENTO E ASSIMILAÇÃO DE BASES DE DADOS GEOESPACIAIS.....	145
4.3.1	Modelo digital do terreno e delimitação de sub-bacias	145
4.3.2	Armazenamento de água na cobertura vegetal	147
4.3.3	Armazenamento de água na superfície	148
4.3.4	Armazenamento máximo de água no solo	150
4.3.5	Taxa de infiltração	151
4.3.6	Áreas impermeáveis	153
4.4	MODELAGEM HIDROLÓGICA A PARTIR DA INICIALIZAÇÃO RÁPIDA DO HEC-HMS	155
4.5	AVALIAÇÃO DE DESEMPENHO EM MODELO HIDROLÓGICO CONCENTRADO E SEMIDISTRIBUÍDO	164
4.6	INFLUÊNCIA DA OPERAÇÃO DE RESERVATÓRIOS NAS SIMULAÇÕES HIDROLÓGICAS	166
4.7	MODELAGEM HIDROLÓGICA A PARTIR DE PRECIPITAÇÕES ESTIMADAS POR SENSORIAMENTO REMOTO	167
4.8	CORREÇÃO DE VIÉS EM VAZÕES CALCULADAS A PARTIR DE PRECIPITAÇÕES ESTIMADAS POR SENSORIAMENTO REMOTO	175
5	CONCLUSÕES	183
6	RECOMENDAÇÕES E TRABALHOS FUTUROS.....	185
	REFERÊNCIAS.....	186
	ANEXO A – Relação de estações pluviométricas Apac	203
	ANEXO B – Script Python para preparação de arquivos de chuva diária	204
	ANEXO C – Relação de estações fluviométricas Hidroweb em Pernambuco.....	205
	ANEXO D – Relação de barragens inseridas no modelo hidrológico HEC-HMS	206
	ANEXO E – Vazões diárias médias observadas e simuladas no HEC-HMS.	207

1 INTRODUÇÃO

A observação, registro e monitoramento de grandezas físicas globais é um desafio científico relevante para aprimorar a compreensão dos efeitos das mudanças climáticas, incluindo as alterações nos padrões hidrometeorológicos (Dore, 2005; Guillod *et al.*, 2018). Satélites meteorológicos e ambientais tornaram-se ferramentas indispensáveis para caracterização do meio físico, principalmente ao considerar o monitoramento dos processos hidrológicos (Schmugge *et al.*, 2002).

Os produtos de sensoriamento remoto podem fornecer registros globais altimétricos (Yang *et al.*, 2022a), umidade do solo (Wakigari; Leconte, 2023), temperatura da superfície da terra (Hooker *et al.*, 2018), estimativas de precipitações (Siena *et al.*, 2023) ou a classificação do uso e ocupação do solo (Zhang, 2022a). A variedade e sofisticação dos dados disponíveis têm possibilitado mudanças na forma de processar e analisar informações espaciais, a exemplo das séries históricas de precipitação e vazão (Alquraish; Khadr, 2021; Dastour; Hassan, 2023).

A precipitação é comumente medida por estações meteorológicas convencionais que registram informações pontuais na superfície. No entanto, essas estações são escassas, especialmente em áreas rurais e remotas, ou não possuem séries contínuas em um período suficientemente longo. Além disso, a precipitação apresenta uma grande variabilidade espacial e temporal, tornando a sua medição uma tarefa que demanda gestão e logística para manutenções periódicas e despesas contínuas (Bayat *et al.*, 2019). Para superar essas limitações, a precipitação estimada com base em produtos de sensoriamento remoto surge como uma alternativa viável (Hong *et al.*, 2018).

Os produtos de precipitação estimada por sensoriamento remoto são gerados por processamentos de imagens de satélite e algoritmos que correlacionam características das nuvens e do ambiente para quantificar a precipitação. Esses produtos apresentam a vantagem de cobrir grandes áreas com alta resolução temporal, fornecendo uma visão abrangente da precipitação em tempo quase real (Huang *et al.*, 2021). No entanto, os produtos de precipitação estimada por satélite possuem limitações, incluindo erros sistemáticos e viés, comumente conhecido como BIAS (Dubovik *et al.*, 2021).

O viés é um erro sistemático na estimativa da precipitação que pode levar a erros significativos nas simulações dos processos hidrológicos. O viés pode ocorrer

devido aos padrões dos algoritmos, condições específicas da atmosfera, bem como diferentes fontes de incerteza associadas aos dados de entrada (Chen *et al.*, 2021). A correção do viés é, portanto, uma etapa crucial na melhoria da qualidade da modelagem hidrológica baseada em produtos de precipitação estimada por satélite (Hashemi *et al.*, 2017).

Entre as técnicas para correções de viés estão os métodos de correlação a partir de dados de precipitação observados em estações meteorológicas com a finalidade de criar uma relação linear entre a precipitação medida e a precipitação estimada pelo satélite (Fang *et al.*, 2017), métodos de pós-processamento estatístico que utilizam técnicas estatísticas, como a análise de regressão, para identificar as variáveis que afetam o desempenho do sensor de satélite (Zhang *et al.*, 2023) e a técnica de assimilação de dados que combina as estimativas de precipitação por satélite com dados de observação de precipitação de estações meteorológicas para ajustar o viés (Prakash; Bhan, 2023).

A assimilação de dados é uma técnica promissora para melhorar a qualidade das previsões hidrológicas ao incorporar observações de campo e correções de viés em modelos hidrológicos. A técnica é particularmente útil para previsões de curto prazo, onde as observações de campo podem ser incorporadas rapidamente para melhorar as previsões. Os métodos de assimilação de dados não se limitam a correção de viés de precipitação e podem agregar qualidade à caracterização física das bacias hidrográficas a partir da discretização de parâmetros associados a cobertura vegetal, relevo ou uso e ocupação do solo (Calvet *et al.*, 2019; Huang *et al.*, 2019).

A assimilação de dados de precipitação estimada por satélite para obtenção do escoamento superficial torna-se um desafio ainda maior. Alguns trabalhos aplicam essas precipitações para representação dos processos hidrológicos e a qualidade dos resultados indicam variações significativas entre as localidades, técnicas utilizadas ou base de dados de entrada considerados (Shen *et al.*, 2020; Xiang *et al.*, 2021).

Conhecendo as imprecisões das estimativas de precipitação por satélite e a existência de padrões de erros distribuídos ao longo do tempo e do espaço (Li *et al.*, 2021), diversos conjuntos de algoritmos deram origem a produtos de precipitação estimada por satélite com a finalidade de representar padrões distintos de fenômenos hidrológicos.

Uma coleção de dados de precipitação estimada por satélite pode estar associada a representação com maior qualidade dos períodos secos (Zhong *et al.*, 2019), a identificação de eventos extremos (Hinge *et al.*, 2022), melhor resolução espacial (Yu *et al.*, 2022) ou menor latência entre a ocorrência do evento e geração do conjunto de dados (Pfreundschuh *et al.*, 2022).

A região nordeste do Brasil é caracterizada por sua irregularidade pluviométrica, apresentando períodos prolongados de seca e, por vezes, inundações severas. Tais características tornam a gestão dos recursos hídricos crucial para garantir o abastecimento de água potável, a produção de alimentos, a geração de energia elétrica e mitigar os efeitos das mudanças climáticas (Marengo *et al.*, 2021).

Desse modo justifica-se os estudos e pesquisas para aperfeiçoamento das técnicas de estimativas e correção de viés em precipitações com base em produtos de sensoriamento remoto e a assimilação de dados geoespaciais aos modelos hidrológicos para melhorar a caracterização das bacias hidrográficas e das estimativas do escoamento superficial em áreas com menor disponibilidade de dados, tomando como estudo de caso dez bacias hidrográficas no estado de Pernambuco com ocorrência predominante do semiárido, bem como em áreas onde ocorrem inundações bruscas e a operacionalização mais ágil das simulações hidrológicas é necessária.

1.1 HIPÓTESE

A hipótese defendida é que as precipitações estimadas por sensoriamento remoto e os dados geoespaciais abertos podem ser integrados às ferramentas computacionais de modelagem hidrológica, através de técnicas de assimilação de dados e correção de viés, de modo a se obter simulações satisfatórias, reduzir a calibração de parâmetros e minimizar desvios relativos entre precipitações estimadas e observadas.

1.2 OBJETIVOS GERAIS

Como objetivos gerais propõe-se o desenvolvimento de técnicas de análise, geoprocessamento e modelagem hidrológica voltadas à assimilação de dados geoespaciais e correção de viés para quantificar precipitações e vazões em bacias hidrográficas de Pernambuco utilizando produtos de sensoriamento remoto.

1.3 OBJETIVOS ESPECÍFICOS

Em abordagem analítica, propõe-se como objetivos específicos:

- a.** Avaliar a acurácia de produtos de precipitação estimada por sensoriamento remoto (CHIRPS, IMERG, PERSIANN CDR, PERSIANN CCS-CDR e PERSIANN PDIR) em bacias hidrográficas de clima úmido e semiárido;
- b.** Aplicar métodos de correção de viés em séries de precipitação estimada por sensoriamento remoto;
- c.** Assimilar dados geoespaciais abertos visando a inicialização rápida de modelos hidrológicos e a redução de parâmetros calibráveis;
- d.** Avaliar a acurácia de vazões geradas com base em precipitações estimadas por sensoriamento remoto em sua forma nativa e após correção de viés;
- e.** Aplicar métodos de correção de viés às vazões geradas a partir de precipitações estimadas por sensoriamento remoto.

2 REFERENCIAL TEÓRICO

2.1 ESTIMATIVAS DE PRECIPITAÇÃO POR SENSORIAMENTO REMOTO

A precipitação é um dos fenômenos hidrológicos mais estudados e monitorados no âmbito científico, havendo registros de mapas globais de precipitação desde meados do século XIX, publicados entre 1838 e 1848 pelo geógrafo e cartógrafo alemão Heinrich Berghaus na obra *“Physikalischer Atlas”*, Atlas do Meio Físico (Berghaus, 1842). Um pouco depois, em 1850, o também geógrafo e cartógrafo escocês Alexander Keith Johnston, incorporou os resultados de Berghaus à obra *“Hyetographic or Rain Map of The World”*, Hietograma ou Mapa de Chuva Global, representando as primeiras grandes publicações sobre estudos globais de precipitação (Johnston, 1850; Siemer, 2020).

No Brasil, o pioneirismo dos registros de precipitação se deu na região Nordeste, no Ceará a partir de 1849, pela Comissão Provincial de Fortaleza-CE, e em Pernambuco, desde 1861, pelo engenheiro e paisagista Emile Beringer, responsável pelos primeiros projetos do Jardim do Palácio do Campo das Princesas e da Praça da República que posteriormente viriam a ser objeto de paisagismo do inglês Burle Marx (Sant’anna, 2003; Silva, 2010).

Em mais de um século realizando medições das chuvas, diversos recursos e equipamentos foram utilizados a exemplo de pluviômetros, pluviógrafos, telepluviômetros e estações meteorológicas. Embora os recursos tecnológicos tenham avançado, ainda existem fatores operacionais e intercorrências que trazem dificuldades ao monitoramento das chuvas e possibilidade de erros (Huff, 1970; Barbera; Lanza e Stagi, 2002).

Entre essas intercorrências pode-se relacionar o fato de que as informações originadas de estações pluviométricas são pontuais, o que demanda uma rede de postos distribuídos de maneira a representar os eventos de chuva e a necessidade de interpolação de dados em fases de processamento (Zeng *et al.*, 2018). Em muitos casos, essa rede depende de um observador para fazer leituras gerando-se assim uma fonte potencial para erros humanos. No caso dos telepluviômetros, podem existir problemas na transmissão de dados via GPRS (Serviços Gerais de Pacote por Rádio) ou celular, além da necessidade de manutenção e calibração dos equipamentos (Ferreira *et al.* 2017).

Dois marcos para a evolução do monitoramento dos fenômenos ambientais, ocorreram quando, em 1960, a Agência Nacional Atmosférica e Oceânica dos Estados Unidos (NOOA - *National Oceanic Atmospheric Administration*) realizou o lançamento do primeiro satélite meteorológico, o Satélite TIROS-1, e em 1972 foi primeiro a Agência Aeronáutica e Espacial americana (NASA - *National Aeronautics and Space Administration*) lançou o satélite ambiental Landsat-1. Desde então as aplicações e necessidades estratégicas pelo domínio da tecnologia dos satélites têm crescido ao longo do século XX, momento que a regulação dos lançamentos atmosféricos passou a ter relevância internacional (Harris e Baumann, 2021).

Os satélites funcionam na órbita da Terra visitando periodicamente determinadas partes do globo, registrando e transmitindo a radiância refletida por diferentes alvos, permitindo aplicações diversas relacionadas à meteorologia (Griffith *et al.*, 1978), monitoramento ambiental (Araya, 1984), telecomunicações (Ribeiro *et al.* 2020), Sistemas de Posicionamento Global (GPS) (Bergé-Nguyen *et al.*, 2020), segurança nacional (Liang; Wang e Liu, 2020), entre outras.

Ao utilizar satélites para identificação de eventos e estimativas dos volumes de precipitação destacam-se os sensores capazes de registrar faixas de comprimento de onda infravermelho e termal, favoráveis a identificação da água (Ombadi *et al.*, 2021).


Ainda na década dos anos 70, Griffith et al. (1978), publicaram estudos sobre as aplicações do sensoriamento remoto para a quantificação da precipitação, considerando métodos de identificação e classificação de nuvens, projeções da variação direcional, quantificação do volume precipitado e possibilidades de aplicações em tempo real, a partir de imagens do espectro visível e infravermelho do satélite GOES-1 (*Geostationary Operational Environmental Satellite*).

Embora promissores, os resultados obtidos por Griffith et al. (1978) já indicavam grandes erros em períodos curtos que diminuía ao ampliar a faixa de tempo observada. Até então a falta de clareza sobre a acurácia posicional se contrapunha aos resultados promissores em tempo real alimentados por expectativas de melhorias a partir da evolução do processamento digital.

O satélite geoestacionário GOES encontra-se com produtos disponíveis na versão 16. Tais produtos são amplamente utilizados no Brasil, disponibilizados pela Divisão de Satélites e Sistemas Ambientais (DSA), do Instituto Nacional de Pesquisas Espaciais (INPE). Imagens do satélite GOES podem ser observadas na Figura 1 onde verifica-se as bandas do canal 1 no espectro visível, o canal 8 que realça vapor d'água e o canal 16 que mostra variações de temperatura nas nuvens.

Figura 1 – Imagens do satélite GOES-16 em 11-04-2021, às 18:00 GMT.

(a) Canal 1 – 0,14 μm . (b) Canal 8 – 6,19 μm . (c) Canal 16 – 13,3 μm .



Fonte: INPE (2021).

2.1.1 Global Precipitation Climatology Centre (GPCC)

Uma vez que a precisão das informações de precipitação estimada por sensoriamento remoto não atendia integralmente às demandas técnicas e pretensões científicas, ficou evidente a necessidade da integração de dados observados em campo aos métodos de processamento dos produtos gerados (Yong et al., 2010).


O Centro Climatológico de Precipitação Global (GPCC - *Global Precipitation Climatology Center*) é um centro especializado no apoio ao monitoramento e pesquisas climáticas, operado pela instituição alemã Deutscher Wetterdienst, em


conjunto com Organização Meteorológica Mundial (OMM), que subsidia dados para programas como o Programa Mundial de Pesquisa do Clima e o Sistema Global de Observações do Clima.

A base de dados do GPCC integra mais de 70.000 estações em todo mundo, que totalizam precipitações diárias e mensais, das quais cerca de 6.300 estações dispõem de informações em tempo quase real. Os dados são convertidos em produtos diários ou mensais em resoluções espaciais que variam de 25 a 250 km ($0,25^\circ$ a $2,5^\circ$), pós-processados e em tempo quase real, para diferentes períodos a partir de 1891 (Schneider *et al.*, 2008; Becher *et al.*, 2013).

Desde maio de 2008, os dados do GPCC estão disponíveis, com base em mais de 50.000 estações diferentes e com pelo menos 10 anos de dados, a espacialização das estações para os anos de 2012 e 2020 podem ser vistas na Figura 2. O Projeto de Climatologia de Precipitação Global (GPCP - *Global Precipitation Climatology Project*) gera produtos que integram a precipitação das estações e imagens de sensoriamento remoto. Outros produtos GPCC podem ser visualizados e obtidos para processamento no endereço <http://gpcc.dwd.de> (DWD, 2021)

Figura 2 – Número de estações por célula do produto GPCC de precipitação mensal com resolução de 100 km, (a) em 2012 e (b) em 2021.





Fonte: Adaptado de DWD (2021).

2.1.2 Tropical Rainfall Measuring Mission (TRMM)

A sequência de pesquisas espaciais consolidou missões com objetivos de melhorar a precisão dos dados de precipitação por satélite, a exemplo da *Tropical Rainfall Measuring Mission* (TRMM). A TRMM foi uma missão conjunta entre Estados Unidos e Japão, em parceria da *National Aeronautics and Space Administration* (NASA) e a *Japan Aerospace Exploration Agency* (JAXA), e iniciada em 1997 voltada à obtenção de precipitação na região tropical e subtropical e estimativa das anomalias de temperatura cobrindo as faixas de latitude de 50° N a 50° S. (Huffman *et al.*, 2007).

Um dos produtos da missão TRMM é gerado a partir do algoritmo Multisatellite Precipitation Analysis (TMPA), sendo o TMPA_3B42v7, a versão mais recente dos produtos de chuva, lançada em junho de 2012. Suas estimativas de precipitação possuem resolução espacial de aproximadamente 25 km (0,25°×0,25°), com dados a cada 3 horas e mensais, em tempo real e pós-processados (Chen *et al.*, 2013). Estudos indicaram que as estimativas de precipitação da versão TMPA_3B42v7, melhoram em relação ao TMPA_3B42v6 (Bigiarini *et al.*, 2017).

2.1.3 Global Precipitation Measurement (GPM)


Após a espaçonave TRMM esgotar suas reservas de combustível em junho de 2012, uma nova missão entrou em operação para dar continuidade a geração de produtos de precipitação a partir da *Global Precipitation Measurement* (GPM). A missão GPM, também realizada em cooperação entre Estados Unidos e Japão, consiste em um satélite que transporta um sistema de radiômetros para medir a precipitação do espaço e servir como padrão de referência para unificar as medições de precipitação de uma constelação de satélites, fornecendo cobertura total de dados de na faixa de 60° N a 60° S com resolução espacial de 10 km ($0,1^\circ \times 0,1^\circ$) e resolução temporal de até 30 minutos (Hou *et al.*, 2014).

Assim como os produtos TMPA foram gerados a partir dos dados da missão TRMM, a missão GPM possui produtos análogos e sucessores, conhecidos como IMERG (*Integrated Multi-Satellite Retrievals for GPM*). Os produtos IMERG possuem muitas semelhanças como o TMPA, quando seus algoritmos foram desenvolvidos para explorar faixas do espectro visível e infravermelho, sensores passivos PMW (Passive Microwave) de micro-ondas nos canais de 6 a 190 GHz, que conseguem penetrar as nuvens e são altamente sensíveis ao tamanho das gotas de precipitação e partículas de gelo (Huffman *et al.*, 2015).

O IMERG gera conjuntos de dados quase em tempo real (execuções iniciais e tardias) e dados de pesquisa em tempo real pós (execução final) para diferentes tratamentos. As execuções iniciais, tardias e finais, respectivamente IMERG-E, IMERG-L e IMERG-F, são liberadas com atrasos de aproximadamente 4h, 12h e 3,5 meses, respectivamente. O pós-processamento feito com base nas observações de campo, e o fluxo de retro análise dos algoritmos é também um dos diferenciais entre o IMERG e o TRMM (Farraro *et al.*, 2018). Na Figura 3 ilustra-se um exemplo do produto IMERG-E para a área de cobertura com resolução espacial de 10 km.

Por meio das estimativas globais de precipitação aprimoradas, a missão GPM tem contribuído para melhorar a definição da climatologia global, a previsão de eventos extremos e propiciar o desenvolvimento de novas aplicações e pesquisas científicas, conforme trabalhos publicados por Li *et al.* (2021) e Moazami e Najafi (2021). Estes trabalhos comentam sobre as melhorias de performance do IMERG e da permanência de erros aleatórios e sistemáticos que podem ser ajustados antes de aplicá-lo a modelos hidrológicos.

Figura 3 – Exemplo de produto IMERG-E.



Fonte: NASA (2021).

Outros produtos de sensoriamento remoto também fornecem precipitação e encontram-se disponíveis como exemplos do CMORPH - *Climate Prediction Center-Morphing* (Joyce et al., 2004); CloudSat (Wang et al. 2017); GSMAP - *Global Satellite Mapping of Precipitation* (Zhou et al., 2020), alguns inclusive com atuação comercial como o MSWEP - *Multi-Source Weighted-Ensemble Precipitation* (Beck et al., 2019).

Com base no referencial teórico analisado, acredita-se que a missão de desenvolver produtos de sensoriamento remoto está longe de acabar, tendo em vista as necessidades de resultados mais aprimorados, seja por novos equipamentos ou pela ampla possibilidade de combinações de satélites disponíveis e as técnicas de processamento desenvolvidas a partir dos produtos de sensoriamento remoto nas faixas visível, infravermelho, termal, radar.

2.1.4 Hidroestimador

O Brasil dispõe de produto de precipitação por sensoriamento remoto desenvolvido pelo INPE, o Hidroestimador. Este produto é obtido através de um método automático que utiliza uma relação empírica exponencial entre a precipitação estimada por radar e a temperatura de brilho do topo das nuvens extraídas do canal infravermelho do satélite GOES-16, gerando taxas de precipitação adaptadas para as condições climáticas da América do Sul, com resolução espacial de 4 km, e resolução temporal de 15 a 30 minutos (Reis; Rennó e Lopes, 2017; Reis, 2018).

O algoritmo do Hidroestimador considera entre os fatores de ajustes a correção de paralaxe. Esta correção proporciona melhor localização dos núcleos de precipitação e a correção orográfica que ajusta a taxa de precipitação em terrenos complexos devido à falta de outras fontes de dados, como radar e pluviômetros (Vincente *et al.*, 2002).

Os produtos e séries históricas de precipitação do Hidroestimador iniciam no ano de 2017 e encontram-se disponíveis em formato binários, no endereço <http://ftp.cptec.inpe.br/goes/goes16/hidroest/> (INPE, 2017).

2.2 ESTIMATIVA DE PRECIPITAÇÃO COM INFRAVERMELHO E ESTAÇÕES PLUVIOMÉTRICAS (CHIRPS)

O Centro de Riscos Climáticos (CHC – *Climate Hazards Center*) é uma aliança entre cientistas do Departamento de Geografia da Universidade da Califórnia em Santa Bárbara, da África e América Latina, em conjunto com o Serviço Geológico dos Estados Unidos (USGS – *United States Geological Survey*), da NASA, da Rede de Sistemas de Alerta Contra Fome (FEWS NET - *Famine Early Warning Systems Network*), da NOAA e do Departamento de Agricultura dos Estados Unidos (USDA – *United States Department of Agriculture*). Essa cooperação possui entre seus objetivos uma abordagem de monitoramento e identificação de riscos climáticos relacionados a seca agrícola e outros impactos das mudanças climáticas (Funk *et al.*, 2014).

Uma das ferramentas criadas pelo grupo é o ambiente *ClimateServ*, disponível no endereço <https://climateserv.servirglobal.net/>. Esta ferramenta amigável permite que tomadores de decisão e pesquisadores visualizem e baixem dados históricos de precipitação, dados de condição da vegetação através de (NDVI – *Normalized Difference Vegetation Index*), históricos climáticos e previsões tendenciais de precipitação e temperatura com alcance de 180 dias para auxiliar decisões relacionadas a agricultura e disponibilidade de água. A ferramenta permite que sejam baixados dados no formato GeoTIFF (*Georeferenced Tagged Image File Format*) para áreas de interesse editáveis no mapa (CHC, 2021).


Dois produtos de precipitação por sensoriamento remoto são fornecidos pelo CHC. Um deles é o CHIRP (*Climate Hazards Group Infrared Precipitation*) gerado em função de análises de imagens na faixa do infravermelho. Outro produto inclui no

processamento correções de erros com dados observados de estações pluviométricas, gerando a base de dados do CHIRPS (Climate Hazards Group Infrared Precipitation with Stations) (Funk *et al.*, 2014).

Os dois produtos apresentam precipitação global a partir de 1981, com resolução espacial de 5 km ($0,05^\circ \times 0,05^\circ$) entre as faixas de latitude de 50° S a 50° N e resolução temporal diária, 5 dias e mensal. A latência média para a disponibilização dos dados é de cerca de 2 dias para as estimativas CHIRP e 3 semanas para os produtos pós-processados do CHIRPS (Funk *et al.*, 2015).

O CHIRPS combina a precipitação de sensoriamento remoto de satélites geosíncronos e de órbita polar, de cinco produtos diferentes incluindo sensores TRMM, e registros de mais de 2.000 estações em solo, para calibrar estimativas globais de precipitação aplicando a técnica de classificação de nuvens CCD (*Cold Cloud Duration*), conforme processamento ilustrado na Figura 4 (Funk *et al.*, 2015).

Figura 4 – Fluxo de processamento da base de dados CHIRPS.



Fonte: Adaptado de Funk *et al.* (2015).

A metodologia CCD utiliza imagens de uma área na faixa do infravermelho termal (TIR – Thermal Infrared), identifica pixels com temperaturas aparentes inferiores classifica-os como "nuvem fria" e acumula a série de resultados ao longo de algum período (Barret, 1989).

Outra informação relevante para entender o processamento do CHIRPS, está relacionada a base CHPclim, referente a Climatologia de Precipitação do Centro de Riscos Climáticos. A CHPclim é um produto de dados em grade de 5 km construído usando uma modelagem geoespacial baseada em regressões de médias móveis e interpolações ponderadas pelo inverso das distâncias, conforme a técnica IDW (*Inverse Distance Weighting*). Uma versão atualizada da base de dados CHIRPS 2.0 foi lançada em fevereiro de 2015 (CHC, 2021).

Diversos estudos têm avaliado a precisão da base de precipitação global do CHIRPS. Estudos locais de precisão ou outras aplicações climáticas foram feitos no Chile (Zambrano *et al.*, 2017), Argentina (Rivera *et al.*, 2018), Etiópia (Ayehu *et al.*, 2018), China (Bai *et al.*, 2018), Paquistão (Nawaz; Iqbal; Mahmood, 2020). Shen *et al.* (2020) realizaram uma análise global de toda a base de dados CHIRP, CHIRPS e a rede de referência GPCC.

No Brasil dois relevantes trabalhos foram publicados abordando a região nordeste, Paredes-Trejo *et al.* (2017) avaliando a acurácia dos dados e Brito *et al.* (2021) aplicando a base CHIRPS para calcular o Índice de Precipitação Padronizado (SPI - *Standardized Precipitation Index*). Cavalcante *et al.* (2021) observaram eventos extremos na Amazônia indicando que nesta região o CHIRPS possui boa correlação entre médias mensais, mas subestima os eventos extremos.

2.3 ESTIMATIVA DE PRECIPITAÇÃO A PARTIR DE SENSORIAMENTO REMOTO E REDES NEURAIAS ARTIFICIAIS (PERSIANN)


A sigla PERSIANN, do inglês, Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks (Estimativa de precipitação a partir de informações de sensoriamento remoto usando redes neurais artificiais), é um projeto desenvolvido pelo Centro de Hidrometeorologia e Sensoriamento Remoto (CHRS) da Universidade da Califórnia, Irvine (UCI) (Nguyen *et al.*, 2019).

Os primeiros estudos do projeto PERSIANN foram publicados em 1997 e possuem a essência de identificar eventos extremos de precipitação (Hsu *et al.*, 1997). A partir de 2016 tais produtos de precipitação passaram a ser disponibilizados através do portal do CHRS, no endereço <http://chrsdata.eng.uci.edu/>, conforme ilustrado na

Figura 5. O portal de acesso é uma plataforma amigável que permite fazer recortes de áreas específicas, seleção da base de dados e do período de interesse,

bem como a resolução temporal e extensão dos arquivos de saídas (Geotiff, ArcGrid e NetCDF) (Nguyen *et al.*, 2019).

Figura 5 – Portal de acesso aos produtos PERSIANN.



Fonte: Nguyen *et al.* (2019).

Os produtos PERSIANN são obtidos a partir de procedimentos de aproximação e classificação de nuvens, algoritmos de redes neurais e estimativa da intensidade de precipitação que utilizam informações de imagens de satélite no espectro infravermelho e de micro-ondas, pluviômetros, dados de radar coletados no solo e informações topográficas. A proposta de obtenção e processamento de imagens com aplicação de rede neural é um recurso que permite treinamento adaptativo e facilita a atualização dos parâmetros da rede sempre que novas estimativas estão disponíveis (Hsu *et al.*, 1997).


O projeto PERSIANN disponibiliza 5 produtos no Portal CHRS: PERSIANN, PERSIANN-CCS, PERSIANN-CDR, PDIR-Now e PERSSIANN-CCS-CDR.

O PERSIANN-CCS (*Cloud Classification System*) é um produto obtido a partir do Sistema de Classificação de Nuvens que permite a categorização de conjuntos de nuvens com base na altura, extensão da área e textura a partir das imagens de satélite. A essência do PERSIANN-CCS está no algoritmo de segmentação de nuvem de limite variável, cujo fluxo de processamento é ilustrado na Figura 6. Em contraste com a abordagem tradicional da segmentação de limite constante, o limite variável

permite a identificação e separação de manchas de precipitação em cada nuvem (Hong *et al.*, 2004).

O PERSIANN-CDR (*Climate Data Record*) é um produto que resgata dados históricos de precipitação para um recorte quase global a partir de 1983. A base de dados visa disponibilizar precipitação consistente de longo prazo para estudar mudanças climáticas, tendências de precipitação diária e eventos extremos. O PERSIANN-CDR é gerado a partir do algoritmo PERSIANN usando dados infravermelho do satélite GridSat-B1. Estes dados são ajustados com base no produto de precipitação mensal do Projeto de Climatologia de Precipitação Global, fornecido pelo GPCC (Ashouri *et al.*, 2015).

Figura 6 – Fluxo de processamento da base de dados PERSIANN-CCS.



Fonte: Adaptado de CHRS (2017).

O PDIR-Now (*Dynamic Infrared Rain Rate Near real-time*) inclui nos algoritmos de processamento a taxa dinâmica de precipitação utilizando a faixa do infravermelho e em tempo quase real. A principal vantagem do PDIR-Now é a latência desde o momento da ocorrência da chuva até a disponibilização dos dados. A disponibilização dos produtos ocorre entre 15 e 60 minutos. A baixa latência torna o conjunto de dados viável para aplicações hidrológicas como previsão de cheias e

desenvolvimento de mapas de inundação. Além disso, estudos indicam potencial do uso do algoritmo PDIR para reconstruir estimativas históricas de precipitação em frações subdiária (Nguyen *et al.*, 2020a, 2020b).

O PERSIANN-CCS-CDR (*Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks-Cloud Classification System-Climate Data Record*), foi projetado para combinar a qualidade da resolução espacial dos dados CCS com as séries de longo prazo da base CDR. Neste processo, o algoritmo CCS é aplicado a dados combinados do satélite Gridded (GridSat-B1) e do NOAA *Climate Prediction Center* (CPC-4km). Em seguida, as estimativas são ajustadas usando o conjunto de dados do Projeto de Climatologia de Precipitação Global (GPCP) a partir de 1983 (Sadegui *et al.*, 2019).

Características técnicas de cada produto PERSIANN podem ser observadas na Tabela 1, incluindo o período de disponibilização de cada produto, área de cobertura, resolução espacial, resolução temporal e latência, ou seja, a defasagem entre o tempo de obtenção e disponibilização do dado sobre um período.

Tabela 1 – Características técnicas dos produtos PERSIANN.

Produto	Início	Cobertura	Resolução espacial	Resolução temporal	Latência
PERSIANN	Mar/2000	60°S a 60°N	0.25° (~25km)	1h, 3h, 6h e 24h	2 dias
PERSIANN-CCS	Jan/2003	60°S a 60°N	0.04° (~4km)	1h, 3h, 6h e 24h	~ 1 h
PERSIANN-CDR	Jan/1983	60°S a 60°N	0.25° (~25km)	diária, mensal e anual	~ 3 meses
PDIR-Now	Mar/2000	60°S a 60°N	0.04° (~4km)	1h, 3h, 6h, diária,	15 a 60 min
PERSIANN-CCS-CDR	Jan/1983	60°S a 60°N	0.04° (~4km)	3h, 6h, diária, mensal e anual	~ 1 h

Fonte: Adaptado de CHRS (2020).

Publicações sobre os produtos de precipitação PERSIANN realizaram avaliações locais da acurácia espaço-temporal na Austrália (Islan; Yu; Cartwright, 2020), na China (Yu *et al.*, 2020), no Chile (Fuente; Meruane; Suárez, 2021) e na Índia (Mondal; Lakshmi; Hashemi, 2018). Métodos de correção de erros sistemáticos foram publicados por Salmani-Dehaghi; Samani (2021) no Iran. Estudos de monitoramento

de seca foram avaliados com base no PERSIANN-CDR por Mohseni *et al.* (2021). Eventos extremos foram estudados por Li *et al.* (2019) aplicando os dados PERSIANN-CCS em um modelo hidrológico distribuído na China.

No Brasil, entre as aplicações do PERSIANN, destacam-se os trabalhos de Sobral *et al.* (2020) que utiliza o PERSIANN-CDR para análise de precipitações anuais no Rio de Janeiro e de Brito *et al.* (2021) que aplica o PERSIANN-CDR para monitoramento de seca na bacia do rio Piranhas, na região Nordeste.

2.4 ESTIMATIVAS DE PRECIPITAÇÃO POR RADAR

2.4.1 Radar de abertura sintética

O princípio de funcionamento do RADAR (*RA*dio *DE*tecting *AN*d *R*anging) é baseado no uso de ondas na frequência de rádio. Um radar é composto por uma antena transmissora/receptora de sinais. Na transmissão um pulso eletromagnético de alta potência, curto período e feixe estreito é emitido. O feixe emitido se alarga em forma de cone, até atingir o objeto monitorado, sendo então refletido e retornado à antena, que passa a ser receptora de sinais e registra (Novo, 2010).

Em contraste com os radiômetros de micro-ondas passivos (PMW), o radar possui sistemas de sensores ativos que fornecem sua própria fonte de radiação de ondas, permitem observar regiões do espectro não captadas por sensores ópticos e possuem capacidade de visualizar os alvos em diferentes condições ambientais, como durante o período noturno, ou gerar imagens sem interferência de nuvens (Novo, 2010).

A resolução espacial dos dados do radar está diretamente relacionada à relação entre o comprimento de onda e o comprimento da antena do sensor, ou seja, quanto mais longa a antena, maior a resolução espacial. Mantendo essa relação de proporcionalidade seria necessário construir antenas da ordem de quilômetros para obter resultados com resolução espacial da ordem de metros. Para contornar esse problema foram desenvolvidos sistemas de Radar de Abertura Sintética (SAR – *Sinthetic Aperture Radar*) que tem como princípio a aquisição sequenciada de partes do sinal em uma antena mais curta, fornecendo dados de alta resolução (Franz, 2019).

A tecnologia SAR permitiu a redução do porte dos equipamentos, o que viabilizou a partir de 1978 o lançamento de satélites com essa tecnologia através do programa Seasat (Black *et al.*, 1985). Os radares normalmente operam nas bandas


P, L, S, C, X e K, cujas frequências, comprimento de onda e principais aplicações de cada banda podem ser observadas na Tabela 2. Na Figura 7 ilustra-se o recorte da faixa espectral em onde normalmente operam os radares e a proporcionalidade do comprimento de onda para as frequências e bandas mais utilizadas.

Tabela 2 – Frequência, comprimento de onda e principais aplicações das bandas imageadas por radar.

Banda	Frequência (GHz)	Comprimento de onda (cm)	Principais aplicações
Ka	27 – 40	1,1 – 0,8	Vigilância de aeroportos (Raramente usada em SAR)
K	18 – 27	1,7 – 1,1	Absorção de água (Raramente usada)
Ku	12 – 18	2,4 – 1,7	Altimetria (Raramente usada)
X	8 – 12	3,8 – 2,4	Monitoramento urbano; gelo e neve; baixa penetração em cobertura vegetal (Alta resolução)
C	4 – 8	7,5 – 3,8	Mapeamento global, gelo, navegação marítima. (Frequentemente utilizada)
S	2 – 4	15 – 7,5	Observações da Terra, agricultura (Utilização em crescimento)
L	1 – 2	30 – 15	Geofísica, mapeamento de biomassa e vegetação, Interferometria (Média resolução)
P	0.3 – 1	100 – 30	Biomassa, mapeamento e avaliação de vegetação (Uso experimental)

Fonte: Adaptado de Franz (2019).

Figura 7 – Principais bandas SAR, faixas de frequência e comprimentos de onda.




Fonte: Adaptado de Franz (2019).

O radar é capaz de observar a estrutura das nuvens e fornecer propriedades de precipitação vertical, medir a sua distribuição tridimensional, identificar núcleos de precipitação e fornecer boa resolução espaço-temporal. Ainda assim, a instalação de radares em satélites possui limitações relacionadas ao tamanho, peso, consumo de energia e outros fatores. Para aumentar o poder da radiação efetiva, fornecer alta sensibilidade e uma ampla faixa de medições dentro dessas limitações, é natural escolher uma frequência de radar superior a 10 GHz. No entanto, surge outro problema com a atenuação da onda de radar devido à chuva, o objeto real da medição (Fujita; Sataki, 1997; Houze, 2014).

Algumas missões espaciais e satélites possuem sensores de radar, entre as quais pode-se citar o RadarSat, SRTM, ALOS, Envisat, Sentinel, SMAP (*Soil Moisture Active Passive*), sendo o SMAP equipado com sensores ópticos passivos e sensores ativos SAR. Como exemplo de aplicações relacionadas a identificação de precipitação através de sensores ativos pode-se citar o TRMM-PR (*Precipitation Radar*), GPM-DPR (*Dual-Frequency Precipitation Radar*) e CloudSat-CPR (*Cloud Profiling Radar*).

O TRMM-PR utilizado por Chen *et al.* (2016) para avaliar variações sazonais de eventos extremos em regiões tropicais e subtropicais. O GPM-DRP foi utilizado por Ferraro *et al.* (2018) para ilustrar um perfil tridimensional e intensidade de precipitação líquida e sólida, conforme ilustrado na Figura 8. Hong; Liu (2015) estudaram as características de nuvens de gelo a partir dos satélites CloudSat e CALIPSO.

Figura 8 – Perfil vertical de precipitação sólida e líquida obtido através da missão GPM e observado em 02 de outubro de 2016 (Furacão Matthew).



Fonte: Adaptado de Ferraro *et al.* (2018).

No Brasil, Duarte, França e Justo (2018) utilizaram dados do CloudSat para caracterização da estrutura microfísica de eventos de precipitação extrema sobre as regiões sul e sudeste. Costa (2018) estudou as influências das propriedades radiativas das nuvens nas incertezas das estimativas de precipitação por satélites, onde foram utilizados dados do TRMM-PR e GPM-DRP nas avaliações e processamentos.

2.4.2 Radar meteorológico doppler

O radar meteorológico Doppler envia pulsos multidirecionais de radiação de micro-ondas a partir de uma antena parabólica. Este tipo de aparelho teve sua aplicação intensificada em função da 2ª Guerra Mundial (1939 - 1945) quando a tecnologia era utilizada para fins militares, e a detecção da precipitação era importante para evitar interferência na identificação dos alvos inimigos. Ao fim da guerra foram doados radares aos centros meteorológicos que iniciaram uma fase de pesquisas sobre as características da intensidade, propagação e atenuação dos sinais de radar sobre nuvens, granizo, neve e precipitação (Atlas, 1964).

Outra vertente importante sobre os radares meteorológicos está relacionada a interpretação quantitativa. Destaca-se os estudos de Marshall *et al.* (1947) e Marshall e Palmer (1948) onde se apresenta que a refletividade das partículas de água possui relação proporcional aos diâmetros das partículas em uma unidade de volume sob incidência do feixe de um radar, conforme Equação 1. Estes estudos indicaram que a taxa de precipitação (R) está relacionada ao diâmetro das gotas (D), através da Equação 2, havendo a relação prática da Equação 3 entre a refletividade e a taxa de precipitação, conhecida como relação Z-R. Posteriormente as simplificações dessas equações foram aprimoradas sobre abordagens físicas e estatísticas (Marshall; Hitschfeld, 1953).

$$Z = \sum_i N_i \cdot D_i^6 = \int_0^{\infty} N(D) \cdot D^6 dD \quad \text{Eq. 1}$$

$$R = \frac{\pi}{6} \int_0^{\infty} N(D) D^3 V_t(D) dD \quad \text{Eq. 2}$$

$$Z = A \cdot R^b \quad \text{Eq. 3}$$

Onde:

Z – Fator de refletividade, mm⁶/m³ ou dBZ

N_i - Número de gotas por unidade de volume de ar para cada diâmetro D

D_i - Diâmetro de gotas por unidade de volume de ar, mm


R - Taxa de precipitação, mm/h

V_t - Velocidade terminal das gotas, cm/s ($V_t = 1400\sqrt{D}$)

A e b – constantes

Os resultados provenientes do radar meteorológico são apresentados em projeção horizontal mostrados ao longo dos raios de um círculo projetados em um plano de referência chamado PPI (Plan Position Indicator), conforme ilustrado na Figura 9. Estes resultados podem representar diferentes alturas a partir da posição do radar obtidos em coordenadas polares, onde para cada plano de altura constante convertido em coordenadas planas dá-se o nome de CAPPI (Constant Altitude PPI). Ainda é possível realizar uma varredura vertical denominada de RHI (Range Height Indicator) (East; Dore, 1957; Marshall, 1957).

Figura 9 – Exemplos esquemático da composição dos planos PPI e CAPPI (a) e refletividade (b) do radar meteorológico Doppler.



Fonte: Adaptado de Angelis (2011).

A evolução dos métodos de quantificação da precipitação teve outro importante avanço a partir da utilização de radares de dupla polarização com base nos estudos de Seliga e Bringi (1976). Observando o comportamento de uma onda plana, tem-se que o comprimento do vetor campo elétrico define a sua amplitude e a velocidade de rotação estabelece a frequência da onda, enquanto a orientação e a forma geométrica são traçadas pela ponta desse vetor sendo o que determina a sua

polarização (Andrade; Rosa; Faria, 2007; Andrade, 2012). Ou seja, a polarização é determinada pela orientação do campo elétrico e forma um plano de propagação para a onda. Muitos radares são projetados para transmitir a radiação polarizada em um plano horizontal (H) ou vertical (V). Os equipamentos mais modernos emitem e recebem sinal, simultaneamente, nas orientações horizontal e vertical.

A polarização dupla é importante para melhorar a sensibilidade da distribuição das gotas de água, fazendo com o sinal tenha menos atenuação na transmissão e melhor interação com os alvos no retorno. Tais estudos trouxeram novos conceitos como a Refletividade Diferencial (Zdr) que é a razão dos retornos de potência vertical e horizontal, e o Coeficiente de Correlação (ρ_{hv}) que é uma correlação estatística entre a razão de retorno de potência horizontal e vertical. A polarização dupla trouxe ganhos quanto avaliação dos tipos de precipitação, intensidade e diferenciação entre neve ou graúdo (Seliga; Bringi, 1976).

Para observar a água através de radar deve-se determinar os comprimentos de onda em função dos tamanhos típicos das gotículas que variam de cerca de 0,1 a 10 mm para gotas de chuva, até 25 mm para flocos de neve e até 50 mm para granizo. O comprimento de onda ideal deve maximizar as interações entre o sinal do radar e os alvos, no entanto esse comprimento de onda ideal aumenta a detecção enquanto afeta a potência do sinal do radar por espalhamento e absorção, reduzindo a capacidade de monitoramento de longo alcance. A compensação entre essas duas restrições levou ao uso principalmente da banda S (comprimento de onda de 10 cm, frequência de 3 GHz), banda C (comprimento de onda de 5 cm, frequência de 5 GHz) e banda X (comprimento de onda de cerca de 3 cm ou frequência de 10 GHz) para sistemas de radar meteorológico (Berne; Krajewski, 2013).

A continuidade das pesquisas levou a estudos como em Charley (1988), quando na década dos anos 1980, o USACE (United States Army Corps of Engineers) utilizava dados de radar e pluviômetros para previsão de inundações, sendo a estimativa da precipitação em tempo real, um de seus atributos positivos. Mesmo que a utilização de radares tenha se consolidado enquanto alternativa sofisticada para quantificar a precipitação, erros e incertezas continuam presentes nos métodos e equipamentos.

Segundo Wilson e Brandes (1979), vários fatores podem causar erros na estimativa de precipitação a partir do radar Doppler, e estes fatores podem ser principalmente agrupados em erros de estimativa da refletividade, variações na

relação Z-R e diferenças entre resultados amostrais do radar e de pluviômetros. Berne e Krajewski (2013) trazem questões relevantes sobre a precipitação a partir de radares, em formato de abordagem evolutiva da tecnologia, acrescentam a dificuldade da gestão dos dados e fazem seguinte reflexão com título de publicação “Radar para hidrologia: promessa não cumprida ou potencial desconhecido?”. Berne e Krajewski (2013) concluem que a resposta sobre a reflexão do trabalho era simples, e naquela ocasião ambas as premissas eram verdadeiras.

Publicações sobre radares seguem a linha investigativa de comparações entre radar e pluviômetros (Gilewski; Nawalany, 2018; Foehn *et al.*, 2018), ajustes locais da relação Z-R (Kim; Kwon; Kim, 2020), previsões em tempo real (Seo; Krajewski, 2020) e simulações hidrológicas (Cha; Lee, 2021).

No Brasil o Centro Nacional de Monitoramento e Alertas de Desastres Naturais (Cemaden) é o principal órgão que disponibiliza informações para nove radares em território nacional, além de outras agências estaduais de meteorologia como a Agência Pernambucana de Águas e Clima (Apac).

2.5 AQUISIÇÃO, ASSIMILAÇÃO E PROCESSAMENTO DE DADOS GEOESPACIAIS

2.5.1 Dados abertos

Até certo tempo a informação, principal insumo para pesquisas científicas, era insuficiente ou restrita aos órgãos governamentais em função de uma cultura de sigilo de informações ou cobrança pelo fornecimento de dados. Uma grande revolução na gestão de informação surge a partir do conceito de dados abertos. Segundo a Open Knowledge (2012) dados são abertos quando qualquer pessoa pode livremente acessá-los, utilizá-los, modificá-los e compartilhá-los para qualquer finalidade, estando sujeito a, no máximo, a exigências que visem preservar sua proveniência e sua abertura, e seguem três leis:

1. Se o dado não pode ser encontrado e indexado na Web, ele não existe;
2. Se não estiver aberto e disponível em formato compreensível por máquina, ele não pode ser reaproveitado; e
3. Se algum dispositivo legal não permitir sua replicação, ele não é útil.

Desde então, o desenvolvimento de plataformas com a finalidade de repositório das mais diversas bases de dados passou a ser recorrente e receber

funcionalidades de acordo com as necessidades dos usuários. Segundo Martín (2018) o Brasil é um país com elevado nível de disponibilidade de dados abertos ou de acesso livre consultados a partir do Google Scholar.

Ao citar apenas três exemplos de plataformas com a finalidade de visualização e disponibilização de dados de sensoriamento remoto como Real Earth (SSEC, 2019), Earth Data (NASA, 2019) e Earth Explorer (USGS, 2019), respectivamente vinculadas ao Centro de Engenharia e Ciência Espacial (SSEC - Space Science and Engineering Center) da Universidade de Wisconsin-Madison, NASA e USGS, tem-se uma vasta quantidade de produtos climáticos e ambientais como GOES, Landsat, MODIS, Sentinel e produtos decorrentes de geoprocessamentos em temáticas tais como qualidade do ar, queimadas, secas, eventos extremos de chuva, inundações, vegetação, geleiras e oceanos.

No Brasil tem-se destaque para bases de dados de sensoriamento remoto disponibilizadas pelo Instituto de Pesquisas Espaciais (INPE) (INPE, 2020), para as bases vetoriais do Instituto Brasileiro de Geografia e Estatística (IBGE, 2020), e para os dados abertos da Agência Nacional de Águas e Saneamento Básico (ANA, 2020).

A seguir apresenta-se detalhes sobre três importantes plataformas de disponibilização de dados abertos: GIOVANNI, Google Earth Engine e MapBiomas.

2.5.2 Plataforma GIOVANNI (Geospatial Interactive Online Visualization and Analysis Infrastructure)

A infraestrutura geoespacial interativa e on-line de análise e visualização de dados espaciais, conhecida como GIOVANNI (*Geospatial Interactive Online Visualization And Analysis Infrastructure*) é uma ferramenta de exibição e análise de dados de sensoriamento remoto da NASA, diretamente na internet, com baixa dificuldade de acesso e aquisição das informações.

Lançada em 2003, a plataforma GIOVANNI foi atualizada em março de 2021 para a versão 4.35. Em abril do mesmo ano, o repositório somava aproximadamente 3.370 *Tb* (*Terabytes*) de armazenamento e cerca de 150 milhões de arquivos. Os arquivos podem ser filtrados por categorias como dados observados ou saídas de modelos, áreas de conhecimento, sensor orbital, resolução espacial e temporal, entre outros (Acker *et al.*, 2014; NASA, 2021).

GIOVANNI também é repositório dos dados das missões TRMM e GPM, configurando-se um ambiente relevante para consulta sobre produtos de precipitação estimada por sensoriamento remoto, além de fornecer dados globais de umidade do solo, temperatura do solo, do ar e dos oceanos, dados climatológicos de precipitação e evapotranspiração, entre outros (Acker *et al.*, 2014; NASA, 2021).

O acesso a plataforma pode ser feito através do endereço <https://giovanni.gsfc.nasa.gov/giovanni/> (NASA, 2021), o portal dispõe de glossário, e para cada produto disponibilizado é possível observar as unidades de saída, o sensor orbital que originou o produto, resolução espacial e temporal, e período de início e término de operação, se for o caso.

2.5.3 Plataforma Google Earth Engine (GEE)


Com a popularização do conceito de dados abertos tem sido frequente o desenvolvimento de sistemas de supercomputadores com processamento em nuvem para minimizar as dificuldades relacionadas à gestão e ao processamento da grande quantidade de produtos de sensoriamento remoto. Tais sistemas de processamento possuem funcionalidades se popularizando para fins públicos ou comerciais (Nemani *et al.*, 2011).

A plataforma Google Earth Engine (GEE) traz um catálogo de dados da ordem de *Petabytes* (1.000 *Terabytes*). Os dados disponíveis encontram-se prontos para análise a partir de um serviço de computacional de alto desempenho. O GEE pode ser acessado e controlado por meio de uma interface de programação de aplicativos (API - *Application Programming Interface*), acessível pela Internet, e um ambiente de desenvolvimento interativo (IDE - *Interactive Development Environment*) que permite o rápido desenvolvimento de protótipos e visualização de resultados (Gorelick *et al.*, 2017). A Figura 10 ilustra o ambiente de desenvolvimento GEE, onde observa-se exemplos de bases de dados e *scripts* (1), ambientes de comandos para programação (2), resultados gráficos e de outras tarefas executadas (3) e campo de visualização de imagens e resultados de processamento (4).

O catálogo de dados geoespaciais do GEE inclui observações de uma variedade de sistemas de imagens de satélite em diversos comprimentos de onda ópticos e não ópticos, variáveis ambientais, previsões meteorológicas, climáticas e *Hindcasts* (método de verificação de modelo matemáticos), cobertura da terra,

topografia e dados socioeconômicos. Todos esses dados são pré-processados e disponibilizados em formatos para uso instantâneo, mas com preservação de informações, que permitem acesso eficiente e remove barreiras associadas ao gerenciamento local de dados (Gorelick *et al.*, 2017).

Figura 10 – Ambiente de desenvolvimento Google Earth Engine.



Fonte: Adaptado de Gorelick *et al.* (2017).

As aplicações desenvolvidas a partir das funcionalidades do GEE tem sido cada vez mais recorrentes e podem ser exemplificadas em trabalhos que passam pela aplicação do método SEBAL (*Surface Energy Balance Algorithm for Land*) para cálculo da evapotranspiração (Mhawej; Faour, 2020), desenvolvimento urbano sustentável (Liang *et al.*, 2020) ou identificação de áreas sob o efeito de marés (Jia *et al.*, 2021). No Brasil, pode-se citar Arruda *et al.* (2020) com trabalho sobre a identificação de queimadas e Vieira *et al.* (2021) realizando mapeamento de áreas degradadas por atividades agrícolas.

2.5.4 O Projeto MapBiomás

O Projeto de Mapeamento Anual da Cobertura e Uso do Solo do Brasil (MapBiomás) é uma iniciativa que envolve uma rede colaborativa com especialistas em biomas (Amazônia, Caatinga, Cerrado, Mata Atlântica, Pampa e Pantanal), usos da terra, sensoriamento remoto, SIG e ciência da computação. O projeto utiliza processamento em nuvem e classificadores automatizados desenvolvidos e operados

a partir da plataforma Google Earth Engine (GEE) para gerar uma série histórica de mapas anuais de cobertura e uso da terra do Brasil.

O MapBiomias produziu 8 coleções de mapas anuais da Cobertura e Uso do Solo para todo o país, a coleção 8 foi publicada em agosto de 2023 e compreende o período de 1985 a 2022. O processamento utiliza a tecnologia de computação em nuvem do GEE, aplicando o algoritmo de classificação *Random Forest* sobre imagens do satélite Landsat, com resolução espacial de 30 m (Souza *et al.*, 2020).

A classificação realizada na Coleção 8, identifica separadamente as classes nos biomas Amazônia, Caatinga, Cerrado, Mata Atlântica, Pampa e Pantanal para cada ano, em três níveis de detalhamento sobre quatro temas transversais de cobertura: pastagem, agricultura, zona costeira e área urbana, conforme ilustrado na Figura 11 e classes descritas na Tabela 3. Filtros para ajustes espaciais e temporais, por exemplo para ajustes em função da presença de nuvens, são utilizados após a classificação. Os mapas de cada classe são integrados e ajustados nas áreas de transições de temas, conforme fluxo de processamento da Figura 11.

Tabela 3 – Classes e identificadores do MapBiomias Coleção 8.

ID	CLASSE COLEÇÃO 8	ID	CLASSE COLEÇÃO 8
1	1. Floresta	40	3.2.1.3. Arroz
2	1.1. Floresta Natural	62	3.2.1.4. Algodão
3	1.1.1. Formação Florestal	41	3.2.1.5. Outras Culturas Temporárias
4	1.1.2. Formação Savânica	36	3.2.2. Culturas Permanentes
5	1.1.3. Mangue	46	3.2.2.1. Café
6	1.1.4. Floresta Inundável	47	3.2.2.2. Cítricos
49	1.1.5. Vegetação de restinga arborizada	35	3.2.2.3. Azeite de Dendê
10	2. Formação Natural Não Florestal	48	3.2.2.4. Outras Culturas Permanentes
11	2.1. Campo Alagado e Área Pantanosa	9	3.3. Floresta Plantada
12	2.2. Formação Campestre	21	3.4. Mosaico de Usos
32	2.3. Planície Salina	22	4. Área Não Vegetada
29	2.4. Afloramento Rochoso	23	4.1 Praia, Duna e Areal
50	2.5. Vegetação Herbácea de Restinga	24	4.2 Infraestrutura Urbana
13	2.6. Outras Formações não Florestais	30	4.3 Mineração
14	3. Agropecuária	25	4.4 Outras Áreas não Vegetadas
15	3.1. Pastagem	26	5. Corpos d'Água
18	3.2. Agricultura	33	5.1. Rio, Lago e Oceano
19	3.2.1. Culturas Temporárias	31	5.2. Aquicultura
39	3.2.1.1. Soja	27	6. Não Observado
20	3.2.1.2. Cana		

Fonte: Adaptado de MapBiomias (2023).

Fonte: MapBiomass (2020).

O potencial de aplicações a partir da série de dados de uso do solo é vasto, e passa por trabalho de monitoramento ambiental das áreas de mangue (Diniz *et al.*, 2019), áreas irrigadas (Saraiva *et al.*, 2019), degradação de vegetação nativa (Alencar *et al.*, 2020) e previsão de cenários tendências de degradação (Fendrich *et al.*, 2020). Além das aplicações citadas, vislumbra-se que as informações de uso e ocupação do solo do MapBiomass fornece um importante insumo para simulações computacionais na área de hidrologia no território brasileiro.

2.5.5 Assimilação de dados

A assimilação de dados é uma técnica empregada para integrar de forma sinérgica dados observados e modelos numéricos visando melhorar a precisão de simulações e previsões para melhor compreensão dos sistemas naturais complexos. Este processo pode envolver a integração de diversas fontes de informação, tais como observações de satélite, observações terrestres ou simulações de outros modelos, para criar uma representação mais abrangente e confiável dos processos da Terra. A assimilação de dados é uma ligação entre os dados observados e as simulações computacionais, como ilustrado na Figura 13.

Figura 13 – Relação entre dados observados, assimilação de dados e simulações.



Fonte: DAT (2022).

Na meteorologia, a assimilação de dados é comumente aplicada na previsão do tempo. Os modelos meteorológicos assimilam observações em tempo quase real, como imagens de satélite e medições terrestres para ajustar as condições iniciais do

modelo e melhorar as previsões de curto prazo. Como exemplo cita-se o estudo realizado por Chen, Huang, Yang (2021) que desenvolveu previsões climáticas de seca a partir da combinação de dados de temperatura de brilho do SMOS (*Soil Moisture and Ocean Salinity*) e previsões climáticas dados de anomalia de armazenamento de água no solo da base de dados GRACE (*Gravity Recovery and Climate Experiment*).

Na hidrologia, a assimilação de dados possibilita uma grande combinação de possibilidades e estratégias metodológicas. Informações sobre as características fisiográficas da bacia podem ser obtidas com auxílio de informações de geoprocessamento (Castro e Maidment, 2020). Quin *et al.* (2022) propõem um método de correção de viés para dados de umidade do solo de grandes áreas com base na assimilação dados de radar. Zhang *et al.* (2021) desenvolveram um modelo para operação de reservatório de controle de cheias com base em simulações hidrológicas para definição do nível de armazenamento do reservatório, tendo como dado de entrada a assimilação do nível atualizado em tempo real.

À medida que as tecnologias continuam a evoluir, a integração de informações na forma de assimilação de dados tende a melhorar a qualidade das simulações e aplicações práticas de modo a desempenhar um papel fundamental em análises de desafios complexos.

2.5.6 Método de processamento de dados por conjunto (*Ensemble*)

Ao adotar modelos computacionais para representar processos climatológicos deve-se entender que tais ferramentas possuem simplificações matemáticas quando caracterizam os fenômenos estudados. Sabe-se também que parte dos dados de entrada dos modelos são observados de forma amostral, logo possuem uma representação simplificada de algo que pode variar no tempo ou no espaço, sendo comum a ocorrência de imprecisões.


Desse modo entende-se que um modelo computacional representa um cenário possível havendo sempre um grau de incerteza associado. O método de processamento de dados por conjunto, conhecido como “*ensemble*” busca combinar resultados de múltiplos modelos para fornecer estimativas mais robustas e confiáveis das variáveis (Caseri, 2000).

Conceitos iniciais apresentados por Brier (1950) associam a possibilidade de previsões climáticas aplicando distribuições de probabilidade. Hersbach (2000)

exemplifica aplicações do método de processamento de dados por conjunto para além da meteorologia, tais como análises econômicas de custo-benefício e determinação da curva Característica de Operação do Receptor (Curva ROC) com aplicações na medicina, biometria, análise de riscos naturais, modelos de avaliação de performance, estudos de validade, machine learning, data mining e outras áreas.

Nas simulações hidrológicas os métodos de ensemble podem incluir médias ponderadas dos resultados de cada modelo, combinações estatísticas como médias ou medianas, ou técnicas de fusão de dados. Essas abordagens visam fornecer uma avaliação mais completa da incerteza associada aos resultados do modelo e, consequentemente, melhorar a precisão das simulações (Hersbach, 2000). Um exemplo dos resultados de processamento de dados tipo ensemble é apresentado na Figura 14.

Figura 14 – Exemplo de resultados de processamento de dados por conjunto tipo *ensemble*.



Fonte: Climate Data, (2022)

Diversas metodologias podem ser adotadas para o processamento de dados por conjunto do tipo *ensemble*, entre algumas dessas metodologias com aplicações nas ciências ambientais pode-se citar:

- **Sistema de Previsão por Conjunto** - Consiste em gerar múltiplas previsões a partir de condições iniciais ligeiramente diferentes ou com variações nos parâmetros do modelo. Isso ajuda a minimizar a incerteza inerente nas condições iniciais e no próprio modelo.
- **Filtro de Kalman** - Combina a previsão do modelo com observações reais para melhorar a acurácia das previsões. Ele ajusta os estados do modelo com base

em novos dados observados, utilizando um conjunto de previsões para estimar um resultado consolidado.

- **Processamento de Multi-Modelos** – Este método combina as previsões de vários modelos diferentes. Cada modelo pode ter diferentes representações de processos hidrológicos e diferentes fontes de incerteza, e a combinação dos resultados pode melhorar a robustez das previsões.
- **Previsão de Vazões por Conjunto** – Este método utiliza dados climáticos históricos, como precipitação e temperatura, para compor um conjunto de cenários de entrada e gerar previsões probabilísticas de vazões em escalas temporais sazonais ou mensais.
- **Modelo de Ponderação Bayesiana** - Método que combina previsões de diferentes modelos de forma ponderada, onde os pesos são baseados na habilidade preditiva de cada modelo.

Lu et al. (2022) verificam a formação da estrutura de vento de um ciclone tropical com auxílio de um modelo determinístico e do Sistema de Previsão por Conjunto (EPS) do Centro Europeu de Previsões Meteorológicas de Médio Prazo (ECMWF). O estudo realizado indica que a estrutura dos ciclones tropicais prevista pelo ECMWF é adequada para o oeste do Pacífico Norte e o Mar da China Meridional.

A assimilação de dados com Filtro de Kalman (EnKF) foi utilizada por Sabzipour *et al.* (2023) para reduzir a incerteza associada às condições iniciais de modelo hidrológico semidistribuído em uma bacia hidrográfica no Canadá de modo a determinar as variáveis de estado mais relevantes para cada estação do ano.

Samuel *et al.* (2023) comparam conjuntos de multimodelos de projeções climáticas globais e regionais para avaliar as precipitações diárias em quatro grandes bacias hidrográficas na África em função de mudanças climáticas com aquecimento de 1,5 °C, 2,0 °C e 3,0 °C.

Petry *et al.* (2023) aplicam o método ESP para previsão de vazões nas bacias dos grandes rios da América do Sul aplicando o Modelo de Grandes Bacias (MGB). Li *et al.* (2022) comparam o Modelo de Ponderação Bayesiana clássico com adaptação denominada Rede Variacional Bayesiana de Memória de Longo Prazo tendo como entrada o resultado de 20 modelos hidrológicos para 4 bacias hidrográficas na China.

Os métodos apresentados podem ser combinados entre si, bem como estarem associados a técnicas de inteligência artificial e aprendizado em máquina

aplicando métodos de regressão, classificação, agrupamento ou otimização. Cada método, por sua vez, possui diversos algoritmos a exemplo de regressão linear, árvore de decisão, redes neurais artificiais, algoritmos genéticos, lógica fuzzy. O breve recorte apresentado apenas ilustra a infinidade de métodos e combinações cujas aplicações tem se tornado cada vez mais intensas na era da informação.

2.6 MODELOS HIDROLÓGICOS

2.6.1 Conceitos gerais

Segundo Sorooshian *et al.* (2008), um modelo é uma representação simplificada dos processos naturais do mundo real. Muitos modelos são usados para prever o comportamento dos vários processos hidrológicos, com base em parâmetros que definem as suas características.

Os parâmetros de entrada dos modelos podem ser aferidos em campo, calculados, estimados ou calibrados. Os modelos que calculam o escoamento superficial de uma bacia hidrográfica têm a área de drenagem e a precipitação como os parâmetros de entrada mais importantes.

Em função das necessidades de se realizar estimativas, monitoramento ou previsões dos fenômenos físicos relacionados ao ciclo hidrológico e ao balanço hídrico de água no solo, surgiram ferramentas computacionais com a finalidade de subsidiar estas informações. Tais ferramentas podem ser definidas como modelos hidrológicos, e provavelmente tiveram uma de suas primeiras versões consolidadas a partir de 1966 com o *Stanford Watershed Model IV* (SWM), segundo (Crowford e Linsley, 1966).


Segundo Singh e Woolhiser (2002), os modelos hidrológicos são desenvolvidos com um nível de detalhe variado para as várias fases do ciclo hidrológico a depender do problema em questão. A fundamentação matemática e física das componentes hidrológicas dos modelos evoluiu separadamente ao longo da história e vem sendo continuamente aperfeiçoada e integrada às ferramentas computacionais disponíveis.

Os modelos hidrológicos podem ser empregados em diversas áreas, desde à gestão de bacias hidrográficas, qualidade de água, operação de reservatórios, previsão de enchentes ou projetos de engenharia (Wurbs, 1998). Em uma abordagem clássica dos tipos de modelos apresentada por Chow, Maidment e Mays (1988) e Tucci (1998) indica-se que os modelos hidrológicos podem ser: físico ou abstrato;

conceitual ou empírico; estocástico ou determinístico; discreto ou contínuo; concentrado ou distribuído.

Outras classificações e subdivisões existem, a exemplo do modelo semidistribuído que considera a existências de sub-bacias como unidade de cálculo onde se aplicam os processos de separação da precipitação efetiva para determinar o escoamento superficial. A Figura 15 mostra um esquema do processo de separação da precipitação efetiva de um modelo concentrado, semidistribuído e distribuído, conforme apresentado por Cho, Engel e Merwade (2018). Alguns exemplos de modelos hidrológicos desenvolvidos após a década de 1960 bem como seus autores e ano de publicação são apresentados na Tabela 4.

Figura 15 – Diferenças entre a separação da precipitação efetiva em modelos concentrados, semidistribuído e distribuídos.



Fonte: Adaptado de Cho, Engel e Merwade (2018).

Apresentadas algumas definições, finalidades e classificação para os modelos hidrológicos é importante ressaltar que devido à rápida urbanização, industrialização, desmatamento, irrigação e outras mudanças no uso e ocupação do solo, várias mudanças também ocorrem nos sistemas hidrológicos e causam impactos direto nas simulações. Desse modo, diversos modelos hidrológicos foram desenvolvidos com características únicas e com objetivos de estimar o impacto das mudanças antrópicas

sobre pequenas áreas urbanas e seus projetos de drenagem ou sobre bacias hidrográficas complexas (Devi; Ganasri e Dwarakish, 2015).

Tabela 4 – Exemplos de modelos hidrológicos, autores e ano de publicação.

Modelo hidrológico	Autores
USGS Model	Dawdy <i>et al.</i> (1970)
Storm Water Management Model (SWMM)	Metcalf e Eddy (1971)
Physically Based Runoff Production Model (TOPMODEL)	Beven e Kirkby (1979)
Hydrologic Engineering Center – Hydrologic Modeling System (HEC-HMS)	Feldman (1981)
Soil Moisture Accounting Procedure (SMAP)	Lopes, Braga e Canejo (1982)
Simulator for Water Resources in Rural Basins (SWRRB)	Williams <i>et al.</i> (1985)
Modelo Hidrológico Auto-Calibrável (MODHAC)	Lanna e Schwarzbach (1989)
Generalized River Modeling Package – Systeme Hydrologique Europeen (MIKE-SHE)	Refsgaard e Storm (1995)
Soil Water Assessment Tool (SWAT)	Arnold <i>et al.</i> (1998)
Global Hydrology Model (GHM)	Anderson e Kavvas (2002)
Modelo de Grandes Bacias (MGB-IPH)	Collischonn <i>et al.</i> (2007)
Campus Agreste Watershed Model (CAWM)	Cirilo <i>et al.</i> (2020) e Gomes <i>et al.</i> (2021)

Fonte: Adaptado de Singh e Woolhiser (2002).

Modelos conceituais e determinísticos têm por definição a possibilidade de dispor de parâmetros ajustáveis para reproduzir o comportamento de uma bacia hidrográfica específica. De tal premissa surge uma importante abordagem sobre os modelos hidrológicos que relaciona um recorte específico do período simulado definido como período de calibração, e outro mais amplo compreendido como período de validação. Para tal é comum adotar indicadores de eficiência que relacionam os dados simulados e observados, conforme Nash e Sutcliffe (1970).

Ainda segundo Moriasi *et al.* (2007) é importante considerar, além do indicador de Eficiência de Nash-Sutcliffe (NSE), um conjunto de indicadores de desempenho que avaliem comportamentos distintos dos resultados, como a Raiz do Erro Quadrático Média (RMSE) ou o percentual de desvio e o viés P_{BIAS}. Moriasi *et al.* (2007) apresentaram faixas dos indicadores de modo a tornar o processo de calibração mais objetivo e auxiliar a comparação entre modelos.


2.6.2 Modelagem hidrológica quase-distribuída

Ao observar os modelos hidrológicos concentrados, semidistribuídos e distribuídos, além do método de separação da precipitação efetiva visto na Figura 15, surge outra distinção relevante em função da necessidade de propagação do escoamento ao longo da bacia hidrográfica. Enquanto o modelo concentrado não possui o objetivo de transportar e defasar hidrogramas, o modelo semidistribuído necessitará reunir, transportar e amortecer picos de cheias em função das contribuições das sub-bacias e efeitos de reservatórios. Os principais métodos utilizados para calcular os referidos efeitos, conhecidos como *routing*, podem ser observados em Puls (1928), USBR, (1949) e Cunge (1969). Lighthill e Whitham (1955) desenvolveram o método da Onda Cinemática (*Kinematic Wave*) aplicáveis a trechos de rios mais extensos.

Os modelos distribuídos, por sua vez, possuem características distintas ao observar o balanço hídrico e os resultados de suas unidades de cálculo. Nesse caso, a concepção distribuída convencional considera que a área simulada é subdividida em células, e cada célula será uma unidade computacional para qual os processos hidrológicos serão calculados.

Uma concepção da malha computacional dos modelos hidrológicos distribuídos pode ser observada na Figura 16, onde ilustra-se as camadas de vegetação, de solo e subterrâneas utilizadas para o balanço hídrico em cada célula; a contribuição e propagação do escoamento entre células; e um conjunto de células que compõem o exutório da bacia.

Figura 16 – Malha computacional de modelo hidrológico distribuído.



Fonte: Adaptado de Li *et al.* (2019).

No entanto, se um modelo é realmente distribuído, todos os aspectos do modelo devem ser distribuídos, incluindo parâmetros, condições iniciais e de contorno, dados de entrada e os resultados. Embora as equações matemáticas embutidas nos processos hidrológicos modelados sejam contínuas no tempo e frequentemente no espaço, muitas das soluções analíticas são obtidas a partir de simplificações das condições de contorno e através de métodos numéricos como diferenças finitas e elementos finitos (Singh; Woolhiser, 2002).

Segundo Bhatt, Kumar, Duffy (2014), modelos hidrológicos distribuídos demandam parâmetros relacionados à topografia; geologia; tipologia, uso e ocupação do solo; precipitação e outras condições meteorológicas, para todos os elementos da malha dentro do domínio do modelo. Em função da heterogeneidade inerente aos dados, o processo de estimativa e calibração desses parâmetros é uma etapa que consome muito tempo e está sujeita a erros quando não realizada a partir de técnicas de geoprocessamento.

Clark (1945) propôs um método para determinar hidrogramas unitários sintéticos de bacias hidrográficas aplicando conceitos de isócronas e o método do Reservatório Linear. As isócronas consistem em regiões homogêneas em relação ao tempo necessário para o escoamento atingir um ponto exutório. Normalmente,

assume-se que a velocidade do escoamento é uniforme e que o tempo necessário para o escoamento atingir o exutório é diretamente proporcional à distância.


No modelo de Clark, o componente relacionado ao Reservatório Linear representa os efeitos de atenuação do escoamento, em função do armazenamento na bacia hidrográfica. A vazão do reservatório linear é calculada de forma simplificada a partir da equação de continuidade. O Método de Clark resulta em três componentes distintos: o tempo de concentração (T_c), o coeficiente de atenuação e armazenamento (R), e o histograma área x tempo representando as isócronas (Kull; Feldman, 1998).

Kull, Feldman (1998) apresentaram o método ModClark, que veio a ser desenvolvido como uma adaptação da técnica de hidrograma unitário sintético de Clark, para utilizar dados de precipitação distribuídos espacialmente. O Centro de Engenharia Hidrológica dos Estados Unidos (HEC – Hydrologic Engineering Center) implementou o método ModClark para viabilizar o uso de dados do conjunto de 158 radares meteorológicos Doppler conhecidos como NEXRAD (*Next-Generation Radar*).

A modelagem hidrológica em que se aplica o método ModClark pode ser considerada quase-distribuída, uma vez que considera uma malha computacional distribuída para esta malha, calcula a precipitação efetiva e o escoamento superficial, atenua os hidrogramas e considera os efeitos de armazenamento na bacia hidrográfica através do método do Reservatório Linear, mas aplica uma convolução de hidrogramas e concentra os resultados por sub-bacia, conforme ilustrado na Figura 17. Neste método a precipitação é o único dado de entrada realmente distribuído.

Os modelos distribuídos e quase-distribuídos favoreceram a integração das bases de dados de precipitação por satélite (Chintalapudi; Sharif; Xie, 2014) e radares meteorológicos Doppler (Shehu; Haberlandt, 2021) aos modelos hidrológicos.

Figura 17 – Esquema computacional do método quase-distribuído ModClark.



Fonte: Adaptado de Kull e Feldman (1998).

Especificamente sobre o método ModClark, pode-se citar as aplicações de Koutroulis, Tsanis (2010) sobre estimativas da vazão de pico de eventos extremos em bacias hidrográficas com poucos dados observados e Cho (2020) que integrou dados NEXRAD e o método ModClark através de linguagem de programação ArcPy.

2.6.3 Modelo hidrológico HEC-HMS

O modelo hidrológico HEC-HMS (Hydrologic Engineering Center – Hydrologic Modeling System) teve sua primeira versão apresentada por Feldman (1981), na ocasião recebendo o nome de HEC-1. Desde sua primeira versão, o HEC-HMS teve o seu desenvolvimento associado e impulsionado pelo Centro de Engenharia Hidrológica (HEC), vinculado ao Corpo de Engenheiros do Exército dos Estados Unidos (USACE – United States Army Corps of Engineers).

Ao longo de 40 anos de aperfeiçoamentos e atualizações, o modelo hidrológico HEC-HMS encontra-se com sua versão 4.12 lançada em julho de 2023. As sucessivas atualizações passaram a detalhar a representação física das bacias

hidrográficas a partir de elementos hidrológicos, sendo sub-bacias, rios, confluências, reservatórios, desvios, fontes e exutórios os elementos principais.

Sete diferentes métodos estão disponíveis para simular as perdas por infiltração. Entre as opções dos métodos de perdas para simulações discretas inclui-se os métodos Initial Constant, Curve Number (CN) SCS, Exponencial, Green Ampt e Smith Parlange. Ou métodos aplicáveis às simulações contínuas como Déficit Constant, Soil Moisture Accounting (SMA). Outros sete métodos também podem ser utilizados para transformar o excesso de precipitação em escoamento superficial. Entre os métodos de hidrograma unitário (HU) disponíveis inclui-se Clark, Snyder, SCS, ModClark, Kinematic Wave, e ainda é possível que o usuário insira um HU específico ou ordenadas do gráfico da Curva S (HEC, 2023).


O HEC-HMS dispõe de cinco métodos para representar as contribuições do escoamento de base. Para vazão de base podem ser aplicados os métodos Recessão Exponencial, Recessão Limitado, Constante Mensal, Reservatório Linear ou Boussinesq Não Linear. Outros oito métodos aplicam-se à propagação de hidrogramas na calha do rio (*Routing*), são eles: Método de Atenuação (*Lag*), Atenuação e Translação (*Lag e K*), Muskingum, Muskingum-Cunge, Straddle Stagger, Puls Modificado, Normal Depth e Kinematic Wave (HEC, 2023).

O HEC-HMS pode considerar efeitos de interceptação da vegetação, perdas no preenchimento de depressões no terreno, e realizar a simulação de reservatórios ou lagos, estruturas hidráulicas como vertedouros, comportas, descargas de fundo e bombeamentos.

Sobre o balanço meteorológico em relação à evapotranspiração, é possível considerar uma evaporação média anual ou média mensal a ser descontada no balanço hídrico, aplicar outros métodos como Hamon, Hargreaves, Penman Monteith, Priestley Taylor, ou ainda inserir uma série histórica de evapotranspiração (HEC, 2023).

A partir de versão 4.4, o modelo HEC-HMS passou a disponibilizar ferramentas de geoprocessamento, permitindo delimitar sub-bacias a partir de Modelo Digital do Terreno (MDT), calcular características físicas e editar a geometria da área estudada conforme janela do programa ilustrada na Figura 18.

Figura 18 – Janela de edição e seleção de ferramentas do modelo hidrológico HEC-HMS.



Fonte: HEC (2023).

Inúmeros trabalhos foram publicados demonstrando aplicações do HEC-HMS, como Dariane, Javadianzadeh, James (2016) propondo algoritmos de autocalibração; Gumindoga *et al.* (2017) simulando bacias hidrográficas sem dados observados de vazão; Gao, Carbone, Lu (2018) e Gunathilake *et al.* (2020) avaliando diferentes bases de dados de precipitação.


2.6.4 Modelo hidrológico CAWM V

Segundo Cirilo *et al.* (2020), o CAWM – Campus Agreste Watershed Model foi desenvolvido com o objetivo inicial de simular o escoamento superficial em bacias hidrográficas de regiões semiáridas, de modo a trazer na versão do CAWM IV uma alternativa metodológica para esta região, e aproveitando procedimentos mais modernos de entrada e saída de dados e a possibilidade de aproveitamento de informações geradas por técnicas de geoprocessamento sobre bases espaciais como SRTM – *Shuttle Radar Topography Mission* e o Programa Pernambuco Tridimensional – PE3D.

Uma das premissas do CAWM é a simplicidade e poucos parâmetros a calibrar, sempre que possível incorporando parâmetros de significado físico, através de um modelo hidrológico conceitual, contínuo, determinístico, concentrado e que pode ser facilmente utilizado em planilha Excel, cujas ferramentas de otimização auxiliam sua calibração. A versão CAWM V propõe ampliar a modelagem hidrológica de bacias semiáridas e úmidas aplicações para bacias.

O CAWM V tem seu esquema representado na Figura 19 e possui em sua conceituação dois reservatórios: um reservatório do solo (S) e o reservatório da calha fluvial (R). Neste modelo, o balanço chuva-evaporação é feito de forma imediata. Se houver precipitação (P) suficiente, toda a evapotranspiração é atendida e descontada. Se não, toda a precipitação é considerada como evapotranspiração direta (E_d) e registra-se uma parcela não atendida (E_n), que poderá ser total ou parcialmente retirada do reservatório do solo (S) (Ferraz, 2019).

Figura 19 – Esquema gráfico do balanço hídrico no modelo CAWM V.



Fonte: Ferraz (2019).

No CAWM, a precipitação efetiva é dividida em três partes, de modo a gerar contribuição de vazão representadas pelo escoamento superficial direto (F_d); o escoamento da água armazenada no solo (F_s), referente a percolação; e o escoamento (F_r) gerado a partir da água acumulada no reservatório (R). As perdas são descontadas ao fim do balanço em uma parcela denominada (F_L). A versão CAWM V incluiu uma componente para o escoamento de base de rios perenes.

Tendo em vista que a primeira publicação de uma versão consolidada do CAWM ocorreu em 2020, pode-se entender como sendo um modelo hidrológico recente e em desenvolvimento. As aplicações do CAWM se deram inicialmente em

bacias hidrográficas do Estado de Pernambuco, havendo trabalhos nas bacias dos rios Capibaribe (Gomes, 2019; Gomes *et al.*, 2021), Sirinhaém (Ferraz, 2019) e Ipojuca (Silva, 2019), havendo outros trabalhos em andamento para a bacia do rio São Francisco e as grandes bacias da região amazônica.

Cabe ainda destacar que, mesmo havendo maior quantidade de informações associadas aos modelos hidrológicos distribuídos, não existe clareza entre a relação dos detalhes das variáveis de entrada e dos resultados obtidos. Enquanto Mazion, Yen (1994) demonstram vantagens sobre os efeitos de discretização da precipitação dos modelos, Vanteenkiste *et al.* (2014) avaliam o desempenho de cinco modelos concentrados e cinco modelos distribuídos, onde todos os modelos avaliados foram considerados adequados, para os quais foram elencados pontos positivos e negativos.

2.7 TRABALHOS CORRELATOS

Considerando os temas centrais abordados neste trabalho relacionados as precipitações estimadas por sensoriamento remoto e combinações de processamentos que geram os produtos CHIRPS, IMERG e PERSIANN, e aplicações relacionadas à assimilação de dados na modelagem hidrológica. Buscou-se compor referencial teórico a partir de buscas estruturadas às bases de dados *Scopus*, *Google Scholar*, Periódicos Capes, além de repositórios de teses e dissertações.

Preferencialmente foram consultadas publicações de artigos em revistas de circulação internacional e elevado fator de impacto na comunidade científica. Também foram priorizadas as publicações consideradas recentes, publicadas entre os anos de 2018 e 2024.

Na etapa de referencial teórico foram analisados cerca de 120 artigos de revistas de circulação internacional, e que estão referenciados neste trabalho, dos quais 70 podem ser consideradas publicações recentes. Algumas destas publicações estão descritas a seguir como trabalhos correlatos, por possuírem maior similaridade quando observadas com recortes desta tese.


Shen *et al.* (2020) apresentam análise global das bases de dados de precipitação por sensoriamento remoto CHIRP e CHIRPS para o período de 1981 a 2016. Entre os principais resultados da avaliação destaca-se que as duas séries de dados possuem tendências negativas até os anos 2000 (-5,93% para CHIRP e

-2,01% para CHIRPS) quando, após esse período, foram aplicadas técnicas de correção de viés no processamento nativo dos dados.

O trabalho inclui avaliações estatísticas regionais, análise temporal e distribuição de intensidade das precipitações. A base de dados CHIRPS, ajustada com os dados do GPCC, mostrou resultados superiores na maioria das regiões, como Estados Unidos, Europa, África, Austrália e América do Sul.

Shen et al. (2020) deixam evidente que existem padrões geoespaciais e temporais sobre os erros dos produtos CHIRPS, conforme Figura 20 onde observa-se que a amplitude dos erros em função da latitude é menor nas regiões tropicais entre o equador e as latitudes 10° N a 10° S.


Figura 20 – Erros sistemáticos em função da latitude para a base de dados CHIRP e CHIRPS.



Fonte: Shen et al. (2020).

Sobre as variações sazonais, observa-se na Figura 21 comportamentos distintos entre as regiões estudadas e os meses do ano, justificando que avaliações regionais são relevantes para identificar as discrepâncias e possíveis correções locais, e ainda indicando que os dados da América do Sul possuem resultados mais satisfatórios no período estudado.

Figura 21 – Variação de erros sistemáticos da base de dados CHIRP e CHIRPS por regiões e períodos trimestrais.



Fonte: Shen *et al.* (2020).


Beck *et al.* (2019) apresentam análise da acurácia de 26 séries de precipitações estimadas por sensoriamento remoto para o território dos Estados Unidos, no período de 2008 a 2017. A avaliação dos dados foi feita em relação a série de precipitações Stage IV obtidas por um conjunto de radares norte-americanos, conforme ilustrado na Figura 22.

Os resultados avaliaram a performance das séries a partir de condições específicas a exemplo da incorporação de dados observador e reprocessamento, período seco e chuvoso, e comparativo entre as séries. A conclusão indica melhor performance para as séries não corrigidas ERA5-HRES e IMERG HHE V05. Para as séries com pós-processamento de precipitações observadas o melhor desempenho foi para a série MSWEP V2.2.

Lober *et al.* (2023) analisam as precipitações da série de dados IMERG para o território do Canadá e Alaska no período de 2000 a 2020, analisando dados mensais e diários, e propondo uma correção continental de BIAS em função da altitude.

Os resultados indicam que a subestimação nos dados de satélite aumenta linearmente com o aumento da altitude, acima de 500 m na escala continental e para todas as elevações na escala regional. O BIAS varia sazonalmente com maior amplitude no verão e menores erros inverno. A correção do BIAS continental mensal reduz o viés absoluto em 16% e o RMSE em 6%, enquanto a correção de BIAS diária melhora o viés absoluto em 17%, mas degrada ligeiramente o RMSE em 2%.


Figura 22 – Indicador de eficiência Kling-Gupta (KGE) para 26 séries de precipitação estimadas por sensoriamento remoto.



Fonte: Beck *et al.* (2019)

Castro e Maidment (2020) apresentam uma ferramenta computacional denominada HMS-PrePro, com a finalidade de obter dados de vários sites e processá-los para inicialização rápida do modelo hidrológico HEC-HMS. O conjunto de funções utiliza a delimitação da bacia hidrográfica e o Modelo Digital do Terreno (MDT) para extrair dados como uso, ocupação e tipos de solos, áreas impermeáveis e outros parâmetros que servem de entrada do HEC-HMS. Na Figura 23 tem-se o fluxo de processamento da ferramenta computacional HEC-PrePro.

Figura 23 – Fluxo de processamento de ferramenta computacional GIS para inicialização rápida do modelo hidrológico HEC-HMS.




Fonte: Castro e Maidment (2020).

Um paralelo feito a partir do trabalho de Castro, Maidment (2020) refere-se ao fato de que a ferramenta desenvolvida a partir das bases de dados por ela obtidas aplicam-se ao recorte territorial dos Estados Unidos. Tal fato justifica a necessidade de estudos que envolvam as bases de dados, e características de outras regiões. Assim, também, é relevante conhecer o desempenho dos modelos hidrológicos a partir da inicialização rápida com esse conceito e aplicando dados abertos.

Gunathilake *et al.* (2020) exploram a modelagem hidrológica para uma bacia hidrográfica localizada no norte da Tailândia, utilizando o programa computacional HEC-HMS. As bases de dados de precipitação utilizadas incluem os dados PERSIANN, PERSIANN-CCS, PERSIANN CDR, TRMM-3B42, TMPA-RT e IMERG, e compreendem os anos de 2003 a 2010.

Os coeficientes de Determinação (R^2) e Nash-Sutcliffe (NSE) podem ser vistos na Figura 24 para os períodos de calibração e validação, em simulações diárias e mensais. Tais resultados revelam o desafio de incluir dados de precipitação estimados por sensoriamento remoto à modelagem hidrológica, onde observa-se resultados gerais satisfatórios para o período de calibração com dados mensais e resultados com NSE abaixo de 0,4 e predominantemente insatisfatórios para todas as bases de dados avaliadas em uma bacia hidrográfica de 13.000 km².

Figura 24 – Modelagem hidrológica com diferentes bases de precipitação e valores de R^2 e NSE. (a) calibração (2003-2006) de períodos diários; (b) validação (2007-2010) de períodos diários; (c) calibração de períodos mensais e (d) validação de períodos mensais.




Fonte: Gunathilake *et al.* (2020).

Le *et al.* (2020) apresenta estudo utilizando oito conjuntos de dados de precipitação estimada por satélite com os produtos TRMM-TMPA 3B42RT, TRMM-TMPA 3B42V7, GPM IMERGE-V6, GPM IMERGF-V6, CHIRP 2.0, CHIRPS 2.0, PERSIANN e PERSIANN-CDR. Esses dados foram utilizados em seis bacias hidrográficas com áreas de 694 a 6.042 km², representando seis subzonas climáticas do Vietnã, durante o período de 2002 a 2017. O trabalho realizou uma comparação das precipitações estimadas por sensoriamento remoto e dados observados em períodos secos e úmidos, e a análise simulações hidrológicas no modelo hidrológico SWAT, calibrado para cada uma das bases de precipitação.

A primeira avaliação demonstrou o melhor desempenho das bases de precipitações pós-processadas e corrigidas com dados observados em campo. Verificou-se melhor desempenho da série CHIRPS em períodos secos e da série IMERGF em períodos úmidos.


Sobre as vazões simuladas a partir das diferentes bases de dados de precipitação derivadas de satélite, tem-se no trabalho de Le *et al.* (2020), uma contribuição relevante sobre o potencial das precipitações SPE, onde na Figura 25 e na Figura 26, observa-se a predominância de desempenho satisfatório para as simulações com dados IMERG-F, bem como Coeficientes de Nash-Sutcliffe (NSE) superiores a 0,5 para os períodos de validação de todas as bases.

Figura 25 – Indicadores de Nash-Sutcliffe para vazões simuladas a partir de oito bases de precipitações derivadas de satélite. S – Satisfatório. G – Bom. VG – Muito bom.



Fonte: Le et al. (2020).


Figura 26 – Dados de vazão observada e simulada a partir de diferentes bases de dados de precipitações devidas de satélite. Vazões simuladas com (a) dados de chuva observados, (b) TRMM-TMPA, (c) IMERG, (d) CHIRP e (e) PERSIANN.



Fonte: Le et al. (2020).

Peng et al. (2021) realizam estudo na bacia do Lago Bosten, noroeste da China, avaliando a precisão e a aplicabilidade hidrológica de seis conjuntos de dados de precipitação baseados em satélite: PERSIANN-CDR, CHIRPS, CMORPH, GSMaP, GPM e TMPA. Foram aplicados sete indicadores de performance para as séries de precipitação e quatro para as séries de vazão obtidas após a modelagem hidrológica no SWAT, conforme esquema geral ilustrado na Figura 27.

Figura 27 – Esquema geral de análise de precipitações estimadas por sensoriamento remoto e modelagem hidrológica no SWAT para bacia hidrográfica na China.




Fonte: Peng et al. (2021).

Os principais resultados indicaram que o GPM e o CDR foram os melhores conjuntos de dados para as avaliações de precisão da precipitação em escala diária e mensal, respectivamente. Todos os conjuntos de dados tenderam a ter um melhor desempenho no verão, enquanto o CDR e o CHIRPS tiveram um bom desempenho no inverno. Avaliando o desempenho hidrológico dos dados não corrigidos e corrigidos, todos os conjuntos de dados têm o potencial de fornecer dados de entrada aplicáveis a modelagem hidrológica.

Os estudos apresentados ilustram a diversidade de combinação que as séries de precipitação estimada por sensoriamento remoto podem fornecer para a comunidade científica, de modo a demandar robusta avaliação de acurácia, métodos de correção de BIAS e aplicabilidades no contexto de assimilação de dados através de modelagem hidrológica.

O método de processamento de dados por conjunto “*ensemble*” tem comumente ocorrido de forma associada às ferramentas de inteligência artificial e aprendizado de máquina para melhoria das simulações e previsões hidrológicas. Um exemplo desta integração pode ser visto no trabalho publicado por Wegayehu e Muluneh (2024) onde apresenta-se uma metodologia que integra oito modelos hidrológicos que utilizam técnicas de aprendizado de máquina e na sequência adota-se três ferramentas de meta-aprendizado para realizar o que se definiu como super-ensemble, conforme esquema ilustrado na Figura 28.

Figura 28 – Esquema geral de processamento por conjunto de precipitações estimadas por sensoriamento remoto e modelagem hidrológica através de inteligência artificial.



Fonte: Wegayehu e Muluneh (2024).

A ferramenta desenvolvida busca alternativas para modelagem hidrológica com poucos dados observados de modo a incorporar bases de dados geoespaciais (NDVI, NDWI e EVI) e três séries de precipitações estimadas por sensoriamento remoto (IMERG-F, CHIRPS e MSWEP), associadas às técnicas de aprendizado de máquina.

Os principais resultados indicaram que os três métodos de super-ensemble avaliados tiveram melhor desempenho que qualquer modelo analisado individualmente, bem como tais resultados foram 24% superiores ao modelo conceitual HBV-Light.

3 MATERIAIS E MÉTODOS


Os materiais e métodos empregados nesta pesquisa podem ser compreendidos se observados as seguintes etapas:

(1) obtenção de precipitação observada em pluviômetros e precipitação derivada de sensoriamento remoto; processamento de dados para correção de viés nas séries de precipitação; e armazenamento em bando de dados DSS (*Data Storage System*) reconhecido pelo modelo HEC-HMS.

(2) delimitação de bacias hidrográficas; processamento de dados para extração de parâmetros de entrada e assimilação no modelo hidrológico HEC-HMS.

(3) modelagem hidrológica quase-distribuída aplicando o método ModClark no HEC-HMS; simulações hidrológicas com parâmetros extraídos de dados físicos obtidos por sensoriamento remoto e precipitações observadas; simulações hidrológicas a partir de diferentes bases de precipitação estimadas por satélites; correção de viés das séries de vazão através do método ensemble. Na Figura 29 ilustra-se os fluxos das etapas gerais desta pesquisa.

Figura 29 - Fluxo geral de processamento de dados de precipitação, extração de parâmetros geoespaciais e modelagem hidrológica.



Fonte: O Autor (2024).

A seguir apresenta-se descritivo das ferramentas computacionais, métodos, considerações e premissas adotados nas etapas deste trabalho.

3.1 ÁREA DE ESTUDO

3.1.1 Unidades de planejamento hídrico

O estado de Pernambuco possui uma área territorial de 98.068 km² segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2020). Enquanto concepção de planejamento e gestão dos recursos hídricos, foi a partir do primeiro Plano Estadual de Recursos Hídricos (PERH), elaborado em 1998, que o estado foi dividido em 29 Unidades de Planejamento Hídrico (UP). Adotou-se neste trabalho esta versão do Plano Estadual por ser a versão vigente no início dos estudos.

As UP's são subdivididas em rios litorâneos que possuem foz no oceano Atlântico: UP01 - Goiana, UP02 - Capibaribe, UP03 - Ipojuca UP04 - Sirinhaém, UP05 - Una, UP06 – Mundaú; e rios interiores: UP07 – Ipanema, UP08 – Moxotó, UP09 – Pajeú, UP10 – Terra Nova, UP11 – Brígida, UP12 – Garças e UP13 – Pontal, que drenam suas águas para o rio São Francisco (Pernambuco, 1998).


Outros grupos de rios litorâneos e interiores, respectivamente identificados pelos prefixos GL e GI, juntamente com o arquipélago de Fernando de Noronha, compõem as 29 UP's vigentes em Pernambuco. A atualização do Plano Estadual de Recursos Hídricos propôs nova delimitação de UP's, não adotadas neste trabalho.

A área de estudo é composta por 15 unidades de planejamento hídrico, conforme ilustrado na Figura 30, sendo a unidade 06 o resultado do agrupamento da UP06 - Mundaú com o Grupo de Rios Interiores 01 (GI-01). Os grupos de rios litorâneos mais importantes referentes as unidades UP14 (GL-01) e UP15 (GL-02) fazem parte da área de estudo.

Tais unidades tiveram as séries históricas de precipitações avaliadas e as vazões simuladas através de modelagem hidrológica, somando uma área de 89.524 km².

As sub-bacias e a rede de drenagem das 15 bacias hidrográficas modeladas foram exportadas como arquivo vetorial *shapefile*, sendo estas sub-bacias utilizadas para obtenção dos parâmetros de entrada do HEC-HMS, obtidos a partir de médias sobre os conjuntos de dados físicos e de sensoriamento remoto.

Figura 30 – Área de estudo e unidades de planejamento hídrico avaliadas.



*Bases cartográficas contínuas - Brasil 1:250.000 (IBGE, 2019).


Fonte: O Autor (2024).

3.1.2 Clima

A área de estudo está inserida nas regiões climáticas de Clima Tropical Zona Equatorial e Clima Tropical Nordeste Oriental. O Clima Tropical Zona Equatorial é caracterizado como quente quanto às temperaturas médias, com valores maiores que 18 °C em todos os meses do ano, predominância de clima semiárido, com cerca de 7 a 10 meses secos no ano (IBGE, 2002).

A região de Clima Tropical Nordeste Oriental é predominantemente quente quanto às temperaturas médias, com valores maiores que 18 °C em todos os meses do ano, predominância de clima semiúmido, com cerca de 4 a 8 meses secos no ano. Áreas específicas dessa região são caracterizadas por temperaturas subquentes, onde ocorrem temperaturas médias de 15 a 18 °C em pelo menos 1 mês. A faixa do litoral se distingue pela ocorrência de clima úmido, conforme ilustrado na Figura 31.

Figura 31 – Regiões climáticas do estado de Pernambuco e área de estudo.



Clima Tropical Zona Equatorial

- Tropical Zona Equatorial, quente - média > 18° C em todos os meses, semiúmido 4 a 5 meses secos
- Tropical Zona Equatorial, quente - média > 18° C em todos os meses, semiárido 6 meses secos
- Tropical Zona Equatorial, quente - média > 18° C em todos os meses, semiárido 7 a 8 meses secos
- Tropical Zona Equatorial, quente - média > 18° C em todos os meses, semiárido 9 a 10 meses secos

Clima Tropical Nordeste Oriental

- Tropical Nordeste Oriental, quente - média > 18° C em todos os meses, superúmido sem seca
- Tropical Nordeste Oriental, quente - média > 18° C em todos os meses, superúmido subseca
- Tropical Nordeste Oriental, quente - média > 18° C em todos os meses, úmido 1 a 2 meses secos
- Tropical Nordeste Oriental, quente - média > 18° C em todos os meses, úmido 3 meses secos
- Tropical Nordeste Oriental, quente - média > 18° C em todos os meses, semiúmido 4 a 5 meses secos
- Tropical Nordeste Oriental, quente - média > 18° C em todos os meses, semiárido 6 meses secos
- Tropical Nordeste Oriental, quente - média > 18° C em todos os meses, semiárido 7 a 8 meses secos
- Tropical Nordeste Oriental, subquente - média entre 15 e 18° C em pelo menos 1 mês, úmido 3 meses secos
- Tropical Nordeste Oriental, subquente - média entre 15 e 18° C em pelo menos 1 mês, semiúmido 4 a 5 meses secos

*Informações Ambientais - Clima 1:5.000.000 (IBGE, 2002).


Fonte: O Autor (2024).

A região de Clima Tropical Zona Equatorial também pode ser usualmente denominada de Sertão, enquanto a região de Clima Tropical Nordeste Oriental pode ser compreendida pelo Agreste, Zona da Mata e Litoral, sendo na faixa litorânea e parte as Zona da Mata as áreas de clima úmido. A UP02, correspondente a bacia do rio Capibaribe, é a unidade com maior variabilidade climática entre as bacias estudadas.

3.1.3 Precipitações

As precipitações anuais médias em Pernambuco variam de 400 a 1900 mm, para o período de 1977 a 2006, conforme recorte do Atlas Pluviométrico do Brasil, publicado pelo Serviço Geológico do Brasil (CPRM, 2011), e ilustrado na Figura 32.

Figura 32 – Precipitações médias anuais em Pernambuco, entre os anos de 1977 e 2006.



*Atlas Pluviométrico do Brasil (CPRM, 2011).

Fonte: O Autor (2024).

Ao observar as Unidades de Planejamento Hídrico tem-se as maiores precipitações sobre as unidades UP04, UP14 e UP15, com precipitações variando de 800 a 1.900 mm. A UP06 e UP07 estão completamente inseridas na região Agreste, com predominância de precipitações na faixa de 500 a 800 mm. A UP01, UP02, UP03 e UP05 são as bacias hidrográficas que possuem maior amplitude entre as precipitações mínimas e máximas, compreendendo toda a faixa de 400 a 1.900 mm em alguma porção de suas delimitações.


A região do Sertão possui precipitações variando de 400 a 800 mm, e neste trabalho compreende a UP08, UP09, UP10, UP11, UP12 e UP13.

3.2 BASES DE DADOS DE PRECIPITAÇÃO E GEOPROCESSAMENTO

3.2.1 Precipitação de estações pluviométricas

Para avaliação das precipitações derivadas de sensoriamento remoto tomou-se como referência um conjunto de dados históricos diários de 462 pluviômetros. Deste total tem-se 399 pluviômetros convencionais e 62 telepluviômetros, obtidos no sítio eletrônico da Agência Pernambucana de Águas e Clima (Apac) e 01 pluviômetro convencional localizado no estado de Alagoas, referente ao posto São José da Laje (Código 936112), cuja série foi obtida através do sistema Hidroweb, da Agência Nacional de Águas e Saneamento Básico (ANA). Na Figura 33 ilustra-se a rede de postos pluviométricos convencionais e automáticos da Apac, acrescida do posto em Alagoas. A lista de postos, incluindo nome, código Apac, coordenadas geográficas e tipo do posto encontra-se no Anexo A.

Figura 33 – Rede de postos pluviométricos da Apac.



Fonte: O Autor (2024).

O conjunto de séries pluviométricas compreendem o período de 01 de janeiro de 1990 a 31 de dezembro de 2020, e representam pontualmente recortes temporais distintos, podendo ou não terem dados válidos em uma determinada data.

A base de dados foi organizada em um banco com a extensão CSV (*character-separated values*) disposto em estrutura semelhante ao banco de dados

Hidroweb, onde cada linha possui a série de dados mensais, e as colunas possuem a série de dados diários. O banco CSV foi utilizado como entrada para processamento de um *script* de comandos (ANEXO B), desenvolvido em linguagem *Python*, e executado através do ambiente integrado de desenvolvimento *Python* (IDLE).

A saída do código *Python* consiste na separação do banco em arquivos CSV para cada dia da série, listando postos, coordenadas e precipitações diárias, de modo a permitir a interpolação dos dados e conversão em arquivo matricial tipo *raster*. A interpolação dos dados de precipitação foi realizada através do método IDW (*inverse distance weighting*), aplicando o parâmetro de força padrão igual a 2.


Sobre o processamento em *Python*, ressalta-se a importância em verificar a compatibilidade e notações das células vazias nas séries, combinada com a definição do separador decimal do sistema operacional utilizado. É importante ainda observar se as células vazias não estão sendo substituídas por zero ao fim do processamento, o que pode ocasionar minimização dos resultados.

A interpolação IDW, individualmente, é um procedimento simples, resolvido por diversas ferramentas de geoprocessamento. No entanto, considerando que entre 1990 e 2020 existem 11.322 dias, tornou-se necessário desenvolver uma rotina computacional para esta etapa. A solução adotada foi desenvolvida com auxílio do programa ArcGIS 10.7, através do ambiente *Model Builder*, apropriado para integração de ferramentas e processamentos em série.

A opção de processamento adotada no *Model Builder*, para as precipitações de pluviômetros, consiste de uma sequência de ferramentas iniciando com a saída CSV do código Python como entrada, interpolando os pontos com a ferramenta IDW, alinhando as células a malha computacional 2 por 2 quilômetros utilizada no método ModClark do HEC-HMS, e como primeira saída uma série de arquivos com a extensão ASC (*American Standard Code for Information Interchange*), georreferenciada em coordenadas projetadas UTM, no fuso 24S. A área de estudo está inserida entre os fusos 24 e 25S, sendo o fuso 24S predominante.

Em paralelo, como segunda saída tem-se uma série de arquivos matriciais com a extensão TIFF, que representam a chuva média de cada dia em cada uma das unidades de planejamento hídrico estudada, conforme fluxo de processamento ilustrado na Figura 34.

Figura 34 – Fluxo de processamento dos dados de precipitação de estações pluviométricas.



Fonte: O Autor (2024).

A série de arquivos ASC foi adicionada a um arquivo no formato DSS (*Data Storage System*) reconhecido pelo modelo HEC-HMS, a partir da execução do arquivo executável “*asc2dssGrid.exe*”. As séries da chuva média a partir dos pluviômetros compõem a série de dados observados para avaliação da eficiência das demais precipitações derivadas de sensoriamento remoto, conforme detalhado a seguir.

Sobre o processamento no *Model Builder* com muitas etapas e grandes séries de dados, destaca-se que apesar do resultado positivo, o desempenho pode não ser considerado inteiramente satisfatório, uma vez que o processamento vai tornando-se lento até ocorrer a paralisação do processo, demandando que o usuário tenha que retirar os arquivos processados da pasta de saída e continuar o processo por algumas vezes.

Em função da quantidade, distribuição espacial e temporal das estações pluviométricas e suas séries históricas, não foi realizado preenchimento de falhas. Pode-se entender que parte das falhas são minimizadas em função da interpolação, quando os postos vizinhos possuem dados consistentes.


3.2.2 Precipitação CHIRPS

A série de precipitação diária da base de dados CHIRPS 2.0 foi obtida para o período entre 01 de janeiro de 1990 e 31 de dezembro de 2020, através da plataforma ClimateServ (NASA, 2020). Os dados brutos foram recortados a partir de um polígono desenhado no mapa, salvos na extensão TIF e com resolução espacial de 5 km. Alerta-se para as situações em que é necessário ampliar a área de interesse para os resultados não recobrirem uma área menor que a desenhada no mapa.

O processamento das séries de precipitações da base de dados CHIRPS 2.0 pode ser considerado mais simples em relação aos dados observados nos pluviômetros, uma vez que o processo já se inicia a partir de dados matriciais. Nesta etapa de processamento optou-se por separar a sequência de ferramentas do *Model Builder* em partes menores, uma para converter os dados TIF em dados com a extensão ASC, e outra para calcular a chuva média de cada bacia hidrográfica analisada.

O fluxo de processamento dos dados de precipitação da série CHIRPS é ilustrado na Figura 35. Nesse fluxo mostra-se com mais detalhes a conversão do sistema de projeção, o script “*asc2dssGrid.exe*”, e a utilização da ferramenta *Sample* utilizada para extração da série da chuva média em formato de tabela a partir de um ponto no mapa, no caso o centroide das bacias.

Figura 35 – Fluxo de processamento de dados de precipitação da série CHIRPS 2.0.



Fonte: O Autor (2024).

3.2.3 Precipitação PERSIANN

A série de precipitação diária da base de dados PERSIANN foi obtida através da plataforma CHRS Data Portal (<http://chrdata.eng.uci.edu/>) para os produtos PERSIANN CDR, PERSIANN CCS-CDR e PERSIANN PDIR, respectivamente iniciando em 01 de janeiro de 1990, 01 de janeiro de 2003 e 01 de março de 2000, até 31 de dezembro de 2020. Os dados brutos foram recortados a partir de um retângulo desenhado no mapa com as coordenadas -7,0 N; -10,0 S; -34,0 E; e -42,0 W, salvos na extensão ASC (ArcGrid) e com resoluções espaciais de 25 km para a base CDR e 4 km para as bases PERSIANN CCS-CDR e PERSIANN PDIR (UCI, 2020).

O processamento da base de dados PERSIANN pode seguir o mesmo fluxo da Figura 35, com a diferença que os dados de entrada já estão no formato ASC. Ainda assim o processamento é indispensável para converter o sistema de coordenadas e alinhar as células a malha computacional do método ModClark.

Comenta-se sobre a gestão de muitos arquivos, e a eventual necessidade de nomeá-los com prefixos para facilitar a identificação ou etapas de processamento. Os prefixos podem ser adicionados diretamente no *Model Builder*, ou através de programas de código aberto como o *Ant Renamer* 2.12.0, disponível no endereço <https://antp.be/software/renamer/download>. (ANTP, 2020).

A base de dados PERSIANN CDR-CCS é a publicação mais recente da série PERSIANN, conforme apresentado por Sadegui *et al.* (2021).


3.2.4 Precipitação IMERG

Uma série de precipitação derivada de sensoriamento remoto da missão GPM foi avaliada. A série de precipitações acumuladas diárias IMERG-F V06 corresponde a versão mais atual em 2020 do processamento final dos produtos IMERG. Os dados foram obtidos para um retângulo de coordenadas -7,0 N; -10,0 S; -34,0 E; e -42,0 W, através da plataforma Giovanni.

O período avaliado teve início em 01 de junho de 2000 e término em 31 de dezembro de 2020, em função da disponibilidade de dados de série. Os dados foram obtidos no formato NetCDF (*Network Common Data Form*), em arquivos com a extensão NC4, e resolução espacial de 10 km. A ferramenta *Simple Mass Downloader* foi utilizada como extensão do navegador *Google Chrome* para baixar a lista com o link de cada arquivo da série de dados. No caso dos arquivos na extensão NC4,

utilizou-se um processamento adicional para convertê-los no formato TIFF através da utilização das ferramentas *Make NetCDF Raster Layer* e *Clip*, conforme modelo do *Model Builder* ilustrado na Figura 36. Após essa etapa executou-se o processamento da Figura 35.

Figura 36 – Configuração do *Model Builder* para conversão de arquivos NC4 em TIFF.



Fonte: O Autor (2024).

3.3 CORREÇÃO DE VIÉS (*BIAS*) EM PRECIPITAÇÕES ESTIMADAS POR SENSORIAMENTO REMOTO


Neste trabalho a correção de viés para os produtos de precipitação estimada por sensoriamento remoto foi realizada aplicando o Método Delta um dos métodos considerados mais simples para ajustes de dados meteorológicos, segundo Hay *et al.* (2000). A precipitação diária corrigida pelo Método Delta (P_{delta}) foi obtida pelo produto entre o dado diário bruto obtido de sensoriamento remoto (P_{sat}) e razão entre a média mensal dos dados observados ($\bar{P}_{obs}$) e a média mensal dos dados de satélite ($\bar{P}_{sat}$), no respectivo mês, conforme Equação 4.

$$P_{delta} = P_{sat,dia} \frac{\bar{P}_{obs,mês}}{\bar{P}_{sat,mês}} \quad \text{Eq. 4}$$

Neste trabalho o Método Delta foi aplicado em duas abordagens distintas. A primeira aplicação de correção de viés foi realizada sobre a área da bacia hidrográfica ($BIAS_{AREA}$) e considerou que as precipitações médias utilizadas na Eq. 4 ($\bar{P}_{obs}$ e $\bar{P}_{sat}$) são valores médios mensais para a delimitação de área de cada bacia hidrográfica descrita na área de estudo. A segunda aplicação ($BIAS_{PIXEL}$) considera que as precipitações médias utilizadas na Eq. 4 ($\bar{P}_{obs}$ e $\bar{P}_{sat}$) são valores médios mensais para cada célula dos arquivos matriciais de precipitação observada e estimada por

sensoriamento remoto, respectivamente, conforme fluxo esquematizado na Figura 37 e Equações 5 e 6.

Figura 37 – Fluxo de processamento para correção de viés em séries de precipitação estimada por sensoriamento remoto.



Fonte: O Autor (2024).

$$BIAS_{AREA} = P_{sat,dia} \frac{\overline{P_{obs,mês_i,bacia j}}}{\overline{P_{sat,mês_i,bacia j}}} \quad \text{Eq. 5}$$

$$BIAS_{PIXEL} = P_{sat,dia} \frac{\overline{P_{obs,mês_i,pixel j}}}{\overline{P_{sat,mês_i,pixel j}}} \quad \text{Eq. 6}$$

Onde:

$BIAS_{AREA}$ - Correção de viés (BIAS) de precipitação estimada por sensoriamento remoto aplicada sobre a área da bacia hidrográfica;

$BIAS_{PIXEL}$ - Correção de viés (BIAS) de precipitação estimada por sensoriamento remoto aplicada sobre cada célula do arquivo matricial de precipitação;

$P_{sat,dia}$ - Precipitação diária estimada por sensoriamento remoto;

$\overline{P}_{obs,mês_i,bacia j}$ - Precipitação média observada para um mês i , sobre a área de uma bacia hidrográfica j ;

$\overline{P}_{sat,mês_i,bacia j}$ - Precipitação média estimada por sensoriamento remoto para um mês i , sobre a área de uma bacia hidrográfica j ;

$\overline{P}_{obs,mês_i,pixel j}$ - Precipitação média observada para um mês i , sobre cada pixel j da série de precipitação;

$\overline{P}_{sat,mês_i,pixel j}$ - Precipitação média estimada por sensoriamento remoto para um mês i , sobre cada pixel j da série de precipitação.

Após a correção de viés uma nova série de precipitação diária foi obtida pelo método de ajuste de $BIAS_{PIXEL}$ e $BIAS_{AREA}$ para os conjuntos de dados CHIRPS, IMERG, PERSIANN CDR, PERSIANN CCS-CDR e PERSIANN PDIR.

3.4 INDICADORES DE EFICIÊNCIA APLICADOS AOS DADOS DE PRECIPITAÇÃO

A avaliação dos dados de precipitação derivados de sensoriamento remoto pode ser avaliada por indicadores estatísticos, de modo a permitir comparações e demonstrar o desempenho e eficiência quanto à identificação de eventos, acurácia posicional e a intensidade de subestimativas e superestimativas.

Os indicadores aplicados têm sido utilizados em outras pesquisas correlatas sobre dados de radar meteorológico e precipitações derivadas de sensoriamento remoto, como visto em Chalegre *et al.* (2018), Gomes, (2018) e Gunathilake *et al.* (2020). A perspectiva dos dados observados pode variar ao considerar a correlação de um dado pontual de pluviômetro com o pixel correspondente sobre a precipitação derivada de sensoriamento remoto, ou através de comparativos de precipitações médias sobre uma área, no caso uma bacia hidrográfica. Neste trabalho estão sendo correlacionadas as precipitações observadas e estimadas por sensoriamento remoto para as 15 bacias hidrográficas descritas como área de estudo, conforme utilizado por Le *et al.* (2020).

Os indicadores utilizados foram o Desvio Relativo de Precipitação Anual (DPA), o Desvio Relativo de Precipitação Mensal (DPM), Coeficiente de Correlação de Pearson (CC), Raiz do Erro Quadrático Médio (RMSE), Probabilidade de Detecção (POD), Taxa de Acurácia (AR), Taxa de Alarme Falso (FAR) e Viés de Frequência ($BIAS_f$), segundo as Equações 7 a 14. Para o DPA, DPM, RMSE, FAR e $BIAS_f$ o valor ótimo é alcançado quando o indicador se aproxima de 0, enquanto para os indicadores CC, POD e AR, o valor ótimo é 1.

$$DPA = \left(\frac{\overline{P_{sat, anual}}}{\overline{P_{obs, anual}}} - 1 \right) \times 100 \quad \text{Eq. 7}$$

$$DPM = \left(\frac{\overline{P_{sat, mensal}}}{\overline{P_{obs, mensal}}} - 1 \right) \times 100 \quad \text{Eq. 8}$$

$$CC = \frac{\sum_{i=1}^n (P_{obs,i} - \bar{P}_{obs})(P_{sat,i} - \bar{P}_{sat})}{\sqrt{\sum_{i=1}^n (P_{obs,i} - \bar{P}_{obs})^2 \sum_{i=1}^n (P_{sat,i} - \bar{P}_{sat})^2}} \quad \text{Eq. 9}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_{sat} - P_{obs})^2} \quad \text{Eq. 10}$$

$$POD = \frac{a}{b + c} \quad \text{Eq. 11}$$

$$FAR = \frac{b}{a + b} \quad \text{Eq. 12}$$

$$AR = \frac{a}{d + n} \quad \text{Eq. 13}$$

$$BIAS_f = \frac{a + b}{a + c} \quad \text{Eq. 14}$$

Onde:

P_{obs} - Precipitação diária observada em pluviômetros;

$\overline{P}_{obs}$ - Precipitação média observada em pluviômetros no período da série;

P_{sat} - Precipitação diária estimada por sensoriamento remoto;

$\overline{P}_{sat}$ - Precipitação média estimada por sensoriamento remoto no período da série;

N – Número de dias da série;

a - Correto positivo (quando a precipitação estimada e observada registra a ocorrência de chuva na bacia igual ou maior que o limiar determinado);

b - Alarme falso (quando a precipitação estimada registra a ocorrência de chuva na bacia igual ou maior que o limiar determinado, em discordância com a precipitação observada);

c - Falha (quando a precipitação estimada não registra a ocorrência de chuva na bacia igual ou maior que o limiar determinado, em discordância com a precipitação observada);

d - Correto negativo (quando a precipitação estimada e observada não registra a ocorrência de chuva na bacia igual ou maior que o limiar determinado);

n - Somatório dos corretos positivos, alarmes falsos, falhas e corretos negativos.

No Quadro 1 apresenta-se a matriz de contingência aplicada ao cálculo dos indicadores de eficiência das precipitações estimadas por sensoriamento remoto.

Quadro 1 – Matriz de contingência aplicada ao cálculo dos indicadores de eficiência das séries de precipitação.

		Precipitação observada em pluviômetros		Total
		Sim	Não	
Precipitação estimada por sensoriamento remoto	Sim	a	b	n = a + b + c + d
	Não	c	d	
Total				

Utilizou-se o limiar de 1mm de precipitação média na bacia hidrográfica sobre a matriz do Quadro 1, para identificação dos parâmetros a, b, c e d.


3.5 EVAPOTRANSPIRAÇÃO POTENCIAL

Após aquisição e processamento dos dados de precipitação, fez-se consulta a rede climatológica brasileira do Instituto Nacional de Meteorologia (INMET, 2020) para aquisição dos dados de evapotranspiração potencial (ETP). A rede de INMET possui 310 estações para o período de 1981 a 2010, sendo 15 estações climáticas em Pernambuco e apenas 09 com dados disponíveis no período de 1990 a 2020.

Considerando as premissas do trabalho relativas à modelagem hidrológica quase-distribuída, e obtenção de parâmetros a partir de sensoriamento remoto, foi dada preferência a base de dados de evapotranspiração em formato matricial, sobre as estações do INMET. No caso, utilizou-se a base global de evapotranspiração potencial mensal, calculada a partir de dados do WorldClim 2.0, aplicando a equação de Penman-Monteith e gerando arquivos matriciais GeoTIFF com resolução espacial de aproximadamente 1 km, conforme Trabucco e Zomer (2018). Os dados globais podem ser obtidos no sítio eletrônico do CGIAR-CSI (*Consultative Group for International Agriculture Research - Consortium for Spatial Information*) (CSI, 2020).

Foram utilizados dados mensais de evapotranspiração potencial, para os quais apresenta-se na Figura 38 o recorte da ETP calculada por Trabucco e Zomer (2018) e as estações climáticas do INMET sobre a área de estudo. As médias mensais de ETP foram calculadas para cada sub-bacia modelada e inseridas no HEC-HMS.

Figura 38 – Evapotranspiração potencial anual sobre a área de estudo.



* Evapotranspiração Potencial Global, Trabucco, Zomer, (2018)
 Fonte: O Autor (2024).


Nota-se que a metodologia de Penman-Monteith traz valores subestimados para a região estudada. Ainda assim a base de dados foi utilizada, entendendo-se que esta condição tende a ser mais relevante para as simulações de reservatórios e na transição entre os meses secos e úmidos.

3.6 VAZÕES OBSERVADAS E RESERVATÓRIOS MONITORADOS

No caso das precipitações estimadas por sensoriamento remoto foram feitas avaliações tendo como referência a precipitação observada em pluviômetros. No caso da avaliação da qualidade das vazões obtidas nas simulações hidrológicas, o ponto central passa pelo comparativo entre as vazões observadas em estações fluviométricas e simuladas no modelo computacional.

Para tal foram utilizadas séries de vazão diária obtidas para 66 estações fluviométricas que continham dados entre 1990 a 2020, obtidos no sistema Hidroweb da Agência Nacional de Águas e Saneamento Básico (ANA, 2005) utilizando o *script* Python HydroBr 0.1.1 desenvolvido por Carvalho (2020). Considerando a saída dos dados de vazão no formato de coluna, optou-se por adicioná-los manualmente a um arquivo DSS específico para vazões. A distribuição das estações fluviométricas utilizadas em cada bacia hidrográfica avaliada pode ser vista na Figura 39.

Figura 39 – Postos fluviométricos e barragens monitoradas sobre a área de estudo.



Fonte: O Autor (2024).

Em análise às séries de vazão observa-se que entre as bacias UP10 a UP13, ainda não existem séries de vazões observadas disponíveis. Desse modo, destaca-se a possibilidade de recorrer aos dados observados em barragens monitoradas pela Agência Pernambucana de Águas e Clima (Apac).

A inclusão dos grandes reservatórios nas simulações hidrológicas é relevante para a qualidade das simulações. O Sistema de Acompanhamento de Reservatórios (SAR) dispõe de 104 reservatórios monitorados em Pernambuco. Estes reservatórios totalizam um armazenamento de 3.417 hm³, dos quais tem-se 2.813 hm³, ou 82% do total, armazenados nos 20 maiores reservatórios em capacidade. A relação de estações fluviométricas contendo código Hidroweb, nome do posto, coordenadas, bacia hidrográfica e período de dados é apresentada no Anexo C, e a relação de 27 reservatórios incluídos nos modelos hidrológicos, incluindo nome da barragem, coordenadas, bacia hidrográfica e capacidade estão no Anexo D.

3.7 PERNAMBUCO TRIDIMENSIONAL E MODELO DIGITAL DO TERRENO

Em janeiro de 2014 teve início o Programa Pernambuco Tridimensional – PE3D (Pernambuco, 2020). Os serviços contratados realizaram o recobrimento aerofotogramétrico e perfilamento a laser de todo o território pernambucano. Na contratação foi incluído o mapeamento dos 98.149 km² do Estado de Pernambuco na escala 1:5.000, subdividindo o Estado em 13.115 folhas articuladas, para as quais foram geradas ortofotos nesta escala e produtos decorrentes do perfilamento a laser com precisão altimétrica melhor que 25 cm. Entre estes produtos estão Modelos Digitais de Terreno (MDT), Modelos Digitais de Elevação (MDE) e imagens de Intensidade Hipsométrica.

Adicionalmente, 870 km² distribuídos em áreas urbanas de 26 municípios foram contempladas com recobrimento aerofotogramétrico e geração de ortofotos na escala 1:1.000, perfilamento a laser com precisão altimétrica melhor que 10 cm e geração de Modelos Digitais de Terreno (MDT), Modelos Digitais de Elevação (MDE) e Imagens Hipsométricas. Algumas especificações dos produtos na escala 1:5.000 e 1:1.000 podem ser vistas na Tabela 5.

Todos os produtos do PE3D estão referenciados no sistema de coordenadas projetadas SIRGAS 2000, nos fusos 24S ou 25S. Para cada uma das folhas do Pernambuco Tridimensional estão disponibilizados conjuntos de seis produtos:

- 1) ORTOFOTOS – Ortofotos digitais articuladas e disponibilizadas em formato GeoTIFF, e resolução espacial de 0,5 m.
- 2) MDE (ASCII) – Modelo Digital de Elevação apresentado em formato XYZI, com as coordenadas de todos os pontos coletados pelo laser e a intensidade de retorno do pulso laser, incluindo áreas com elevações como vegetação, edifícios, pontes.
- 3) MDE (RASTER) – Modelo Digital de Elevação obtido através do MDE ASCII, apresentado em formato GeoTIFF, com resolução espacial de 1,0 m.
- 4) MDT (ASCII) – Modelo Digital de Elevação apresentado em formato XYZ, com as coordenadas de todos os pontos coletados pelo laser, excluindo áreas com elevações como vegetação, edifícios, pontes.
- 5) MDT (RASTER) – Modelo Digital de Terreno obtido através do MDT ASCII, apresentado em formato GeoTIFF, com resolução espacial de 1,0 m.
- 6) MDE COMPOSIÇÃO – Imagem de composição das informações hipsométricas e intensidade de retorno do pulso laser, em GeoTIFF com resolução espacial de 1,0m.

Tabela 5 – Características técnicas dos produtos do Pernambuco Tridimensional.

	Escala 1:5000		Escala 1:1000	
	Ortofoto	Perfilamento laser	Ortofoto	Perfilamento laser
Extensão dos arquivos	.tif .tfw e .dwg	.xyz .xyzi e .tif	.tif .tfw e .dwg	.xyz .xyzi e .tif
Densidade de pontos	-	~ 1 ponto/m ²	-	~ 4 pontos/m ²
Resolução espacial	50 cm	1 m	12 cm	50 cm
Resolução radiométrica	8 bits	32 bits	8 bits	32 bits
Precisão planimétrica	~ 1 m	-	~ 25 cm	-
Precisão altimétrica*	-	25 cm	-	10 cm
Altura média de voo	4.800 m	2.800 m	700 m	700 m

* A precisão altimétrica dos produtos 1:5000 tem como referência o MAPGEO 2010, enquanto os produtos 1:1000 são referenciados segundo Referências de Nível (RN's) do IBGE.

Fonte: Alves (2017).

Para modelagem hidrológica e delimitação de sub-bacias no HEC-HMS foram utilizados todos os arquivos contendo Modelo Digital do Terreno do PE3D, com resolução espacial reamostrada de 1,0 m para 30,0 m. O sistema de coordenadas projetadas UTM no fuso 24S foi utilizada para todo projeto, visando unificar a mesma base de dados de precipitação.

Uma análise do MDT foi realizada de modo a identificar vazios (*No Data*) e corrigir pequenas falhas provenientes de nuvens. Cada bacia hidrográfica foi

processada separadamente, uma vez verificada a inviabilidade de agrupar toda área de estudo em um projeto do HEC-HMS, mesmo com resolução espacial de 30,0 m.

3.8 DELIMITAÇÃO DE SUB-BACIAS E REDE DE DRENAGEM

O modelo hidrológico HEC-HMS, a partir da versão 4.4, passou a integrar ferramentas de geoprocessamento que permitem a delimitação de sub-bacias e rede drenagem, o que até então era feita através da extensão HEC-GeoHMS.

Os modelos hidrológicos foram desenvolvidos no HEC-HMS 4.12, inicialmente com a criação da bacia hidrográfica simulada, definição do sistema de coordenadas e importação do MDT. O processamento das sub-bacias e rede de drenagem, segue ferramentas das funções GIS, utilizando sequencialmente o pré-processamento do preenchimento de depressões (*Preprocess Sinks*) e da rede de drenagem (*Preprocess Drainage*), identificação de rede de drenagem (*Identify Streams*), definição manual do exutório (*Break Point Creation*) e delimitação das sub-bacias (*Delineate Elements*).

Na delimitação das sub-bacias através do HEC-HMS é necessário informar a área para definir a rede de drenagem. Definiu-se o valor de 25 km² nas bacias dos rios Pajeú e Brígida, em função de possuírem as maiores áreas; 10 km² para as bacias do Mundaú, Terra Nova, GL-1 e GL-2 em função de possuírem menores áreas; 5 km² para a bacia do rio Goiana em função de erros de processamento ocasionadas por pequenas falhas no MDT sobre a rede de drenagem, e 20 km² para as demais bacias.

3.9 USO E OCUPAÇÃO DO SOLO – MAPBIOMAS


O MapBiomas fornece uma base de dados de uso e ocupação do solo para todo o território brasileiro. A base MapBiomas possui dados matriciais no formato GeoTIFF, armazenando números inteiros positivos em 8 *bits* e resolução espacial de 30m. A série de dados utilizada é referente ao MapBiomas Coleção 8, cujo recorte da área de estudo foi realizado na plataforma Google Earth Engine, através da ferramenta *MapBiomas user toolkit 1.3.0* (Siqueira, 2020), conforme apresentado na Figura 40.

Entre as 30 classes do nível detalhado do MapBiomas, 20 classes foram identificadas na área de estudo e fornecem um dos principais conjunto de dados geoespaciais utilizados neste trabalho. A base do MapBiomas foi utilizada através de reclassificação de grupos de classes ou combinada a outras bases de dados físicos,

como os mapas de solos e Modelo Digital do Terreno (MDT) do Pernambuco Tridimensional.

Figura 40 – Uso e ocupação do solo a partir do MapBiomas e percentuais das classes.

A) Área de Estudo e B) Detalhe ampliado



Fonte: O Autor (2024).

3.10 CARACTERIZAÇÃO DA COBERTURA VEGETAL

A primeira componente a ser descrita na modelagem hidrológica do HEC-HMS está relacionada a cobertura vegetal das sub-bacias, sendo denominada *Canopy*. Esta componente recebe influência da interceptação da precipitação retida

nas folhas e caules da vegetação, bem como a intensidade de extração de água do solo por esta vegetação.

A precipitação retida pela vegetação está sujeita a evapotranspiração e, embora opcional no HEC-HMS, a componente *Canopy* passa a ser recomendada em simulações contínuas. Valores referencias da componente *Canopy* aplicados no HEC-HMS são apresentados por Fleming, Neary (2004) e Holberg (2014), com base em estudo geral sobre interceptação desenvolvido nos Estados Unidos por Zinke (1967).

Os valores recomendados para o armazenamento de água na cobertura vegetal são relacionados ao porte da vegetação. Utilizou-se 1,27 mm para vegetação geral ou espécies desconhecidas; 2,03 mm para gramíneas e árvores caducifólias e 2,54 mm para árvores coníferas e vegetação de maior porte (Tabela 7).

Para a área de estudo, o armazenamento da cobertura vegetal foi estimado a partir de ferramenta de reclassificação de arquivos matriciais, onde para cada classe MapBiomas foi associado um valor de Canopy, com base na literatura. As áreas impermeáveis foram associadas ao valor 0, conforme descrito na Tabela 6.

Tabela 6 – Classes MapBiomas e relação de armazenamento de água na cobertura vegetal.

ID	Classe MapBiomas	Percentual, (%)	Canopy, (mm)
3	Formação Florestal	3,8	2,54
4	Formação Savânica	41,5	2,03
5	Mangue	0,1	2,54
9	Floresta Plantada	<0,1%	2,54
11	Campo Alagado e Área Pantanosa	<0,1%	2,54
12	Formação Campestre	3,1	1,27
13	Outras Formações Não Florestais	<0,1%	1,27
15	Pastagem	29,9	1,27
20	Cana	2,5	2,03
21	Mosaico de Usos	13,7	1,27
23	Praia, Duna e Areal	<0,1%	0,00
24	Infraestrutura Urbana	1,1	0,00
25	Outras Áreas Não Vegetadas	0,8	0,00
29	Afloramento Rochoso	<0,1%	0,00
30	Mineração	<0,1%	0,00
31	Aquicultura	<0,1%	0,00
33	Rio, Lago e Oceano	1,4	0,00
41	Outras Culturas Temporárias	1,1	2,03
48	Outras Culturas Perene	0,8	2,03
27	Não Observado	0,0	1,27

Fonte: Adaptado de Fleming e Neary (2004).

Tabela 7 – Armazenamento de precipitação na cobertura vegetal em função do porte da vegetação.

Descrição	Armazenamento máximo na cobertura vegetal, (mm)
Árvores coníferas	2,54
Gramíneas e árvores caducifólias	2,03
Espécies de vegetação desconhecida	1,27

Fonte: Fleming e Neary (2004).

3.11 CARACTERIZAÇÃO DO ARMAZENAMENTO DE ÁGUA NA SUPERFÍCIE

O armazenamento de água na superfície (*Surface*) é um componente opcional que pode ser incluído no balanço hídrico de cada sub-bacia modelada no HEC-HMS, e representa a água acumulada nas depressões do terreno. No HEC-HMS, o escoamento superficial começa quando a intensidade de precipitação for maior que a capacidade de infiltração do solo e a capacidade de armazenamento de água na superfície estiver atendida. A precipitação armazenada na superfície continua infiltrando em simulações contínuas e após os eventos de precipitação.


Fleming e Neary (2004), aplicam uma relação entre declividade e o armazenamento de água na superfície do HEC-HMS, conforme faixas apresentadas na Tabela 8. O armazenamento varia de 1,0 mm para as áreas com declividade maior que 30%, até 50,8 mm, para as áreas consideradas planas. Observou-se que uma linha de tendência se ajusta quando os valores são plotados em escala logarítmica, como mostrado na Figura 41. Para estimar o armazenamento de água na superfície, a equação gerada foi aplicada a uma ferramenta de álgebra de mapas tendo como entrada apenas a declividade, calculada percentual, a partir da base de dados do PE3D, com resolução de 30m. As células com áreas impermeáveis tiveram a declividade de 30% atribuída de modo a resultar valores próximos a 6,4 mm.

Tabela 8 – Relações de declividades e armazenamento de água na superfície no modelo hidrológico HEC-HMS.

Descrição	Declividade, (%)	Armazenamento de água na superfície, (mm)
Áreas planas e com sulcos	0 - 5	50,8
Declives suaves a moderados	5 - 30	12,7 – 6,4
Encostas suaves a íngremes	> 30	1,0
Áreas impermeáveis e pavimentadas	-	3,2 – 6,4

Fonte: Bennett, (1998) apud Fleming e Neary (2004).

Figura 41 – Linha de tendência das relações declividade x armazenamento na superfície.



Fonte: O Autor (2024).

3.12 CARACTERIZAÇÃO DE PERDAS – MÉTODO DÉFICIT CONSTANTE

No balanço hídrico, o método de perdas possui objetivo de calcular a precipitação efetiva e determinar o escoamento superficial direto. Desde o início do armazenamento de água na superfície, começa a ocorrer infiltração de água no solo. Horton (1940) descreve um modelo físico para interpretar a capacidade de infiltração de água no solo. Fleming, Smiles (1975) trazem uma revisão da teoria de Horton com uma aplicação à modelagem hidrológica da qual se dá origem ao modelo de perdas de Déficit Constante, disponível no HEC-HMS, aplicável a simulações contínuas e considerando em seu balanço hídrico os principais processos físicos de perdas de precipitação, conforme ilustrado na Figura 42.

O método Déficit Constante usa apenas uma camada de solo para contabilizar mudanças contínuas no teor de umidade. O método Déficit Constante demanda a aplicação de um modelo para extrair água do solo em resposta à evapotranspiração potencial. Esta camada de solo poderá secar entre os eventos de precipitação conforme extração contínua da água do solo. O método Déficit Constante é associado ao armazenamento de água na superfície, nesse caso a precipitação retida no armazenamento superficial infiltra-se para camada do solo até a saturação.

A precipitação infiltra até atender a capacidade de armazenamento máximo do solo, quando então a precipitação excedente passar a gerar escoamento superficial direto (HEC, 2021).

Figura 42 – Principais processos físicos de perdas de precipitação no balanço hídrico.




Fonte: Hill e Thomson (2019).

Toda precipitação adicionada ao balanço hídrico passa pela camada de armazenamento superficial, de modo a verificar se o déficit de umidade é maior que zero, ocorrendo nesse caso infiltração. Essa infiltração ocorrerá de forma contínua até que a camada de solo atinja a saturação e o déficit de umidade seja zero. Durante a fase saturada não ocorre percolação (HEC, 2021).

A percolação da camada de solo para o canal do rio também ocorre a uma taxa constante e apenas enquanto a camada de solo estiver saturada. O déficit de umidade aumenta em resposta à extração da água do solo pela vegetação para atender à demanda de evapotranspiração potencial, conforme principais componentes do método ilustrados na Figura 43 (HEC, 2021).

Figura 43 – Componentes do balanço hídrico no método de perdas de Déficit Constante.



Fonte: Hill e Thomson (2019).

Descreve-se a seguir referências na literatura e métodos aplicados para estimativas dos parâmetros do método de perdas de Déficit Constante.

3.12.1 Déficit inicial (*Inicial Deficit*)

O parâmetro de Déficit Inicial retrata a condição inicial do método de Déficit Constante. No início da simulação, é a quantidade de água que seria necessária para preencher a camada de solo até o armazenamento máximo (HEC, 2021).

Entendendo que este parâmetro passa a se ajustar ao longo de simulações contínuas, e que é possível utilizar o conceito de aquecimento das simulações hidrológicas, se identificada distinção de qualidade dos resultados nos primeiros eventos simulados. Adotou-se um déficit de 80% e 50% do déficit máximo para bacias hidrográficas na região semiárida e úmida, respectivamente.

3.12.2 Déficit máximo (*Maximum Deficit*)

O Déficit Máximo determina a quantidade total de precipitação que a camada de solo pode armazenar. Fisicamente, o limite superior do déficit máximo é a espessura da camada de solo multiplicada pela porosidade. No entanto, na maioria dos casos, essa estimativa pode ser reduzida quando houver algumas condições que reduzam a capacidade de retenção de água (HEC, 2021).

O Déficit Máximo é comumente determinado através de calibração, porém neste trabalho ele será calculado tendo como premissa à similaridade física com a capacidade máxima de armazenamento de água no solo (S), do método do *Soil Conservation Service*, (SCS, 1956), conforme Equação 15, e uma redução proporcional a água disponível no solo (AD). Para determinar a capacidade de armazenamento (S), utilizou-se recorte de mapa de solos na escala 1:250.000 disponibilizado pelo IBGE, segundo o Sistema Brasileiro de Classificação de Solos (SiBCS, 2018). Os solos foram classificados em 4 classe hidrológicas, seguindo a Classificação Hidrológica dos Solos apresentada por Genovez, Lombardi e Sartori (2005), tendo como resultados os tipos de solos e a classificação hidrológica ilustrada na Figura 44.


$$S = \frac{25400}{CN} - 254 \quad \text{Eq. 15}$$

Onde:

S – Capacidade máxima de armazenamento de água no solo, em mm;

CN – Curve Number

Figura 44 – Classificação de solos. A) Classificação SiBCS e B) Classificação hidrológica.



Fonte: O Autor (2024).

Segundo USDA (2004a), no método do SCS, cada grupo de solo está associado a um valor CN (Curve Number) na condição de umidade II. A partir das informações de uso e ocupação do solo obtidas através do MapBiomas (2020) e da classificação hidrológica dos solos fez-se a classificação através da associação da classe MapBiomas aos valores de CN II, conforme na Tabela 9, elaborada com base nos valores de USDA (2004b). Na Tabela 9 também se considera as interpretações apresentadas em Tucci (2012) e ANA (2018).

A distribuição dos valores de CN II para a área de estudo encontra-se na Figura 45. A saída desta etapa foi gerada com a melhor resolução espacial das duas bases de entrada, no caso o MapBiomas com resolução espacial de 30 m.

Tabela 9 – Relação entre MapBiomias e Curve Number (CN II) para a classificação hidrológica dos solos.

ID	Classe MapBiomias	Classe hidrológica dos solos			
		A	B	C	D
3	Formação Florestal	36	60	70	76
4	Formação Savânica	56	75	86	91
5	Mangue	26	52	62	69
6	Floresta Inundável	26	52	62	69
49	Restinga Arborizada	56	75	86	91
11	Campo Alagado e Área Pantanosa	26	52	62	69
12	Formação Campestre	36	60	73	79
32	Planície Salina	55	72	81	86
29	Afloramento Rochoso	98	98	98	98
50	Vegetação Herbácea de Restinga	56	75	86	91
13	Outras Formações Não Florestais	49	69	79	84
15	Pastagem	49	69	79	84
39	Soja	62	75	83	87
20	Cana	43	65	77	82
40	Arroz	62	75	83	87
41	Outras Culturas Temporárias	57	73	82	86
36	Culturas Perenes	64	76	84	88
46	Café	48	68	79	83
47	Citrus	48	68	79	83
48	Outras Culturas Perenes	64	76	84	88
9	Floresta Plantada	46	68	78	84
21	Mosaico de Usos	46	67	78	83
23	Praia, Duna e Areal	36	60	70	76
24	Área Urbana	77	85	90	92
30	Mineração	98	98	98	98
25	Outras Áreas Não Vegetadas	98	98	98	98
33	Rio, Lago e Oceano	100	100	100	100
31	Aquicultura	98	98	98	98
27	Não observado	56	75	86	91


Fonte: Adaptado de USDA (2004a).

Com objetivo de determinar o armazenamento máximo de água no solo aplicável ao método de Déficit Constante no modelo HEC-HMS, supõe-se que este valor máximo é representado pelo solo em condição de umidade próxima ao CN I.

No entanto, sabe-se que a condição de umidade do solo é variável ao longo do ano, sendo possível que uma condição de baixa umidade se tornar uma situação


atípica. De acordo com faixas de amplitude da variação de armazenamento de água no solo apresentadas em USDA (2004b) aplicou-se uma aproximação polinomial através de ferramentas álgebra de mapas, permitindo identificar o limite superior (CN III) e inferior (CN I) em função dos valores de CN II, com base nas relações ilustradas na Figura 46.

Figura 45 – Relação Curve Number (CN) para a área de estudo na condição de umidade II.



Fonte: O Autor (2024).

Figura 46 – Relação entre Curve Number (CN) nas condições de umidade I, II e III.




Fonte: Adaptado de USDA (2004b).

Uma vez obtidos os valores do CN I, CN II e CN III, utilizou-se o Mapeamento de Água Disponível em Solos no Brasil para encontrar a condição de umidade que determina o armazenamento máximo no HEC-HMS, conforme recorte para área de estudo ilustrado na Figura 47. O mapeamento apresentado pela EMBRAPA define água disponível (AD) como sendo a água que os solos podem armazenar no seu espaço poroso de modo que as plantas possam acessá-la, garantindo a vida continental no planeta (EMBRAPA, 2022).

Supondo uma relação linear entre o CN e AD adotou-se que nas áreas onde o parâmetro AD está na classe AD6, acima de 1,84 mm/cm, a condição de umidade do CN será o CN III. Quando o AD estiver abaixo de 0,34 mm/cm a condição de umidade será da CN I, e uma relação linear foi aplicada nos casos intermediários.

Figura 47 – Classificação de Água Disponível no Solo (AD) para a área de estudo.



Fonte: Adaptado de Embrapa, (2022)

Desse modo, chega-se à proposta do armazenamento máximo de água no solo aplicada no método de perdas de Déficit Constante disponível no HEC-HMS. Sobre este resultado tomou-se a média para cada sub-bacia modelada.

A camada referente ao armazenamento máximo de água no solo é apresentada em milímetros e manteve a resolução espacial de 30 m do dado de entrada MapBiomas. Embora esta resolução não pode ser associada a uma escala, tendo em vista que o método utiliza bases de dados de entrada distintas.

O HEC-HMS permite que os dados de entrada sejam inseridos a partir de arquivos matriciais, desde que convertidos ao formato DSS. No entanto, esta alternativa não foi adotada de modo a permitir eventuais calibrações de bacias hidrográficas específicas.

3.12.3 Taxa de infiltração (Constant rate)

A taxa de infiltração (constant rate) define as taxas de infiltração e percolação enquanto a camada de solo estiver saturada. A condutividade hidráulica saturada é considerada uma boa aproximação para este parâmetro conforme proposto no manual do usuário do HEC-HMS (HEC, 2021), onde apresenta-se o estudo de Rawls, Brakensiek, Miller (1983) como referência para estimar a condutividade hidráulica a partir da textura do solo, conforme Tabela 10.

Tabela 10 – Relação entre classificação de textura dos solos e estimativa da condutividade hidráulica saturada.

Textura do Solo	Condutividade Hidráulica Saturada, (mm/h)
Arenosa	117,80
Arenosa média	29,90
Média arenosa	10,90
Média	3,40
Média siltosa	7,60
Média argilosa e arenosa	1,50
Média argilosa	1,00
Média argilosa e siltosa	1,00
Argilosa arenosa	0,50
Argilosa siltosa	0,50
Argilosa	0,25

Fonte: Adaptado de Rawls, Brakensiek e Miller (1983).

A classificação textural dos solos é uma informação disponível no mapa de solos do Sistema Brasileiro de Classificação de Solos (SiBCS, 2018). Sendo assim, é possível aplicar a Tabela 10 através de correlação direta, havendo, no entanto, adaptações de algumas classificações do SiBCS que traziam descrições mais

detalhadas que as apresentas como referência, a exemplo da presença de cascalho. Não foram identificados solos com classe textural siltosa.

O estudo de Rawls, Brakensiek e Miller (1983) foi originalmente desenvolvido para aplicação hidrológica e estimativa dos parâmetros do método Green-Ampt. É relevante enfatizar que os valores apresentados na Tabela 10 são estimativas iniciais dos parâmetros, mas a condição real dos solos retrata uma condição anisotrópica ao longo do perfil de solo.

3.12.4 Áreas impermeáveis (Impervious)

No método de perdas de Déficit Constant, a porcentagem de áreas impermeáveis de cada sub-bacia pode ser especificada. Nessas áreas não ocorrem perdas e toda precipitação torna-se excedente (HEC, 2021). Para identificação das áreas impermeáveis, inicialmente foi realizada uma reclassificação binária do MapBiomass, onde cada classe recebeu o valor 0 ou 100.

As classes MapBiomass associadas a infraestrutura urbana; áreas não vegetadas, afloramento rochoso; mineração; aquicultura; rio, lago e oceano tiveram o valor de 100% impermeável atribuído, enquanto as demais classes receberam o valor zero.

Por fim, utilizou-se ferramenta de geoprocessamento para obter o valor médio desta reclassificação sobre a delimitação de cada sub-bacia. Como resultado obteve-se o percentual de áreas impermeáveis de cada sub-bacia.

3.13 MÉTODO DE TRANSFORMAÇÃO CHUVA x VAZÃO

3.13.1 Método ModClark

Segundo Kull e Feldman (1998), o cálculo do escoamento superficial através do método ModClark considera uma componente de translação e outra de armazenamento. O armazenamento é computado com base no modelo de reservatório linear adotado no método de Clark. E a translação é calculada em função do tempo de viagem de cada célula da malha computacional.

O reservatório linear consiste em um balanço de massa da vazão afluente (I_t) e efluente (O_t), entre dois instantes de tempo (t), onde a componente de translação

é determinada a partir de um coeficiente linear (R), conforme descrito por Kull e Feldman (1998) nas Equações 16, 17 e 18.

O método ModClark incorpora uma grade de cálculo padrão sobreposta a bacia hidrográfica. A malha adotada possui resolução espacial de 2 km x 2 km, onde o HEC-HMS define para cada célula, através do arquivo *GridCell File*, um identificador posicional com base matricial X e Y, o tempo de viagem e a área da célula. O tempo de viagem é definido com base na Equação 19, representando uma fração do tempo de concentração da bacia hidrográfica.

$$\frac{dS}{dt} = I_t - O_t \quad \text{Eq. 16}$$

$$S_t = R.O_t \quad \text{Eq. 17}$$

$$\overline{O_t} = \frac{O_{t-1} + O_t}{2} \quad \text{Eq. 18}$$

$$t_{cell} = t_c \frac{d_{cell}}{d_{máx}} \quad \text{Eq. 19}$$

Onde:

dS / dt - Taxa de variação do armazenamento de água no instante t, (m³/s);

I_t - Vazão afluente ao reservatório no instante t, (m³/s);

O_t - Vazão efluente ao reservatório no instante t, (m³/s);

S_t - Armazenamento no instante t, (m³/s);

R - Constante de armazenamento do reservatório linear, adimensional;

$\overline{O_t}$ - Vazão efluente média no instante t, (m³/s);

t_{cell} - Tempo de viagem da célula, (s);

t_c - Tempo de concentração da bacia hidrográfica, (s);

d_{cell} - Distância da célula ao exutório da bacia hidrográfica, (km);

$d_{máx}$ - Distância da célula mais afastada do exutório, (km).

3.13.2 Tempo de concentração e tempo de armazenamento

O tempo de concentração e o tempo de armazenamento são os dois parâmetros a serem definidos em cada sub-bacia para as simulações hidrológico do HEC-HMS através do método quase-distribuído ModClark. O tempo de concentração é comumente calculado na modelagem hidrológica, sendo aplicada a Equação 20, apresentada por Linsley *et al.* (1977), a partir de estudo desenvolvido para 25 bacias hidrográficas rurais com áreas até 12.000 km². O manual do HEC-HMS propõe relação entre tempo de concentração e tempo de armazenamento conforme apresentado na Equação 21, e sugere que esta relação pode variar de 0,50 a 0,65. A relação adotada foi de 0,65, podendo ser posteriormente analisada através de calibração.

$$T_c = 0,191 \cdot \frac{L^{0,76}}{I^{0,19}} \quad \text{Eq. 20}$$

$$\frac{R}{T_c + R} = 0,65 \quad \text{Eq. 21}$$

Onde:

T_c - Tempo de concentração, em h;

L - Comprimento do talvegue, em km;

I - Declividade média, em m/m;

R - Constante de armazenamento do reservatório linear, adimensional.


3.14 VAZÃO DE BASE

O método selecionado para o cálculo da vazão de base utiliza as Equações 16, 17 e 18 que descrevem o método do Reservatório Linear. No HEC-HMS, o método do Reservatório Linear é a única opção de vazão de base que conserva a massa dentro da sub-bacia. A infiltração ou percolação calculada pode ser conectada em até três reservatórios, interagindo com a camada de cobertura vegetal e armazenamento de água na superfície, conforme o esquema da Figura 48.

Cada reservatório pode receber uma fração da precipitação infiltrada. Se a soma das frações for menor que um, esta diferença será considerada como recarga do aquífero, caso contrário toda água percolada se torna vazão de base. O método

de perdas do Déficit Constante transmite a percolação para os reservatórios da vazão de base apenas durante a condição de saturação do solo.

Figura 48 – Fluxo de interação da vazão de base aos demais componentes do balanço hídrico adotados na modelagem do HEC-HMS.




Fonte: Adaptado de HEC, (2021)

Ao definir os parâmetros do método do Reservatório Linear para computar a vazão de base no HEC-HMS, deve-se definir a descarga inicial, a fração de precipitação armazenada em cada camada e a constante de armazenamento do Reservatório Linear (R), apresentada na Equação 21.

A utilização de três camadas é opcional, sendo recomendado o mínimo de duas camadas para melhor representação da curva de recessão dos hidrogramas, onde a Camada 1 contribui na fase de interfluxo e a Camada 2 a vazão de base. Neste trabalho a Camada 3 foi conceitualmente associada para representar o trecho do hidrograma após o interfluxo, conforme ilustrado na Figura 49.

Em termos práticos, valores elevados da constante de armazenamento atenuam a contribuição da vazão de base nas vazões máximas e em contraponto estas contribuições se prolongam no tempo, devido ao efeito de conservação de massa. Outra recomendação do manual do usuário adotada, passa por adotar para vazão de base, múltiplos da constante de armazenamento do método de Clark.

Figura 49 – Separação do escoamento direto, interfluxo e vazão de base em hidrogramas.



Fonte: Adaptado de HEC, (2021)

Para a descarga inicial utilizou-se a vazão média do posto multiplicada pela fração de cada camada. Não foram avaliadas metodologias aplicáveis a estimativas das frações de precipitação e constantes de armazenamento de cada sub-bacia a partir de bases de dados físicos, devendo estes resultados serem analisados por similaridades com outras bacias hidrográficas estudadas.

3.15 PROPAGAÇÃO DE VAZÃO NO CANAL DO RIO

Após o cálculo das vazões, de maneira independente para cada sub-bacia, o modelo hidrológico HEC-HMS permite adotar um método de propagação de vazão ao longo dos canais dos rios. Com base nos princípios de conservação de massa e conservação de momento, o método *Muskingum-Cunge* é uma alternativa adequada aos modelos hidrológicos para representar os efeitos de translação e amortecimento da onda de cheia, uma vez que resultados mais precisos podem ser obtidos a partir de modelos hidrodinâmicos resolvendo as equações de *Saint-Venant*.

O método de *Muskingum-Cunge* aproxima o canal principal de uma sub-bacia por um prisma de seção e declividade constantes. Ao considerar que a onda de cheia se propaga ao longo desse prisma, utiliza-se as Equações 22 a 28 para calcular a vazão no exutório de cada sub-bacia (USACE, 1936; Cunge, 1969).

$$Q_{s+1}^{t+1} = C_0 Q_s^{t+1} + C_1 Q_s^t + C_2 Q_{s+1}^t \quad \text{Eq. 22}$$

$$C_0 = \frac{c \left(\frac{\Delta t}{\Delta x} \right) - 2X}{2(1-X) + c \left(\frac{\Delta t}{\Delta x} \right)} \quad \text{Eq. 23}$$

$$C_1 = \frac{c \left(\frac{\Delta t}{\Delta x} \right) + 2X}{2(1-X) + c \left(\frac{\Delta t}{\Delta x} \right)} \quad \text{Eq. 24}$$

$$C_2 = \frac{2(1-X) - c \left(\frac{\Delta t}{\Delta x} \right)}{2(1-X) + c \left(\frac{\Delta t}{\Delta x} \right)} \quad \text{Eq. 25}$$

$$c = \beta \cdot V = \frac{5}{3} \cdot \frac{Q}{A} = \frac{5}{3} \cdot \frac{q}{y} \quad \text{Eq. 26}$$

$$K = \frac{\Delta x}{c} \quad \text{Eq. 27}$$

$$X = \frac{1}{2} \cdot \left(1 - \frac{q}{S_0 \cdot c \cdot \Delta x} \right) \quad \text{Eq. 28}$$

Quando, $X \leq \frac{\Delta t}{2.K} \leq (1-X)$ tem-se que:

Q_{t+1}^{s+1} - Vazão na seção s+1, no instante t+1, (m³/s);

C_0, C_1 e C_2 - Coeficientes do método de *Muskingum-Cunge*

c - Celeridade de propagação da onda de cheia, (m/s);

Δt - Tempo de passo de cálculo, (s);

Δx - Distância entre seções de cálculo, (m);

X - Fator de ponderação X que representa a atenuação da onda;

β - Expoente de curvatura do hidrograma;

V - Velocidade média do escoamento, (m/s);

q - Vazão unitária por largura do canal, (m³/s/m);

y - Altura da lâmina de água na seção, (m);

K - Parâmetro K que representa o tempo de propagação da onda no canal, (s);

S_0 - Declividade média do fundo do canal, (m/m).

Para simulação no HEC-HMS, para cada trecho de rio, devem ser definidos comprimento, declividade, coeficiente de Manning, formato do canal e largura da base. O comprimento e a declividade são obtidos na fase de processamento da geometria. O coeficiente de Manning utilizado foi de 0,035. A seção do canal foi definida como trapezoidal adotando uma largura média para a base de 10 m e uma declividade dos taludes 1:1 (H:V).

3.16 OPERAÇÃO DE RESERVATÓRIOS

A existência de barragens e seus reservatórios pode ser um aspecto relevante à qualidade das simulações hidrológicas e de representação complexa às ferramentas computacionais de modelagem hidrológica. Tais condições podem estar relacionadas à alteração do regime hidrológico natural da bacia hidrográfica devido ao volume retido, aos reservatórios que foram construídos em diferentes períodos ao longo das séries históricas, maior sensibilidade às condições de evapotranspiração, dados observados ausentes ou insuficientes para representar os volumes vertidos, liberações de comportas e descargas de fundo, captações em tomada d'água ou outros usos no entorno dos reservatórios.

Conforme casos abordados por Han *et al.* (2020) e Ouyang *et al.* (2021), os reservatórios possuem importância na modelagem hidrológica e podem auxiliar a validação de resultados em bacias hidrográficas que não possuem estações fluviométricas, “*ungauged*”.


Uma das alternativas de simular os reservatórios no HEC-HMS é entrando com as relações entre cota, volume, área e descarga. Também é possível informar as dimensões das estruturas para cálculo interno, ou regras de operação de comportas, não sendo adotadas estas opções.

Para determinação da curva de descarga do vertedouro foram observadas recomendações do manual de projetos de pequenas barragens, *Design of Small Dams* (USBR, 1987). De acordo com esquema ilustrativo apresentado na Figura 50 para perfil vertedouro tipo Creager, o HEC-HMS aplica as Equações 29 e 30, obtendo curvas de descargas para o vertedouro de cada barragem simulada conforme exemplo ilustrado na Figura 51. O dimensionamento de vertedouros possui critérios sofisticados para as mais diversas soluções adotadas, simplificações consideradas adequadas a representação do comportamento hidrológico das bacias hidrográficas foram feitas na inserção das estruturas no HEC-HMS.

As relações entre cota, volume e área foram obtidas através de fichas técnicas dos reservatórios disponibilizadas pela Agência Pernambucana de Águas e Clima (Apac), conforme exemplificado através da Figura 52. No HEC-HMS, as informações relativas aos volumes devem ser inseridas na unidade de 1000 m³.

Os principais parâmetros a serem inseridos para simulação de reservatórios e vertedouros no HEC-HMS podem ser vistos nas janelas de configuração apresentadas na Figura 53.

Figura 50 – Esquema geral de vertedouro tipo Creager.



Fonte: Sampaio, (2015)

$$Q_v = C \cdot L \cdot H_e^{\frac{3}{2}}$$

Eq. 29

$$L = L' - 2(N.K_p - K_a)H_e \quad \text{Eq. 30}$$

Onde:

Q_v - Vazão de descarga do vertedouro, (m³/s);

C - Coeficiente de descarga, (m^{0,5} . s⁻¹);

L - Largura efetiva da soleira do vertedouro, (m);

L' - Largura da soleira do vertedouro, (m);

H_e - Carga hidráulica do vertedouro (H + ha), (m);

N - Número de pilares, se houver;


K_p - Coeficiente de contração devido aos pilares;

- pilares com cantos arredondados com raios da ordem de 10% da espessura do pilar: $k_p = 0,02$
- pilares com face redonda no sentido do fluxo: $k_p = 0,01$
- pilares com face pontiaguda no sentido do fluxo: $k_p = 0$

K_a - Coeficiente de contração devido às paredes laterais do vertedor.


- paredes com cantos em 90°: $k_a = 0,2$
- paredes com cantos arredondados: $k_a = 0,1$
- paredes com entrada inclinada em 45° e cantos arredondados: $k_a = 0$

Figura 51 – Exemplo de curva de descarga de vertedouro.



Fonte: O Autor (2024).

Figura 52 – Exemplo de relação cota área e volume para reservatórios simulados.



Fonte: O Autor (2024).

Figura 53 – Principais parâmetros configurados para simulação de reservatórios e vertedouros simulados no HEC-HMS.

Reservatório Configuration:

- Basin Name: PAJEU
- Element Name: PAJ_D_SERRINHA_II
- Description: [Empty]
- Downstream: PAJ_R15
- Method: Outflow Structures
- Storage Method: Elevation-Area
- *Elev-Area Function: CA_SERRINHA_II
- Initial Condition: Elevation
- *Initial Elevation (M): 370
- Main Tailwater: Assume None
- Auxiliary: --None--
- Time Step Method: Automatic Adaption
- Outlets: 0
- Spillways: 1
- Dam Tops: 0
- Pumps: 0
- Dam Break: No
- Dam Seepage: No
- Release: No
- Evaporation: Yes

Spillway 1 Configuration:

- Basin Name: PAJEU
- Element Name: PAJ_D_SERRINHA_II
- Method: Ogee Spillway
- Direction: Main
- Abutments: 2
- Abutment Type: Concrete
- *Approach Depth (M): 1
- *Approach Loss (M): 0,1
- *Crest Elevation (M): 395
- *Crest Length (M): 550
- *Apron Elevation (M): 370
- *Apron Length (M): 550
- *Design Head (M): 4
- Gates: 0

Fonte: O Autor (2024).

A evapotranspiração potencial a ser aplicada no balanço hídrico dos reservatórios foi especificada individualmente para cada estrutura simulada no HEC-HMS. Nesse caso, a análise dos resultados foi verificada individualmente, de modo a optar entre a evapotranspiração potencial da sub-bacia e as normais climatológicas do INMET a partir da estação meteorológica mais próxima.

3.17 INDICADORES DE EFICIÊNCIA APLICADOS ÀS SIMULAÇÕES HIDROLÓGICAS

A avaliação da qualidade das simulações hidrológicas pode ser verificada através de indicadores estatísticos. Diversos indicadores podem ser mais adequados para situações específicas, de modo a permitir avaliar a qualidade das vazões máximas, vazões mínimas ou erros percentuais do volume escoado.

Tendo em vista o número de bacias hidrográficas simuladas, optou-se por adotar os indicadores mais usuais às simulações hidrológicas e utilizados nas pesquisas correlatas anteriormente descritas. Para as séries de vazão calculadas no HEC-HMS através de simulações hidrológicas quase-distribuídas aplicou-se os indicadores de Nash-Sutcliffe (NSE), Percentual do viés de frequência (PBIAS), Desvio Padrão da Raiz do Erro Quadrático Médio (RSR) e Coeficiente de Determinação (R^2), conforme Equações 31, 32, 33 e 34, descritas em Nash e Sutcliffe (1970), Moriasi *et al.* (2007), Gunathilake *et al.* (2020) e Le *et al.* (2020), cujas faixas de performance estão indicadas na Tabela 11.

$$NSE = 1 - \left(\frac{\sum_{i=1}^n (Q_{obs} - Q_{cal})^2}{\sum_{i=1}^n (Q_{obs} - \overline{Q_{obs}})^2} \right) \quad \text{Eq. 31}$$

$$PBIAS = \left(\frac{\sum_{i=1}^n (Q_{obs} - Q_{cal})}{\sum_{i=1}^n Q_{obs}} \right) \cdot 100 \quad \text{Eq. 32}$$

$$RSR = \frac{\sqrt{\sum_{i=1}^n (Q_{obs} - Q_{cal})^2}}{\sqrt{\sum_{i=1}^n (Q_{obs} - \overline{Q_{obs}})^2}} \quad \text{Eq. 33}$$

$$R^2 = \left(\frac{\sum_{i=1}^n (Q_{obs} - \overline{Q_{obs}}) \cdot \sum_{i=1}^n (Q_{cal} - \overline{Q_{cal}})}{\sqrt{\sum_{i=1}^n (Q_{obs} - \overline{Q_{obs}})^2} \cdot \sqrt{\sum_{i=1}^n (Q_{cal} - \overline{Q_{cal}})^2}} \right)^2 \quad \text{Eq. 34}$$

Onde:

Q_{obs} - Vazão observada, m³/s

$\overline{Q_{obs}}$ - Vazão observada média, m³/s

Q_{cal} - Vazão calculada, m³/s

$\overline{Q_{cal}}$ - Vazão calculada média, m³/s

Tabela 11 – Performance geral dos indicadores estatísticos para simulações de vazão.

Performance	NSE	PBIAS	RSR
Muito boa	$0,75 < NSE \leq 1,00$	$BIAS < \pm 5$	$0,00 \leq RSR \leq 0,50$
Boa	$0,65 < NSE \leq 0,75$	$\pm 5 \leq BIAS \leq \pm 10$	$0,50 < RSR \leq 0,60$
Satisfatória	$0,50 < NSE \leq 0,65$	$\pm 10 \leq BIAS \leq \pm 15$	$0,60 < RSR \leq 0,70$
Insatisfatória	$NSE \leq 0,50$	$BIAS \geq \pm 15$	$RSR > 0,70$

Fonte: Moriasi *et al.* (2007).

Para o NSE e R^2 , o valor ótimo é atingido quanto os indicadores se aproximam de 1, enquanto para os indicadores PBIAS e RSR, o valor ótimo é 0.

O conjunto de indicadores foi aplicada para calibração de cada posto tendo como referência vazões observadas médias diárias sobre o calendário juliano para o período de dados disponível em cada posto, comparado com as vazões simuladas. A validação das simulações foi realizada avaliando o conjunto de indicadores de performance sobre as vazões diárias observadas e simuladas.

3.18 CORREÇÃO DE VIÉS EM VAZÕES GERADAS COM PRECIPITAÇÕES ESTIMADAS POR SENSORIAMENTO REMOTO

Para correção de viés em vazões geradas com precipitações estimadas por sensoriamento remoto recorreu-se a aplicação de técnicas de processamento por conjunto do tipo *ensemble*. A metodologia proposta buscou reduzir erros sistemáticos através de três ponderações combinadas de forma empírica. A primeira refere-se à combinação de 15 séries de vazões, sendo as vazões provenientes das séries CHIRPS, IMERG-F, CDR, CCS-CDR e PDIR, em sua forma nativa, e após o método de correção $BIAS_{PIXEL}$ e $BIAS_{AREA}$. A segunda correção foi realizada através de um peso mensal e a terceira um fator de ajuste em função de magnitude das vazões geradas. A método ensemble foi aplicado conforme descrito na Equação 35.

$$Q_{cor} = \sum_{i=1}^n (q_i * fq_i + \dots + q_n * fq_n) * fm_j * fv_k \quad \text{Eq. 35}$$

Onde:

Q_{COR} - vazão diária corrigida, (m³/s);

q_i - vazão diária gerada com a série de precipitação i, (m³/s);

$f q_i$ - fator de ponderação aplicado à série de vazão q_i ;

q_n - vazão diária gerada com a série de precipitação n, (m³/s);

$f q_n$ - fator de ponderação de série de vazão q_n

fm - fator de correção mensal aplicado à média de vazões ponderadas;

fv - fator de correção de magnitude de vazões aplicado à média de vazões ponderadas.

O conjunto de pesos foi obtido aplicando o método de otimização de Gradiente Reduzido Generalizado (GRG) não linear disponível na ferramenta Solver do programa computacional Excel 2019 (Microsoft, 2019). Três bacias hidrográficas foram estudadas para avaliação dos métodos de correção de viés em vazões geradas a partir de precipitações estimadas por sensoriamento remoto. As bacias dos rios Sirinhaém, Una e Pajeú foram escolhidas por representarem, respectivamente, áreas com totalidade no clima úmido, misto de semiárido e úmido e totalidade de clima semiárido.

4 RESULTADOS E DISCUSSÕES

4.1 ACURÁCIA DE PRECIPITAÇÕES ESTIMADAS POR SENSORIAMENTO REMOTO

4.1.1 Geoprocessamento de dados de precipitação

O processamento das séries de precipitação possui finalidades distintas aos objetivos propostos. A primeira refere-se a formar uma série de precipitações compreendida como série de referência, sendo estas observadas em solo através de leituras em pluviômetros. Outra, refere-se as médias diárias calculadas sobre os recortes de bacias hidrográficas de Pernambuco, permitindo avaliar as precipitações estimadas por sensoriamento remoto (PES), bem como o desenvolvimento da modelagem hidrológica no HEC-HMS.

A alternativa de precipitações especializadas, no formato de arquivos matriciais, ainda é uma solução pouco usual na modelagem hidrológica, mas que traz expectativas para maior assimilação de dados. Estas expectativas se justificam uma vez que a precipitação é um dos dados de entrada mais importante dos modelos hidrológicos e a representação da distribuição espacial das chuvas contribui principalmente sobre os efeitos de propagação da onda de cheia na bacia hidrográfica.

As precipitações diárias observadas entre 01 de janeiro de 1990 a 31 de dezembro de 2020 foram representadas por 11.323 arquivos GeoTIFF, com tamanho de 386 Kilobytes (Kb) e resolução espacial 2 km, totalizando uma base de aproximadamente 4,5 Gigabytes (Gb).


O resultado das interpolações dos dados pontuais dos pluviômetros para os dias 17 e 18 de junho de 2010 pode ser visto na Figura 54, visando ilustrar precipitações significativas, onde observa-se maiores acumulados sobre o litoral e a região agreste de Pernambuco.

O mesmo recorte temporal dos dias 17 e 18 de junho de 2010 é apresentado na Figura 55 para a série de precipitações CHIRPS 2.0. Em análise visual é possível observar a resolução espacial distinta entre a série CHIRPS, com 5 Km de resolução espacial, e a série interpolada da Apac.

Outro aspecto a ser observado em análise visual qualitativa refere-se aos valores máximos de cada série que resultam, pontualmente, em acumulados com mais que o dobro de precipitação entre as séries. O processamento da série CHIRPS resultou em 1,8 Gb de dados.

Figura 54 – Resultado de processamento de precipitações diárias observadas em pluviômetros.

A) dia 17/06/2010 e B) dia 18/06/2010




Fonte: O Autor (2024).

Outro conjunto de dados de precipitação estimada por sensoriamento remoto refere-se as séries PERSIANN. Na Figura 56 ilustra-se as precipitações dos produtos PERSIANN CDR, PERSIANN CCS-CDR e PERSIANN PDIR, para o dia 17 de junho de 2010.

Observa-se que o padrão de identificação do evento chuvoso se mantém para as três bases de dados, havendo características específicas destacadas pela resolução espacial de 25 km, no caso do PERSIANN CDR, e 4 km para as séries CCS-CDR e PDIR. Ou ainda pelos algoritmos de processamento e suas

características intrínsecas como a melhor precisão da base CDR em função do pós-processamento, a melhor resolução da base CCS-CDR e a finalidade de identificação de eventos extremos da base PDIR.

Figura 55 – Precipitação diária da base de dados CHIRPS 2.0. A) dia 17/06/2010 e B) dia 18/06/2010




Fonte: O Autor (2024).

O recorte de 31 anos de dados da série PERSIANN CDR, que recobre todo território de Pernambuco e partes de outros estados, resultou em uma base de dados de 115 Mb. A série PERSIANN PDIR é mais curta, possui 21 anos de dados, e resulta em 144 Mb de dados, tendo em vista as diferentes resoluções espaciais. A série CCS-

CDR também resulta em 144 Mb de dados por ter a mesma resolução espacial que a série PDIR.

Figura 56 - Precipitação diária da base de dados PERSIANN em 17 de junho de 2010.

A) PERSIANN-CDR, B) PERSIANN CCS-CDR e C) PERSIANN PDIR.



Fonte: O Autor (2024).


Por fim o quinto conjunto de dados de precipitação processado refere-se à série de IMERG-F, versão 6, para a qual foram baixados arquivos da camada referente a precipitação calibrada (Pcal). Uma vez ajustados os fluxos de processamento com a finalidade de converter arquivos NetCDF para GeoTIFF e para ASC.

O processamento de 7.516 arquivos na extensão .NC4, com resolução espacial de aproximadamente 10 km que totalizavam 297 Mb, resultou em 2,1 Gb de dados na extensão ASC, havendo a necessidade de reamostrar a base para resolução espacial de 2 km, visando utilizar a mesma malha computacional do HEC-HMS.

Na Figura 57a visualiza-se exemplos dos dados IMERG utilizados na modelagem hidrológica do HEC-HMS e na Figura 57b exemplo da precipitação média sobre as bacias hidrográficas avaliadas, cujas séries de dados foram extraídas dos centroides e na sequência aplicados indicadores estatísticos.

Figura 57 - Precipitação diária da base de dados GPM, série IMERG-F V06.

A) Dia 17/06/2010 e B) Média por sub-bacia no dia 17/06/2010




Fonte: O Autor (2024).

4.1.2 Acurácia das precipitações anuais médias estimadas por sensoriamento remoto

Uma vez observadas as características gerais dos dados a partir de análise visual, quantificou-se as precipitações anuais médias em cada bacia hidrográfica da área estudada. Antes de avaliar as séries de precipitação cabe destacar o recorte de mesorregiões de Pernambuco que ajudará na correlação entre localização geográfica e regiões climáticas da região estudada, conforme Figura 58.

Figura 58 – Bacias hidrográficas e mesorregiões de Pernambuco.



Fonte: O Autor (2024).


Resgatando a caracterização climática (Figura 31) e as isoietas de precipitações anuais médias (Figura 32) apresentadas, observa-se que três Unidades de Planejamento Hídricos possuem predominância de clima úmido, no caso a UP04, UP14, UP15. A UP01 e a UP05 podem ser observadas com similaridade por possuírem interface com as regiões Agreste e Mata. A UP06 e a UP07 estão inteiramente inseridas na região Agreste, enquanto as demais unidades (UP08 a UP13) representam a região do Sertão, e a porção mais seca da área de estudo.

Embora os resultados obtidos não possuam pretensões de atualizar as normais climatológicas da área de estudo, uma vez que a metodologia perfeitamente

adotada não é adequada para tal, entende-se que os números encontrados no presente estudo devem seguir a tendência climatológica. A fim de verificar a qualidade do processamento dos dados de precipitação observados em pluviômetros, apresenta-se o comparativo entre as precipitações médias anuais do Atlas Pluviométrico da CPRM (2011), para o período de 1977 a 2006, e as séries disponibilizadas pela Apac (2020) entre 1990 e 2020, conforme Figura 59.

Duas características qualitativas podem ser observadas na Figura 59. A primeira mostra que as características da climatologia de precipitações foram preservadas para todas as bacias hidrográficas estudadas, e a segunda, que ocorreu tendência de redução dos valores médios anuais para o período mais recente. Tais resultados representam os efeitos de mudanças climáticas e encontram-se em concordância com o estudo de Marengo, Torres e Alves (2016) que indicam aumento das regiões semiáridas e tendência de desertificação no nordeste brasileiro.


Figura 59 – Comparativo de precipitações anuais médias com dados CPRM (1977-2006) e APAC (1990-2020).



Fonte: O Autor (2024).


Ao observar as precipitações estimadas por sensoriamento remoto (PES), utilizou-se a precipitação Apac de 1990 a 2020 como referência, sobre as médias anuais das séries CHIRPS, IMERG-F, PERSIANN CDR, PERSANN CCS-CDR e PERSIANN-PDIR, conforme Figura 60. Enquanto na Figura 60 observa-se as precipitações em números absolutos, na Figura 61 tem-se as diferenças relativas entre as precipitações APAC e as precipitações estimadas para cada bacia hidrográfica avaliada.

Figura 60 – Precipitação anual média observada em pluviômetros pela APAC e dos produtos de sensoriamento remoto CHIRPS, IMERG-F, CDR, CCS-CDR e PDIR.



Fonte: O Autor (2024).

Figura 61 – Desvio relativo entre a precipitação média anual observada em pluviômetros e nas séries CHIRPS, IMERG-F, CDR, CCS-CDR e PDIR.



Fonte: O Autor (2024).

Os resultados apresentados indicam que as bacias hidrográficas GL-1, GL-2 e Sirinhaém possuem os maiores desvios negativos em todas as séries de PES avaliadas. A maior diferença chegou a -73% para a série PERSIANN CCS-CDR, e ocorreu na UP15 correspondente ao GL-2. A tendência de variações negativas predomina entre todas as séries de PES e bacias hidrográficas dos rios Goiana, Una, Capibaribe, Ipojuca, Mundaú e Ipanema que possuem características principais das regiões de Matas e Agreste de Pernambuco.

A mudança da predominância de desvios negativos para desvios positivos ocorre a partir da bacia hidrográfica do rio Moxotó, bem como as demais unidades

hidrográficas inseridas nas mesorregiões do São Francisco e Sertão Pernambuco. A maior variação positiva sobre a precipitação média anual foi de 46%, e ocorreu na bacia do rio das Garças.

4.1.3 Acurácia das precipitações mensais médias estimadas por sensoriamento remoto

Além da avaliação das precipitações estimadas em escala anual, analisou-se os dados em frequência mensal. Para tal, calculou-se valores mensais médios a partir do Atlas Pluviométrico da CPRM e das séries da Apac apresentados na Tabela 12.

Tabela 12 – Precipitações médias mensais para as bacias hidrográficas estudadas.

		Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Anual
Goiana	CPRM	55	69	111	147	138	190	168	99	49	24	25	28	1102
	APAC	56	71	95	118	142	184	162	84	44	21	18	27	1022
Capibaribe	CPRM	48	56	90	99	98	129	109	60	32	14	18	25	778
	APAC	48	51	72	82	94	120	95	54	25	13	12	21	687
Ipojuca	CPRM	54	60	96	108	103	136	115	64	37	19	24	28	843
	APAC	54	57	85	92	107	129	108	63	30	19	16	24	784
Sirinhaém	CPRM	74	87	133	194	229	300	265	158	88	33	27	39	1629
	APAC	79	83	122	164	217	280	243	148	79	36	29	33	1514
Una	CPRM	59	57	94	123	132	177	164	100	47	28	25	26	1030
	APAC	53	54	82	101	135	166	145	89	47	23	18	24	938
Mundaú	CPRM	50	49	75	78	99	142	111	81	39	24	25	24	798
	APAC	45	45	65	76	110	130	122	79	41	24	16	20	773
Ipanema	CPRM	50	65	91	86	65	64	66	31	23	15	25	25	606
	APAC	49	55	77	66	83	81	73	45	20	20	17	22	607
Moxotó	CPRM	60	79	106	87	54	50	42	22	14	6	23	34	578
	APAC	56	72	95	70	61	45	40	20	9	13	18	25	524
Pajeú	CPRM	88	100	146	97	56	30	22	11	5	4	21	41	620
	APAC	78	96	117	84	53	26	19	7	3	10	20	30	543
Terra Nova	CPRM	98	94	150	87	45	13	9	5	12	5	26	54	597
	APAC	83	98	99	70	31	11	8	2	2	8	20	40	473
Brígida	CPRM	115	101	142	84	37	9	9	29	27	5	30	70	659
	APAC	98	95	106	74	32	11	9	2	3	10	27	49	516
Garças	CPRM	99	76	122	54	27	8	5	10	17	5	41	64	529
	APAC	77	82	87	54	22	6	5	2	3	10	31	48	425
Pontal	CPRM	100	79	125	45	28	8	5	4	10	5	47	68	524
	APAC	82	74	83	53	16	5	3	1	3	10	36	47	414
GL-1	CPRM	76	101	157	204	241	312	233	149	70	43	27	49	1663
	APAC	84	93	141	201	233	290	240	135	70	36	28	42	1593
GL-2	CPRM	76	95	138	207	253	346	271	156	79	32	27	53	1734
	APAC	83	89	137	195	241	303	248	145	76	39	29	44	1630

Fonte: O Autor (2024).

Considera-se que estes resultados por si trazem contribuições técnicas e valores de referência para outras aplicações de hidrologia, uma vez que não é usual dispor de médias mensais de precipitação atualizadas para o recorte das bacias hidrográficas estudadas. De modo análogo às séries anuais, calculou-se os desvios relativos entre a precipitação mensal média (DPM) observada em pluviômetros e nas séries de PES. Nas Figura 62, Figura 63, Figura 64, Figura 65 e Figura 66 tem-se os desvios mensais para as séries CHIRPS, IMERG-F, PERSIANN CDR, PERSIANN CCS-CDR e PERSIANN PDIR.

Figura 62 – Desvio relativo entre a precipitação mensal média observada e a série CHIRPS.

CHIRPS	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
GL-1	-19%	3%	5%	8%	11%	1%	-22%	-69%	-74%	-66%	-53%	-5%
GL-2	-29%	-21%	-13%	-15%	-18%	-29%	-44%	-78%	-80%	-75%	-48%	-17%
SIRINHAEM	-22%	-10%	-1%	-5%	-18%	-31%	-43%	-80%	-79%	-73%	-45%	10%
GOIANA	1%	1%	17%	23%	5%	-1%	-15%	-67%	-71%	-65%	-45%	13%
UNA	-5%	8%	10%	3%	-18%	-26%	-57%	-76%	-80%	-62%	-25%	16%
CAPIBARIBE	-3%	16%	25%	13%	-11%	-26%	-37%	-63%	-73%	-56%	-23%	29%
IPOJUCA	-15%	1%	1%	-5%	-18%	-40%	-52%	-76%	-81%	-66%	-34%	15%
MUNDAU	4%	17%	5%	8%	-6%	-50%	-52%	-77%	-78%	-52%	-11%	33%
IPANEMA	-1%	11%	13%	4%	-22%	-60%	-59%	-78%	-77%	-60%	-24%	43%
MOXOTO	10%	-2%	13%	3%	-9%	-49%	-60%	-76%	-74%	-59%	-10%	23%
PAJEU	13%	3%	13%	9%	-4%	-37%	-52%	-84%	-63%	-50%	-15%	26%
TERRA NOVA	12%	10%	34%	20%	-5%	-54%	-59%	-78%	-58%	-21%	11%	27%
BRIGIDA	17%	21%	40%	19%	7%	-47%	-74%	-85%	-67%	-35%	9%	19%
GARÇAS	3%	6%	30%	15%	-10%	-35%	-79%	-79%	-80%	-28%	27%	10%
PONTAL	-6%	6%	26%	7%	-15%	-51%	-94%	-93%	-87%	2%	30%	15%

Fonte: O Autor (2024).

Figura 63 – Desvio relativo entre a precipitação mensal média observada e a série IMERG-F

IMERG-F	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
GL-1	-4%	12%	-16%	-1%	-28%	-14%	-53%	-86%	-73%	-76%	-65%	-4%
GL-2	-4%	8%	-15%	-4%	-37%	-23%	-63%	-84%	-76%	-71%	-69%	-4%
SIRINHAEM	-5%	-1%	-14%	-2%	-43%	-38%	-73%	-88%	-80%	-64%	-68%	8%
GOIANA	27%	26%	-3%	18%	-17%	-1%	-52%	-79%	-68%	-68%	-58%	12%
UNA	36%	36%	18%	30%	-28%	-27%	-73%	-83%	-78%	-46%	-45%	55%
CAPIBARIBE	45%	54%	25%	46%	-8%	0%	-54%	-74%	-69%	-28%	-35%	55%
IPOJUCA	38%	38%	19%	30%	-18%	-15%	-62%	-75%	-72%	-31%	-45%	64%
MUNDAU	51%	48%	30%	35%	-26%	-35%	-80%	-83%	-77%	-35%	-22%	105%
IPANEMA	56%	36%	24%	29%	-8%	-26%	-65%	-72%	-65%	-18%	-14%	89%
MOXOTO	65%	38%	24%	22%	2%	-7%	-39%	-53%	-31%	21%	-17%	85%
PAJEU	48%	40%	31%	33%	23%	38%	8%	-1%	33%	63%	-12%	90%
TERRA NOVA	34%	28%	47%	25%	54%	31%	49%	26%	32%	76%	24%	82%
BRIGIDA	10%	34%	45%	20%	27%	-7%	-29%	-44%	-3%	43%	14%	68%
GARÇAS	23%	17%	25%	29%	41%	17%	-16%	-29%	-37%	66%	25%	45%
PONTAL	19%	25%	23%	20%	28%	-1%	-5%	-3%	-43%	77%	27%	37%

Fonte: O Autor (2024).

Figura 64 – Desvio relativo entre a precipitação mensal média observada e a série CDR.

CDR	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
GL-1	-35%	-12%	-21%	-26%	-36%	-30%	-43%	-88%	-86%	-66%	-60%	-31%
GL-2	-31%	-11%	-21%	-30%	-42%	-39%	-54%	-89%	-87%	-62%	-56%	-24%
SIRINHAEM	-20%	-9%	-15%	-24%	-39%	-47%	-63%	-90%	-85%	-58%	-46%	3%
GOIANA	2%	7%	12%	7%	-20%	-12%	-33%	-86%	-84%	-37%	-46%	0%
UNA	27%	33%	13%	2%	-22%	-42%	-66%	-89%	-82%	-28%	-8%	44%
CAPIBARIBE	35%	50%	40%	34%	5%	-11%	-33%	-82%	-78%	18%	16%	53%
IPOJUCA	32%	38%	22%	17%	-4%	-28%	-53%	-88%	-75%	1%	11%	56%
MUNDAU	59%	58%	46%	27%	-8%	-51%	-75%	-90%	-83%	-17%	39%	95%
IPANEMA	68%	56%	47%	52%	9%	-35%	-60%	-83%	-65%	31%	49%	110%
MOXOTO	58%	35%	26%	45%	26%	-9%	-31%	-65%	-8%	87%	42%	83%
PAJEU	29%	19%	18%	33%	36%	56%	15%	-3%	100%	70%	10%	56%
TERRA NOVA	20%	8%	16%	15%	36%	71%	28%	256%	161%	63%	33%	29%
BRIGIDA	13%	17%	14%	11%	9%	22%	-21%	141%	173%	41%	11%	19%
GARÇAS	23%	18%	14%	11%	24%	41%	18%	209%	78%	53%	21%	24%
PONTAL	16%	25%	15%	9%	40%	54%	57%	114%	52%	71%	17%	35%

Fonte: O Autor (2024).

Figura 65 – Desvio relativo entre a precipitação mensal média observada e a série CCSCDR

CCS-CDR	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
GL-1	-30%	-2%	-26%	-24%	-53%	-78%	-87%	-98%	-99%	-92%	-71%	-17%
GL-2	-26%	-10%	-24%	-31%	-61%	-82%	-90%	-98%	-98%	-87%	-62%	-16%
SIRINHAEM	-12%	-7%	-20%	-30%	-65%	-87%	-92%	-99%	-98%	-87%	-58%	9%
GOIANA	7%	5%	1%	0%	-49%	-73%	-87%	-98%	-99%	-84%	-54%	13%
UNA	22%	36%	9%	-2%	-56%	-88%	-93%	-99%	-98%	-78%	-20%	46%
CAPIBARIBE	34%	45%	35%	36%	-37%	-77%	-89%	-99%	-98%	-58%	14%	60%
IPOJUCA	29%	41%	26%	17%	-37%	-83%	-90%	-99%	-97%	-59%	5%	65%
MUNDAU	49%	62%	49%	24%	-60%	-92%	-95%	-99%	-97%	-69%	24%	100%
IPANEMA	67%	73%	72%	59%	-39%	-88%	-93%	-99%	-91%	-44%	53%	127%
MOXOTO	51%	44%	35%	53%	-15%	-86%	-89%	-97%	-88%	-25%	43%	92%
PAJEU	34%	28%	23%	53%	14%	-64%	-75%	-90%	-78%	-14%	35%	74%
TERRA NOVA	30%	20%	14%	28%	30%	-53%	-73%	-28%	-39%	8%	71%	52%
BRIGIDA	22%	13%	11%	13%	-2%	-59%	-81%	-75%	-56%	-3%	46%	39%
GARÇAS	37%	27%	27%	22%	39%	-54%	-79%	-56%	-58%	31%	55%	46%
PONTAL	25%	36%	26%	9%	43%	-59%	-55%	-74%	-66%	59%	38%	58%

Fonte: O Autor (2024).

Figura 66 – Desvio relativo entre a precipitação mensal média observada e a série PDIR.

PDIR	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
GL-1	-19%	6%	3%	-11%	-31%	34%	-25%	-83%	-77%	-74%	-60%	-17%
GL-2	-22%	-20%	-7%	-25%	-45%	18%	-34%	-76%	-76%	-64%	-56%	-30%
SIRINHAEM	-10%	-15%	-11%	-17%	-39%	14%	-46%	-82%	-66%	-54%	-47%	-21%
GOIANA	17%	6%	8%	3%	-27%	52%	-27%	-81%	-73%	-53%	-41%	-9%
UNA	36%	24%	1%	-4%	-35%	28%	-55%	-84%	-77%	-43%	0%	10%
CAPIBARIBE	46%	23%	19%	21%	-18%	66%	-35%	-79%	-86%	-6%	24%	25%
IPOJUCA	51%	28%	6%	5%	-22%	43%	-45%	-79%	-73%	-17%	8%	14%
MUNDAU	77%	51%	27%	4%	-28%	8%	-62%	-86%	-69%	-25%	28%	60%
IPANEMA	91%	66%	33%	14%	-6%	47%	-53%	-78%	-34%	39%	27%	57%
MOXOTO	65%	46%	16%	16%	42%	66%	-31%	-52%	37%	73%	18%	30%
PAJEU	49%	26%	10%	24%	105%	158%	35%	8%	115%	104%	15%	22%
TERRA NOVA	45%	27%	9%	33%	204%	288%	125%	292%	264%	158%	66%	10%
BRIGIDA	39%	16%	4%	28%	109%	175%	20%	217%	142%	109%	59%	15%
GARÇAS	64%	22%	12%	60%	185%	334%	88%	306%	238%	133%	77%	21%
PONTAL	49%	27%	13%	64%	198%	395%	105%	200%	218%	140%	55%	45%

Fonte: O Autor (2024).

Sobre a série CHIRPS (Figura 62), observa-se que na região do litoral (GL-1, GL-2 e Sirinhaém) as precipitações estimadas estão abaixo das precipitações observadas ao longo de todos os meses, e entre os meses de maio a novembro as precipitações são sempre estimadas abaixo do observado para todas as bacias hidrográficas estudadas.

Tais ocorrências justificam o melhor desempenho da série CHIRPS para a região semiárida, uma vez que no período chuvoso do Sertão as precipitações são registradas em excesso, enquanto no período chuvoso do litoral, as precipitações são registradas em déficit.

Sobre a série IMERG-F (Figura 63), também se observa que no litoral as precipitações estimadas estão abaixo das precipitações observadas ao longo de todos os meses. No entanto é menos perceptível as variações negativas entre os meses de maio a novembro na região do Sertão, havendo desvios positivos de precipitação para a maior parte do ano nessa região.

Na série PERSIANN CDR (Figura 64) é possível identificar padrões de variações distintos entre o litoral e o sertão de Pernambuco. No litoral as precipitações estimadas por sensoriamento remoto foram abaixo das observadas ao longo de todo o ano. Nas regiões Agreste e Mata as variações negativas ocorrem entre maio e setembro, compreendendo todo o período chuvoso da região, enquanto na região do Sertão as estimativas foram acima das observações durante todo o ano.

A série PERSIANN CCS-CDR (Figura 65) possui as maiores discrepâncias negativas entre todas as séries, com predominância negativa entre os meses de junho a outubro. Já a série PERSIANN PDIR mantém o padrão de variações da série PERSIANN CDR. No entanto observa-se que em junho ocorre um viés com desvios positivos para todas as bacias estudadas, bem como ocorrem desvios positivos mais discrepantes para o sertão, chegando até cinco vezes a precipitação observada.

4.1.4 Acurácia de precipitações diárias estimadas por sensoriamento remoto

Ao observar o comportamento das variações mensais das precipitações estimadas por sensoriamento remoto, deve-se entender que esta análise representa um recorte específico das características climatológicas da área estudada. Um novo conjunto de informações pode ser analisado através de indicadores de acurácia da PES na frequência temporal diária.

Os indicadores de Probabilidade de Detecção (POD), Taxa de Acurácia (AR), Taxa de Alarme Falso (FAR), Coeficiente de Correlação de Pearson (CC), Viés de Frequência (BIAS_f), e Raiz do Erro Quadrático Médio (RMSE) foram obtidos para precipitação diária média em cada bacia hidrográfica e para as séries dados de precipitação Apac, CHIRPS 2.0, IMERG-F, PERSIANN CDR, PERSIANN CCS-CDR e PERSIANN PDIR.

Observa-se que a POD possui tendência de crescimento à medida que a bacia hidrográfica se localiza mais a oeste, sendo os melhores resultados obtidos na série CHIRPS e na faixa de 61 e 62%, respectivamente, para as bacias hidrográficas dos rios Pajeú e Brígida, conforme Figura 67. O indicador de FAR teve seus melhores resultados para a região litoral e da zona da mata, ocorrendo também para a série CHIRPS na faixa de 26% na unidade GL-2, conforme Figura 68.


A Taxa de Acurácia (AR) variou de 4 a 10% entre todas as séries e bacias hidrográficas estudadas, conforme apresentado na Figura 69. Os melhores resultados do litoral foram de 10% para a série IMERG-F e nas bacias hidrográficas GL-1, GL-2 e Sirinhaém, enquanto na região do Sertão, o melhor resultado foi de 9% para a série CHIRPS na bacia do rio Pajeú.

O Coeficiente de Correlação de Pearson (CC) variou de 0,19 para a bacia do Goiana na série IMERG até 0,72 para a bacia do Pajeú na série CHIRPS, conforme Figura 70. Observa-se tendência crescente do indicador no sentido do litoral ao sertão e que os valores encontrados para a série IMERG-F possuem predominância inferior aos demais, bem como os valores das séries CDR e CHIRPS possuem predominância superior em relação ao conjunto de dados.

O Viés de Frequência (BIAS_f) possui melhor desempenho quando próximo de 1, ou no caso 100%. A tendência de variação do BIAS_f segue o padrão da POD, uma vez que os resultados do litoral estão abaixo do observado e vão aumentando à oeste, com tendência de estimativa superior ao observado para o Sertão. Os melhores resultados foram de 96% (CDR), 99% (CHIRPS) e 106% (IMERG), respectivamente nas bacias hidrográficas Moxotó, Brígida e Pajeú (Figura 71).


Sobre a variação do RMSE apresentada na Figura 72, identifica-se os maiores erros no litoral chegando à faixa de 20 mm para a série PERSIANN PDIR na UP GL-1, enquanto os melhores resultados foram encontrados na faixa de 3 mm para a bacia do Pajeú sobre a série CHIRPS.

Figura 67 – Probabilidade de Detecção (POD) de eventos de precipitação diária nas séries estimadas por sensoriamento remoto analisadas.




Fonte: O Autor (2024).

Figura 68 – Taxa de Alarme Falso (FAR) de eventos de precipitação diária nas séries estimadas por sensoriamento remoto analisadas.




Fonte: O Autor (2024).

Figura 69 – Razão de Acurácia (AR) de eventos de precipitação diária nas séries estimadas por sensoriamento remoto analisadas.




Fonte: O Autor (2024).

Figura 70 – Coeficiente de Correlação (CC) de eventos de precipitação diária nas séries estimadas por sensoriamento remoto analisadas.




Fonte: O Autor (2024).

Figura 71 – Viés de Frequência (BIASf) de eventos de precipitação diária nas séries estimadas por sensoriamento remoto analisadas.



Fonte: O Autor (2024).

Figura 72 – Raiz do Erro Quadrático Médio (RMSE) de eventos de precipitação diária nas séries estimadas por sensoriamento remoto analisadas.



Fonte: O Autor (2024).

A análise do conjunto de indicadores permite identificar a existência de padrões e tendências sobre as séries de precipitações avaliadas. A influência de aspectos climáticos e geográficos pode ser observada em todos os indicadores ao dispor os resultados de cada bacia hidrográfica no sentido do litoral ao sertão, da esquerda para a direita.

A influência da área da bacia hidrográfica é percebida de forma sutil, mas na Figura 69 verifica-se por exemplo que a bacia do rio Terra Nova obteve resultados levemente inferiores às suas bacias vizinhas que possuem maior área de contribuição.

4.2 CORREÇÃO DE VIÉS EM PRECIPITAÇÕES ESTIMADAS POR SENSORIAMENTO REMOTO

4.2.1 Acurácia de precipitações médias anuais estimadas por sensoriamento remoto após correção de viés (BIAS)


O Método Delta para correção de viés (BIAS) foi aplicado em duas abordagens distintas. A abordagem tratada a seguir como $BIAS_{PIXEL}$ toma como referência de correção às médias observadas em cada pixel da precipitação estimada por sensoriamento remoto, enquanto o método $BIAS_{AREA}$ adotou precipitação de referência sobre as médias mensais em cada bacia hidrográfica.

Os valores de Desvio Relativo de Precipitação Anual (DPA) sem correção de BIAS encontram-se na Figura 73a e variaram numa amplitude de -73% a 46%. Após a correção de viés pela abordagem $BIAS_{PIXEL}$ (Figura 73b) estes valores reduziram para -22% na série PERSIANN CCS-CDR na bacia GL-1 e 20% para a série PERSIANN PDIR na bacia Sirinhaém.

Melhorias ainda mais significativas foram observadas ao aplicar a correção pela abordagem $BIAS_{AREA}$, conforme Figura 73c, os valores mais negativos de -3% ocorreram nas séries CDR e CCS-CDR, enquanto os maiores desvios positivos foram próximos de 6% para a série IMERG.

Registra-se ainda comportamentos tendenciais específicos, como exemplo de que após a correção $BIAS_{PIXEL}$ as séries IMERG e PDIR passar a ter desvios positivos em todas as bacias hidrográficas, enquanto as séries CHIRPS, CDR e CCS-CDR possuem tendência de desvios negativos. O comportamento oposto é observado na série PDIR após a correção $BIAS_{AREA}$, onde a tendência de desvio passa a ser negativa.

Figura 73 – Desvio relativo de precipitação anual média (DPA). (a) Séries de precipitações sem correção; (b) Correção por $\text{BIAS}_{\text{PIXEL}}$ e (c) Correção por $\text{BIAS}_{\text{AREA}}$.




Fonte: O Autor (2024).

4.2.2 Acurácia de precipitações médias mensais estimadas por sensoriamento remoto após correção de viés (BIAS)

Os valores do Desvio Relativo de Precipitação Mensal (DPM) sem correção de BIAS para a série CHIRPS encontram-se na Figura 74, onde verifica-se variação entre -94% e 43%. Após a correção $\text{BIAS}_{\text{PIXEL}}$ estes desvios passaram para valores entre -87% a 215%. Aqui observa-se que os métodos de correção de viés também podem degradar a qualidade do dado original, cabendo registrar que o desvio de 215% ocorreu para o mês de agosto na bacia do Pontal, onde a precipitação média mensal observada é próxima de 1mm, logo para valores tão baixos de precipitação qualquer desvio se torna muito significativo.

Ainda analisando a série IMERG-F, ao aplicar a correção $BIAS_{AREA}$ os desvios passaram para valores entre -18% e 53%, indicando melhor desempenho que o método $BIAS_{PIXEL}$, porém com desempenho inferior ao comparar os resultados das demais séries através do mesmo método. Na Figura 76 ilustra-se a variação do DPM para as séries PERSIANN CDR, PERSIANN CCS-CDR e PERSIANN PDIR.

Figura 76 – Desvio relativo de precipitação mensal (DPM) das séries PERSIANN originais e após correção por $BIAS_{PIXEL}$ e $BIAS_{AREA}$.



Legenda:

■ DPM < -25%
 ■ -25% ≤ DPM < -5%
 ■ -5% ≤ DPM ≤ 5%
 ■ 5% < DPM ≤ 25%
 ■ DPM > 25%

Fonte: O autor

De modo geral, ao avaliar as precipitações mensais médias, o método $BIAS_{AREA}$ apresentou melhor desempenho que o método $BIAS_{PIXEL}$. Conforme observa-se na Figura 76, a série PERSIANN CDR obteve melhor desempenho entre as demais com desvios relativos de precipitações médias mensais (DPM) variando de -90% a 256% na série sem correção, passando para desvios de -33% a 114% após a correção $BIAS_{PIXEL}$ e -6% a 5% após a correção $BIAS_{AREA}$.

A série PERSIANN CCS-CDR resultou em desvios mensais entre -58% e 175% após a correção $BIAS_{PIXEL}$ e -7% a 13% após a correção $BIAS_{AREA}$. Já a série PERSIANN PDIR obteve desvios entre -69% e 82% após a correção $BIAS_{PIXEL}$ e -7% a 10% após a correção $BIAS_{AREA}$.

De modo geral avalia-se que as precipitações estimadas por sensoriamento remoto possuem desempenho satisfatório para representar as normais climatológicas mensais após correção de viés em áreas superiores a 1.000 km².

4.2.3 Acurácia de precipitações diárias estimadas por sensoriamento remoto após correção de viés (BIAS)

Os resultados satisfatórios para a correção de viés (BIAS) nas séries anuais e mensais não é observado da mesma forma ao analisar as séries diárias. Verificou-se comportamento distinto na acurácia dos dados de precipitação estimada por satélite entre as bacias hidrográficas de clima úmido e de clima semiárido. Para representar as duas condições climáticas foram analisadas as bacias do Sirinhaém e Pajeú, sendo estas bacias representativas sobre a variabilidade climática regional.

Na Tabela 13 e Tabela 14 tem-se os indicadores de performance para precipitações observadas e estimadas por sensoriamento remoto, na bacia dos rios Sirinhaém, Una e Pajeú, para as séries CHIRPS, IMERG, PERSIANN CDR, CCS-CDR e PDIR sem correção, ajustadas por $BIAS_{PIXEL}$ e $BIAS_{AREA}$. Tais resultados ilustram a complexidade das estimativas de precipitação através de produtos de sensoriamento remoto, onde observa-se que os métodos de correção aplicados podem ser efetivos, indiferentes ou ineficientes a depender da região estudada, série avaliada ou do método de correção aplicado.

Para ilustrar graficamente a apresentação destes resultados utilizou-se a Figura 77 onde o indicador de Probabilidade de Detecção é apresentado para a série de dados original (Figura 77a) e para as séries corrigidas pelos métodos $BIAS_{PIXEL}$ (Figura 77b) e $BIAS_{AREA}$ (Figura 77c).

Tabela 13 – Indicadores de performance para precipitações diárias estimadas por sensoriamento remoto, na bacia do Sirinhaém, para as séries sem correção, ajustadas por $BIAS_{PIXEL}$ e $BIAS_{AREA}$.

Série	Correção	POD	FAR	AR	BIAS	RMSE	CC
CHIRPS	Sem Correção	24%	26%	8%	32%	13,3	0,39
	$BIAS_{PIXEL}$	25%	27%	8%	34%	19,0	0,37
	$BIAS_{AREA}$	25%	27%	8%	34%	22,2	0,35
IMERG-F	Sem Correção	29%	30%	10%	41%	11,8	0,25
	$BIAS_{PIXEL}$	41%	22%	14%	52%	26,3	0,47
	$BIAS_{AREA}$	45%	26%	12%	61%	10,3	0,48
PERSIANN CDR	Sem Correção	26%	37%	9%	42%	11,8	0,45
	$BIAS_{PIXEL}$	29%	39%	10%	46%	44,2	0,32
	$BIAS_{AREA}$	23%	42%	9%	57%	10,3	0,37
PERSIANN CCS-CDR	Sem Correção	27%	45%	7%	50%	5,9	0,35
	$BIAS_{PIXEL}$	23%	38%	8%	37%	59,3	0,24
	$BIAS_{AREA}$	33%	38%	8%	36%	37,0	0,30
PERSIANN PDIR	Sem Correção	26%	36%	9%	41%	17,4	0,41
	$BIAS_{PIXEL}$	26%	36%	9%	41%	17,4	0,33
	$BIAS_{AREA}$	28%	37%	10%	45%	30,8	0,35

Fonte: O Autor (2024).


Na Figura 77 observa-se que a série de dados IMERG-F obteve melhor desempenho após o ajuste de BIAS havendo predominância de resultados favoráveis nas séries de precipitação corrigidas pelo $BIAS_{PIXEL}$ e na maior parte das bacias corrigidas pelo $BIAS_{AREA}$. Os melhores resultados da série IMERG-F para o indicador POD após a correção de viés foi de 67% nas bacias Ipanema, Pajeú, Brígida e Pontal.

Tabela 14 – Indicadores de performance para precipitações diárias estimadas por sensoriamento remoto, na bacia do Pajeú, para as séries sem correção, ajustadas por $BIAS_{PIXEL}$ e $BIAS_{AREA}$.

Série	Correção	POD	FAR	AR	BIAS	RMSE	CC
CHIRPS	Sem Correção	61%	30%	9%	87%	3,0	0,72
	$BIAS_{PIXEL}$	60%	32%	9%	88%	3,0	0,72
	$BIAS_{AREA}$	60%	32%	9%	89%	3,1	0,69
IMERG-F	Sem Correção	56%	47%	8%	106%	5,9	0,40
	$BIAS_{PIXEL}$	67%	31%	10%	98%	5,1	0,77
	$BIAS_{AREA}$	67%	36%	8%	104%	5,1	0,77
PERSIANN CDR	Sem Correção	59%	48%	9%	113%	4,9	0,67
	$BIAS_{PIXEL}$	56%	47%	8%	105%	4,5	0,66
	$BIAS_{AREA}$	51%	51%	7%	114%	4,5	0,68
PERSIANN CCS-CDR	Sem Correção	55%	50%	7%	109%	5,3	0,65
	$BIAS_{PIXEL}$	52%	45%	8%	95%	4,0	0,59
	$BIAS_{AREA}$	55%	45%	8%	93%	4,8	0,60
PERSIANN PDIR	Sem Correção	55%	49%	8%	107%	6,7	0,56
	$BIAS_{PIXEL}$	55%	49%	8%	107%	6,7	0,60
	$BIAS_{AREA}$	51%	48%	8%	98%	5,5	0,61

Fonte: O Autor (2024).

Figura 77 – Probabilidade de detecção (POD) de eventos de precipitação diária.
(a) Séries Originais; (b) Correção BIAS_{PIXEL} e (c) Correção BIAS_{ÁREA}.



Fonte: O Autor (2024).

Gráficos de dispersão entre a precipitação observada e estimada nas bacias do Sirinhaém, Una e Pajeú encontram-se apresentados na Figura 78, Figura 79 e Figura 80, respectivamente. As precipitações estimadas nas bacias de clima úmido, representadas pela unidade bacia hidrográfica do rio Sirinhaém, obtiveram baixa correlação com a precipitação observada independente da série de dados analisada, conforme observa-se através dos valores de R^2 abaixo de 0,22 (Figura 78), mesmo após a correção de viés. Para série CHIRPS ocorreu degradação da qualidade dos

dados diários após multiplicação pelo fator de correção mensal, resultando numa redução do R^2 de 39%. A bacia do rio Una sofre influência de áreas úmidas e semiáridas, os gráficos de dispersão para esta bacia do rio Una encontram-se na Figura 79 e para bacia do rio Pajeú, exclusivamente no semiárido na Figura 80.

Figura 78 – Gráfico de dispersão entre precipitações diárias observadas e estimadas por sensoriamento remoto na bacia do Sirinhaém, para as séries CHIRPS e IMERG sem correção, ajustadas por $\text{BIAS}_{\text{PIXEL}}$ e $\text{BIAS}_{\text{AREA}}$.






Figura 79 – Gráfico de dispersão entre precipitações diárias observadas e estimadas por sensoriamento remoto na bacia do Una, para as séries CHIRPS e IMERG sem correção, ajustadas por $BIAS_{PIXEL}$ e $BIAS_{AREA}$.



Fonte: O Autor (2024).

Figura 80 – Gráfico de dispersão entre precipitações diárias observadas e estimadas por sensoriamento remoto na bacia do Pajeú, para as séries CHIRPS e IMERG sem correção, ajustadas por $\text{BIAS}_{\text{PIXEL}}$ e $\text{BIAS}_{\text{AREA}}$.



Fonte: O Autor (2024).

Para a série IMERG-F o R^2 aumentou de 0,06 para 0,22 com a correção de $\text{BIAS}_{\text{PIXEL}}$, mas apesar do aumento de 253% o resultado não indica correlação satisfatória entre os dados observados e estimados.

As precipitações estimadas na bacia do rio Una resultaram em maior similaridade à bacia úmida do Sirinhaém, fato este associado a menor acurácia que nas bacias de clima semiárido. As precipitações estimadas nas bacias de clima semiárido, representadas pela unidade bacia hidrográfica do rio Pajeú, mostraram resultados distintos entre as séries de precipitação estimada por satélite para as séries CHIRPS e IMERG-F (Figura 80). A linha de tendência do gráfico de dispersão entre os dados do rio Pajeú apresenta R^2 entre 0,16 e 0,60. A série CHIRPS manteve a redução da correlação após a correção do BIAS, porém com uma redução suave de 7% do valor de R^2 . Para a série IMERG-F o R^2 aumentou de 0,16 para 0,60 após a correção de $BIAS_{PIXEL}$, representando um aumento de 270% e atingindo a melhor correlação entre os dados observados e estimados.

A estimativa da precipitação a partir do processamento de imagens de satélite pode trazer erros espaciais e temporais em relação a posição e distribuição da chuva de um determinado evento (Wu *et al.*, 2021). Estudos regionais para avaliar a acurácia das precipitações estimadas e os padrões dos erros sistemáticos auxiliam na compreensão da origem dos erros, permitem aperfeiçoar os algoritmos de processamento ou identificar os métodos de correção mais adequados. Estudos indicam padrões de erros distintos na estimativa de precipitação em função da posição geográfica e da época do ano (Shen *et al.*, 2020). Tais padrões foram observados no presente trabalho conforme resultados indicados entre a Figura 67 e a Figura 76 onde é possível verificar que os desvios relativos de precipitação são significativamente distintos entre os meses do ano e ao longo da distribuição espacial das bacias hidrográficas. A variabilidade climática global é um fator que dificulta a metodologia de estimativa das precipitações uma vez que o processo de formação das chuvas é distinto entre as regiões, pode mudar ao longo do ano para uma mesma localidade ou até mesmo se a precipitação ocorre durante o dia ou a noite sendo um fator que altera a evolução temporal de um evento chuvoso (Liu e Zipser, 2009; Gao *et al.*, 2021) A região do nordeste brasileiro e os resultados obtidos ilustram tais condições.

Sobre as características da precisão posicional verifica-se que é possível analisar a precisão da precipitação estimada com base em um ponto de referência, no caso os pluviômetros (Hidayah *et al.*, 2021; Peng *et al.*, 2021), ou a precisão das precipitações médias sobre uma área como os limites de uma bacia hidrográfica (Mei *et al.*, 2014; Katiraie-Boroujerdy *et al.*, 2020; Zhang *et al.*, 2021;). Cada abordagem possui relevância, mas para o caso de assimilação dos dados de precipitação em

simulações hidrológicas passa a ser mais relevante a precipitação média em uma área, o que também pode vir a reduzir os erros posicionais das estimativas.

Verifica-se também que as séries de precipitações analisadas representam satisfatoriamente os padrões de normais climatológicas mensais após a correção de BIAS, sendo o método BIAS_{AREA} mais efetivo para correção das precipitações médias anuais e mensais. A avaliação das precipitações diárias sugere que a qualidade dos dados de precipitação sofre maior impacto sobre a localização geográfica e características climáticas do que da série de dados analisada.

Entre a Figura 67 e a Figura 72 é possível observar que a tendência dos indicadores analisados evidencia que a qualidade das estimativas de precipitação aumenta à medida que a bacia hidrográfica está mais distante do litoral por onde percorre-se duas regiões climáticas distintas, sendo o litoral do nordeste uma região susceptível a precipitações formadas por sistemas meteorológicos distintos e de características torrenciais.

Entre a Figura 78 e a Figura 80 avalia-se as séries CHIRPS e IMERG-F em bacias hidrográficas que representam as diferentes regiões climáticas da área de estudo. Tais resultados demonstram que a mesma técnica de correção de viés pode degradar a qualidade dos dados para uma determinada área ou não trazer ganhos de qualidade expressivos para outra localidade.

Verifica-se também que uma determinada série de precipitação pode apresentar ganhos de qualidade diferentes, uma vez que na Figura 80 observa-se a série CHIRPS apresentar melhoria discreta na correlação com as precipitações observadas. Enquanto a série IMERG-F melhora significativamente e apresenta as maiores probabilidades de detecção de eventos entre as séries de dados analisadas, conforme observado em outros estudos (Lober *et al.*, 2023).


4.3 PROCESSAMENTO E ASSIMILAÇÃO DE BASES DE DADOS GEOESPACIAIS

4.3.1 Modelo digital do terreno e delimitação de sub-bacias

O Modelo Digital do Terreno (MDT) é um dos principais elementos para caracterização física das bacias hidrográficas. A base de dados utilizada é originada do Programa Pernambuco Tridimensional (PE3D) (Pernambuco, 2020), o que por si não seria um resultado específico deste trabalho.

Considerando que a metodologia proposta executou processamentos que adequam os dados originais à aplicação hidrológica requisitada, apresentam-se o resultado de processamento da base de dados do PE3D, conforme mostrado na Figura 81.

Figura 81 – Modelo digital do terreno (MDT) da base cartográfica PE3D sobre a área de estudo.



*Modelo digital do terreno da base cartográfica Pernambuco Tridimensional (Pernambuco, 2020)
Fonte: O Autor (2024).


O produto apresentado inclui o preenchimento de vazios na base de arquivos matriciais de MDT, em áreas de corpos d'água ou pequenas falhas provenientes de

nuvens. Também faz parte destes resultados a reamostragem da resolução espacial de 1 m para 10 m, visando a operacionalização do processamento no HEC-HMS.

A área recortada para modelagem hidrológica recobre 89.524 km², dos quais 87.792 km² fazem parte do Estado de Pernambuco e representam 89,5% do território estadual. As áreas remanescentes correspondem a 452 km² da bacia do rio Una e 985 km² da bacia do rio Moxotó, que integram o estado de Alagoas, e 295 km² da bacia do rio Brígida no Ceará.

A divisão das sub-bacias e a rede de drenagem gerada no HEC-HMS foram agrupadas em 15 Unidades de Planejamento Hídrico, que por sua vez foram subdivididas em 2.904 sub-bacias hidrográficas e uma rede de drenagem de 10.034 km, conforme ilustrado na Figura 82.

Figura 82 – Bacias modeladas no HEC-HMS. A) Sub-bacias e B) Rede de drenagem.



Fonte: Autor

A estratégia adotada no desenvolvimento de geometria dos modelos hidrológicos procura beneficiar o conceito de distribuição das informações, onde buscou-se um maior número de sub-bacias, uma vez que a calibração individual de cada unidade não é a intenção da metodologia adotada. Para cada bacia hidrográfica simulada apresenta-se na Tabela 15 a área total, o número de sub-bacias e a extensão da rede de drenagem simulada.

A bacia hidrográfica do rio Pajeu é a maior do Estado de Pernambuco, sendo dividida em 414 sub-bacias. Este número não trouxe dificuldades às simulações computacionais, no entanto observou-se que a operacionalidade do HEC-HMS se tornou mais lenta quanto da inclusão dos reservatórios, fato que não ocorreu com a mesma intensidade em bacias com menos elementos como Una e Ipojuca.

Tabela 15 – Áreas totais, sub-bacias e rede de drenagem das bacias hidrográficas simuladas.


UP	Nome	Área, (km ²)	Sub-bacias	Rede de drenagem, (km)
01	Goiana	2.832	305	634
02	Capibaribe	7.523	268	985
03	Ipojuca	3.453	59	370
04	Sirinhaém	2.071	54	287
05	Una	6.693	157	716
06	Mundaú	3.121	187	518
07	Ipanema	6.115	149	636
08	Moxotó	9.727	239	882
09	Pajeú	16.854	414	1.534
10	Terra Nova	4.905	244	739
11	Brígida	13.781	341	1.228
12	Garças	4.105	100	451
13	Pontal	6.031	174	670
14	GL1	1.143	116	192
15	GL2	1.169	82	192
Total		89.524	2.904	10.034

Fonte: O Autor (2024).

4.3.2 Armazenamento de água na cobertura vegetal

O MapBiomass se mostrou uma base de dados de importância relevante ao subsidiar mais de um parâmetro físico integrado ao modelo HEC-HMS. A estimativa do armazenamento de água na cobertura vegetal é primeiro recorte do MapBiomass a ser apresentado como resultado da reclassificação de base de dados, conforme distribuição espacial ilustrada na Figura 83.

Figura 83 – Armazenamento de água na cobertura vegetal a partir do MapBiomias.



Fonte: O Autor (2024).

Os valores de referência propostos por Fleming e Neary (2004) e Holberg (2014) foram integralmente aplicáveis a área de estudo, com amplitude de 0 a 2,54 mm. Os valores médios por bacia hidrográfica variaram de 1,45 mm na bacia hidrográfica do rio Mundaú (UP06) a 1,82 mm na bacia do rio Terra Nova (UP10).

4.3.3 Armazenamento de água na superfície


O armazenamento de água na superfície estimado a partir da declividade em percentual calculada a partir do Modelo Digital do Terreno da base cartográfica PE3D demonstrou maiores declividades nas bacias hidrográficas litorâneas, sendo a maior média de 22,5% encontrada para a bacia hidrográfica do rio Sirinhaém. Enquanto a bacia hidrográfica mais plana encontra-se em localização extremamente oposta à oeste, com 4,6% para a UP13 do rio Pontal, resultando respectivamente em armazenamento de água na superfície de 6 a 12 mm. O armazenamento de água na superfície é um recurso utilizado para estimar parte das perdas iniciais, onde as áreas planas terão maiores perdas.

Uma vez definido um valor fixo de armazenamento de água na superfície, este parâmetro funciona como um reservatório com uma capacidade representada em

milímetros e interligando-se ao balanço hídrico de modo que só ocorrem precipitações excedentes após o atendimento das demandas deste “reservatório” de superfície.

A variação das declividades (Figura 84A) para a área de estudo e a distribuição do armazenamento de água na superfície (Figura 84B) mostra a correlação inversa entre os parâmetros, ao tempo que também apresenta os valores de armazenamento calculado para cada sub-bacia hidrográfica.

Figura 84 – Armazenamento de água na superfície. A) Mapa de declividade, e B) Armazenamento de água na superfície em cada sub-bacia.



Fonte: O Autor (2024).

A declividade mostra as áreas planas e íngremes, e a correlação entre as depressões naturais e susceptibilidade ao escoamento superficial é coerente a partir desta declividade. No entanto, a existência de pequenas barragens é uma característica regional fortemente presente nas áreas de clima semiárido, chega à ordem de milhares de pequenos reservatórios e indiscutivelmente se configura em um acréscimo aos valores calculados.

Uma estratégia para considerar a componente de armazenamento em pequenos reservatórios poderá ser melhorada a partir da distribuição da capacidade de acumulação dos volumes conhecidos ou estimados. Tais estimativas podem ser avaliadas a partir de álgebra de mapas com a diferença entre o MDT e o preenchimento de depressões, definido no HEC-HMS após processamento *Fill Sinks*.

4.3.4 Armazenamento máximo de água no solo

O armazenamento de água no solo é um parâmetro importante na definição da saturação do solo, e por consequência sua variação afetará de forma significativa a resposta sobre os primeiros eventos do período chuvoso.


Na Figura 85A observa-se a distribuição espacial do armazenamento máximo de água no solo para cada *pixel* com resolução espacial de 30 m, enquanto a Figura 85B apresenta o armazenamento de água ajustado para cada sub-bacia modelada no HEC-HMS, em função da condição de umidade correlacionada com a água disponível no solo (AD), cuja amplitude variou de 5,5 a 473,0 mm.

Os valores apresentados seguem a premissa de que o armazenamento máximo de água no solo, calculado a partir do método do Soil Conservation Service (SCS) se dá na condição de umidade relacionada ao CN I. No entanto, durante a etapa de simulação hidrológica observou-se que tais valores não se adequam a todas as sub-bacias uma vez que a representação dos eventos hidrológicos se relaciona com a capacidade de armazenamento de água no solo, a taxa de infiltração para cada tipo de solo e a distribuição temporal dos eventos de chuvas em cada região.

Operacionalmente, o armazenamento máximo de água no solo adotado no HEC-HMS foi calculado para um valor entre a condição da umidade I e III, em uma relação linear com base na amplitude da água disponível no solo (AD) disponibilizada pela EMBRAPA. Após aplicar este método observou-se melhoria nos indicadores de performance para as vazões calculadas no HEC-HMS.

Figura 85 – Armazenamento de água no solo.

A) Armazenamento máximo na área de estudo e B) Armazenamento ajustado por sub-bacia.



4.3.5 Taxa de infiltração

No método de perdas de Déficit Constante, a taxa de infiltração é um parâmetro que contribui para a definição das vazões de pico, sendo recomendado que a fase de calibração avalie a vazão de pico dos eventos extremos da série observada.

Por outro lado, as estimativas da taxa de infiltração para inicialização rápida do HEC-HMS possuem uma complexidade adicional, quando se observa a anisotropia dos solos e a sensibilidade deste parâmetro no método de Déficit Constante. A

correlação entre a classificação textural dos solos e condutividade hidráulica saturada é o parâmetro físico do solo com maior afinidade à taxa de infiltração, sendo inicialmente aplicados os valores sugeridos por Rawls, Brakensiek e Miller (1983) e ajustados conforme indicado na Tabela 16.

Tabela 16 – Textura dos solos, condutividade hidráulica saturada teórica e ajustada.

Textura do Solo	Condutividade hidráulica saturada teórica, (mm/h)	Condutividade hidráulica saturada ajustada, (mm/h)
Arenosa	116,80	30,0
Arenosa Média	30,50	15,0
Média Arenosa	10,20	10,0
Média	2,50	3,0
Média Siltosa	7,60	5,0
Média Argilosa e Arenosa	1,50	5,0
Média Argilosa	1,00	4,0
Média Argilosa e Siltosa	1,00	4,0
Argilosa Arenosa	0,50	4,0
Argilosa Siltosa	0,50	3,0
Argilosa	0,25	2,0

Fonte: Adaptado de Rawls, Brakensiek e Miller (1983).


Durante as simulações identificou-se que os solos com valor referencial de infiltração igual ou menor que 2,5 mm/h resultaram em vazões de pico elevada em alguns eventos, motivo pelo qual fez-se um ajuste.

A espacialização da classificação textural dos solos e da condutividade hidráulica saturada média para cada sub-bacia pode ser vista na Figura 86, onde observa-se predominância de solos com taxa de infiltração de 2 a 4 mm/h na região litorânea, de 15 a 30 mm/h na região agreste e de 4 a 10 mm/h na região do sertão.

Será avaliado a seguir que tais faixas de condutividade hidráulica estão associadas à qualidade dos resultados das simulações hidrológicas, sendo as regiões de solos mais arenosos, com maior condutividade hidráulica, as áreas com predominância de resultados insatisfatórios ao representar as vazões.

Ao verificar solos com condutividade hidráulica de 15 a 30 mm/h, capacidade de armazenamento máximo de água no solo da ordem de 100 a 200 mm conclui-se que o armazenamento de água no solo pode variar de 0 a 100% em menos de 24 horas, logo para estas áreas seriam recomendadas simulações intradiárias.

Figura 86 – Relação entre A) classificação textural dos solos e B) condutividade hidráulica saturada.




Fonte: O Autor (2024).

4.3.6 Áreas impermeáveis

As áreas impermeáveis, por sua vez, não trazem grande complexidade quanto a classificação a partir da base MapBiomias, uma vez que os critérios adotados atenderam as condições de inicialização rápida do HEC-HMS. Ao caracterizar como área impermeável, as áreas de infraestrutura urbana, corpos d'água, afloramentos rochosos, áreas de mineração e outras áreas não vegetadas obteve-se o resultado apresentado na Figura 87A.

Figura 87 – Classificação de áreas impermeáveis.

A) Áreas impermeáveis e B) Percentual impermeável por sub-bacia.



Fonte: O Autor (2024).

A bacia hidrográfica com maior percentual de áreas impermeáveis foi a GL-1 com 13,6% de sua área total, enquanto a bacia do rio das Garças possui o menor percentual impermeável com 0,08%, conforme distribuição espacial e amplitudes ilustradas na Figura 87.

4.4 MODELAGEM HIDROLÓGICA A PARTIR DA INICIALIZAÇÃO RÁPIDA DO HEC-HMS

Uma vez concluído o processamento dos dados de precipitação, cujas séries foram armazenadas em arquivos no formato DSS, e o processamento dos dados geoespaciais do Programa Pernambuco Tridimensional (PE3D), do Projeto MapBiomass e do Sistema Brasileiro de Classificação de Solos (SiBCS) foram realizadas as simulações hidrológicas no modelo HEC-HMS. Dez bacias hidrográficas foram simuladas, conforme ilustrado na Figura 88.


A partir das simulações, avaliou-se os resultados da inicialização rápida do HEC-HMS em um conjunto inicial de três bacias hidrográficas de referência de modo a representar características de regiões climáticas distintas. Inicialmente as bacias dos rios Sirinhaém, Una e Pajeú foram analisadas e seus resultados foram avaliados em conjunto de modo a subsidiar eventuais ajustes e correções às considerações técnicas realizadas e fontes de referência disponíveis.

Entre os principais ajustes realizados nessa etapa de retro análise destaca-se a correção da condição de umidade associada à água disponível no solo e aplicada para a definição do armazenamento máximo de água no solo, bem como os ajustes sobre a taxa de infiltração utilizada no método de perdas que foram associados a classificação textural dos solos.

De modo geral, em avaliação qualitativa, foram observados resultados mais satisfatórios sobre às simulações nas bacias hidrográficas em regiões de clima úmido ante as regiões de clima semiárido. Alguns aspectos podem ser registrados ao buscar compreender esta situação.


Na Figura 89 ilustra-se as vazões diárias médias de longo termo no calendário juliano para a estação fluviométrica Engenho Mato Grosso, o melhor resultado entre as 49 estações com simulação de vazão modeladas no HEC-HMS. Nesta sub-bacia verifica-se que o balanço hídrico possui excedente de precipitações e ocasiona regime perene no rio Sirinhaém, onde também ocorre a predominância de solos argilosos e ausência de grandes reservatórios que interfiram no regime de vazões naturais.

Figura 88 – Bacias hidrográficas com vazões simuladas no HEC-HMS.



Fonte: O Autor (2024).

Figura 89 – Vazões diárias médias de longo termo na estação fluviométrica Engenho Mato Grosso, bacia do rio Sirinhaém.



Fonte: O Autor (2024).

Ao observar os indicadores de performance para a estação Engenho Mato Grosso na verifica-se indicador de Eficiência de Nash-Sutcliffe (NSE) igual a 0,77, Desvio Padrão da Raiz do Erro Quadrático Médio (RSR) igual a 0,50 e o percentual de viés (P_{BIAS}) de 1,4%, todos indicando uma simulação muito boa.

Além do NSE obtido para as séries de dados diários calculou-se o NSE juliano, obtido para as médias dos dias julianos que dão origem ao gráfico plotado na Figura 89. Neste caso o NSE da série diária resulta em 0,77, enquanto o NSE juliano foi para 0,97. Avalia-se que o indicador NSE juliano é um recurso adicional para a avaliação da qualidade das vazões médias. Adicionalmente, observou-se que o método de transformação ModClark apresenta limitações relacionadas à taxa de infiltração de solos argilosos causando vazões de pico excessivas em eventos de chuvas intensas nos solos de baixa taxa de infiltração.

Em contraponto, o resultado mais desfavorável obtido nas simulações hidrológicas no HEC-HMS ocorreu para a estação Inajá, bacia hidrográfica do rio Moxotó. Neste posto fluviométrico o valor de NSE foi de -0,29, o RSR foi igual a 1,1 e o P_{BIAS} foi igual a -19%, todos indicadores apontando para resultados insatisfatórios.

No caso da bacia hidrográfica do rio Moxotó, localizada em clima semiárido, cita-se algumas características que diferem das condições da bacia de clima úmido do rio Sirinhaém. Para a bacia do Moxotó identifica-se predominância de solos com classificação textural arenosa e a existência de muitos reservatórios que interferem nas vazões naturais, incluindo o reservatório Francisco Sabóia (Poço da Cruz), o maior em capacidade no Estado de Pernambuco, com cerca de 500 hm³.

Adicionalmente, verifica-se a recorrência de déficit de umidade no solo e uma maior variabilidade de normais climatológicas entre os meses, muitas vezes com o maior escoamento superficial no mês de fevereiro, redução de chuvas em março e novo aumento em abril. Em suma, verificou-se que as estações cujos resultados não foram satisfatórios possuem características de regiões com maior similaridade à estação Inajá. É provável que a condição de solos arenosos e elevada taxa de infiltração sejam uma das condições mais desfavoráveis, associadas à aplicação de um intervalo computacional diário das simulações que não representa com precisão a saturação e geração de escoamento superficial direto nos solos arenosos.

Os indicadores de desempenho sobre as demais estações, incluindo nome, área de drenagem, NSE de calibração, NSE de validação, RSR, P_{BIAS} e Coeficiente de Determinação (R^2) obtidos a partir das simulações hidrológicas podem ser consultados na Tabela 17.

Analisando os indicadores de performance das vazões geradas no HEC-HMS, em 49 estações fluviométricas, verifica-se que 37 estações (75%) tiveram performance satisfatória ou boa para o indicador NSE, as séries geradas em 44 estações (90%) tiveram resultados bons ou muito bons para o indicador P_{BIAS} e 38 estações (77%) tiveram performance satisfatória ou boa para o indicador RSR.

A distribuição espacial e as faixas de performance para cada estação fluviométrica simulada encontram-se na Figura 90, Figura 91 e Figura 92, respectivamente para o NSE, P_{BIAS} e RSR. Resultados gráficos para cada estação fluviométrica encontram-se no Anexo E.

Do total, 13 estações tiveram seus resultados considerados insatisfatórios para o NSE ou RSR, enquanto apenas 3 estações indicaram uma performance considerada insatisfatória quando ao P_{BIAS} . Para estas regiões deve-se considerar, além das condições relevantes citadas, que podem estar contribuindo para tais resultados insatisfatórios, como a existência de centenas de pequenos reservatórios, a operação de grandes reservatórios para controle de cheias e abastecimento humano

que podem alterar as vazões naturais, falhas nos dados observados ou a necessidade de calibrações específicas visando a melhoria dos resultados.

Tabela 17 – Indicadores de desempenho sobre séries de vazões simuladas no HEC-HMS.

Bacia	Estação	Área (km ²)	NSE Calib	NSE Valid	P _{BIAS} (%)	RSR	R ²
Goiana	Engenho Volta	329	0,49	0,23	-3,1	0,9	0,24
Goiana	Vicência	192	0,61	0,51	2,2	0,7	0,54
Goiana	Engenho Retiro	472	0,83	0,57	-2,6	0,7	0,57
Goiana	Caricé	1320	0,88	0,63	-1,2	0,6	0,65
Goiana	Nazaré da Mata	692	0,90	0,67	-3,2	0,6	0,68
Goiana	Engenho Itapissirica	1230	0,85	0,52	-3,5	0,7	0,59
Capibaribe	Santa Cruz do Capibaribe	1560	0,37	0,38	-35,0	0,8	0,41
Capibaribe	Toritama	2450	0,34	0,30	-34,0	0,8	0,41
Capibaribe	Salgadinho	4910	0,61	0,28	-6,1	0,8	0,60
Capibaribe	Limoeiro	5580	0,51	0,51	-4,8	0,7	0,48
Capibaribe	Paudalho	6190	0,71	0,51	-3,0	0,7	0,54
Capibaribe	Engenho Canaveira	311	0,85	0,58	0,5	0,6	0,59
Capibaribe	Vitória de Santo Antão	264	0,71	0,51	0,0	0,7	0,49
Capibaribe	São Lourenço da Mata II	7290	0,83	0,53	-5,4	0,7	0,54
Ipojuca	Sanharó	672	0,49	0,46	-6,5	0,8	0,49
Ipojuca	Caruaru	2000	0,54	0,52	1,8	0,7	0,61
Ipojuca	Gravatá	2650	0,66	0,65	-1,9	0,6	0,68
Ipojuca	Engenho Tabocas	2960	0,85	0,69	-0,3	0,5	0,72
Ipojuca	Engenho Maranhão	3310	0,86	0,72	4,2	0,5	0,78
Sirinhaém	Amaraji	139	0,72	0,28	1,6	0,8	0,73
Sirinhaém	José Mariano	295	0,86	0,70	5,3	0,6	0,84
Sirinhaém	Engenho Bento	537	0,92	0,68	-0,3	0,6	0,91
Sirinhaém	Engenho Mato Grosso	1310	0,97	0,77	-1,4	0,5	0,96
Una	Cachoeirinha	1210	0,32	0,34	-6,4	0,8	0,36
Una	Capivara	2610	0,75	0,42	-4,6	0,8	0,44
Una	Belém de Maria	388	0,81	0,59	0,8	0,6	0,63
Una	Catende	718	0,91	0,68	0,6	0,6	0,68
Una	Palmares	4910	0,90	0,54	-0,8	0,7	0,56
Una	Engenho Florescente	181	0,87	0,60	-1,2	0,6	0,65
Una	Jacuípe	756	0,96	0,75	0,8	0,5	0,79
Una	Barreiros	6550	0,90	0,69	4,8	0,6	0,72
Canhoto	Canhotinho	808	0,67	0,55	-0,2	0,6	0,60
Mundaú	Correntes	624	0,83	0,54	2,1	0,7	0,61
Inhumas	Palmeirina	128	0,38	0,13	4,6	0,9	0,23
Paraíba	Brejão	326	0,63	0,53	3,6	0,7	0,54
Ipanema	Horizonte Alegre	567	0,36	0,24	5,8	0,9	0,30
Ipanema	Águas Belas	3910	0,32	0,45	-7,3	0,7	0,47
Moxotó	Caroalina	1740	0,53	0,45	-1,9	0,8	0,43
Moxotó	Inajá	8250	-0,17	-0,29	-19,0	1,1	0,07


Bacia	Estação	Área (km ²)	NSE Calib	NSE Valid	P _{BIAS} (%)	RSR	R ²
Pajeú	Afogados da Ingazeira	3540	0,59	0,58	-4,5	0,7	0,62
Pajeú	Flores	4970	0,76	0,57	-6,1	0,7	0,60
Pajeú	Serra Talhada	5910	0,78	0,62	-12,2	0,6	0,67
Pajeú	Floresta	12300	0,75	0,70	-2,7	0,6	0,70
Pajeú	Ilha Grande	2260	0,34	0,42	-13,9	0,8	0,44
Jaboatão	Moreno	92	0,79	0,58	-1,1	0,7	0,59
Jaboatão	Cachoeira Tapada	90	0,79	0,51	-1,4	0,7	0,51
Jaboatão	Destilaria Inexport	235	0,81	0,53	-1,9	0,7	0,55
Jaboatão	Pirapama	372	0,91	0,53	-1,0	0,7	0,54
Jaboatão	Destilaria Bom Jesus	149	0,85	0,53	0,8	0,7	0,53

Fonte: O Autor (2024).

A evolução de recursos computacionais e o detalhamento do relevo a partir de bases de dados de sensoriamento remoto demandam a atualização das técnicas e estratégias para as simulações hidrológicas. O conceito de inicialização rápida de modelos hidrológicos busca reunir bases de dados de sensoriamento remoto para caracterização detalhada da bacia hidrográfica de modo a subsidiar a estimativa inicial dos parâmetros calibráveis.


A proposta de inicialização rápida do HEC-HMS foi aplicada com êxito nas simulações que tiveram a precipitação observada como dado de entrada. As contribuições desta pesquisa, a partir da revisão de literatura e considerações locais, evidenciam que a assimilação de dados geoespaciais com o Modelo Digital do Terreno (MDT) do PE3D, o mapa de classificação de solos do Sistema Brasileiro de Classificação de Solos (SiBCS) e o mapa de uso e ocupação do solo do MapBiomas resultaram em simulações satisfatórias ou boas para mais de 75% das séries com base na avaliação do NSE, P_{BIAS} e RSR, após a calibração da vazão de base.

Figura 90 – Performance geral do indicador NSE sobre vazões diárias médias simuladas no HEC-HMS.




Fonte: O Autor (2024).

Figura 91 – Performance geral do indicador BIAS sobre vazões diárias médias simuladas no HEC-HMS.



Fonte: O Autor (2024).

Figura 92 – Performance geral do indicador RSR sobre vazões diárias médias simuladas no HEC-HMS.




Fonte: O Autor (2024).

4.5 AVALIAÇÃO DE DESEMPENHO EM MODELO HIDROLÓGICO CONCENTRADO E SEMIDISTRIBUÍDO

A relação entre o detalhamento físico e matemático dos processos simulados através de modelos hidrológicos concentrados e distribuídos nem sempre forma consenso sobre os ganhos de qualidade aos resultados das simulações. A avaliação comparativa entre as vazões diárias médias de longo termo simuladas através do modelo hidrológico semidistribuído HEC-HMS e do modelo concentrado CAWM V permite breve discussão sobre o tema.

Ao analisar a estação fluviométrica Engenho Mato Grosso, para a qual se obteve os melhores resultados a partir dos indicadores de desempenho NSE, P_{BIAS} e RSR, observa-se que os dois modelos hidrológicos representam o comportamento das vazões observadas de forma satisfatória com NSE igual a 0,77 e 0,68, P_{BIAS} de -1,4% e -3,5%, e RSR de 0,50 e 0,56, respectivamente para o modelo HEC-HMS e para o modelo CAWM V, conforme ilustrado na Figura 93.

Figura 93 – Vazões diárias médias de longo termo simuladas através dos modelos hidrológicos HEC-HMS e CAWM V para a bacia hidrográfica do rio Sirinhaém.




Fonte: O Autor (2024).

Ao analisar de forma análoga a estação fluviométrica Palmares, na bacia do rio Una, identifica-se NSE igual a 0,54 e 0,50, P_{BIAS} de -1,4% e -0,8%, e RSB de 0,70

e 0,70, respectivamente para o modelo HEC-HMS e para o modelo CAWM V, conforme ilustrado na Figura 94.

Figura 94 – Vazões diárias médias de longo termo simuladas através dos modelos hidrológicos HEC-HMS e CAWM V para a bacia hidrográfica do rio Una.



Fonte: O Autor (2024).

Graficamente verifica-se que existem diferenças sistemáticas na representação das vazões de pico nos modelos das bacias hidrográficas do rio Sirinhaém e do Una. No caso avaliado, o modelo HEC-HMS possui maior aderência às vazões de base e vazões de pico observadas, sendo estas diferenças intensificadas na bacia do rio Una. Sobre tais resultados destaca-se que outros trabalhos compararam a performance de modelos concentrados e distribuídos (Vansteenkiste *et al.*, 2014; Zeng *et al.*, 2018) indicando desempenho sutilmente superior para os modelos distribuídos.

Tal desempenho deve-se à variação espacial das características físicas e climáticas da bacia hidrográfica. Identificando que a bacia do rio Sirinhaém possui predominância de clima úmido, com precipitações mais bem distribuídas ao longo do ano, e que as características físicas relacionadas, por exemplo, ao armazenamento máximo de água no solo e taxa de infiltração também são mais homogêneas nesta bacia. Entende-se que o desempenho dos modelos concentrados nestas condições seria mais próximo ao do modelo semidistribuído. Logo, na bacia do rio Una, com


maior heterogeneidade de características físicas, demanda maior detalhamento da bacia através de modelos mais sofisticados e detalhamento de parâmetros.

Sobre uma avaliação quantitativa, verifica-se que nas duas condições os modelos geraram simulações aceitáveis para o NSE, P_{BIAS} e RSR, cabendo avaliação de esforço operacional para identificar em quais circunstância uma ferramenta é mais apropriada que outra.

4.6 INFLUÊNCIA DA OPERAÇÃO DE RESERVATÓRIOS NAS SIMULAÇÕES HIDROLÓGICAS


Sobre a inclusão de grandes reservatórios nos modelos hidrológicos, observa-se que este recurso é uma componente essencial para a qualidade das vazões geradas através de simulações computacionais. Tomando como exemplo a bacia hidrográfica do rio Pajeú, apresenta-se os resultados de cenários com e sem barragens para estação fluviométrica de Floresta, conforme Figura 95 e Figura 96.

Figura 95 – Vazões diárias médias de longo termo geradas em cenários sem barragens e com principais existentes na bacia hidrográfica do rio Pajeú, estação fluviométrica Serra Talhada.



Fonte: O Autor (2024).

Figura 96 – Vazões diárias médias de longo termo geradas em cenários sem barragens e com principais existentes na bacia hidrográfica do rio Pajeú, estação fluviométrica Floresta.



Fonte: O Autor (2024).

O cenário com barragens passou a considerar o efeito de amortecimento das vazões de pico armazenadas no reservatório ou laminadas através de vertedouros das barragens Rosário (35 hm³), Brotas (20 hm³), Jazigo (16 hm³) e Serrinha II (311 hm³). Em Serra Talhada os valores de NSE e P_{BIAS} melhoraram de -0,05 e 71%, para 0,62 e 12%, respectivamente. Em Floresta, os valores de NSE e P_{BIAS} passaram, respectivamente, de -0,32 e 71%, para 0,70 e 2,7%.

Em análise gráfica, observa-se que o efeito da inclusão de reservatórios foi positivo para pontos distintos da bacia hidrográfica, mas é perceptível que as vazões geradas ainda são superiores às observadas, de modo que seria pertinente a inclusão de mais barragens ou realizar a calibração de outros parâmetros para melhoria dos resultados.

4.7 MODELAGEM HIDROLÓGICA A PARTIR DE PRECIPITAÇÕES ESTIMADAS POR SENSORIAMENTO REMOTO


A avaliação de performance das simulações hidrológicas tendo como dado de entrada as precipitações estimadas por sensoriamento remoto foi realizada para três bacias hidrográficas: Sirinhaém, Una e Pajeú. Estas bacias hidrográficas representam

regiões com características climáticas distintas na área de estudo. A bacia do rio Sirinhaém localizada inteiramente na região úmida, a bacia do rio Una possui áreas com características úmidas e do semiárido e a bacia do Pajeú, inteiramente no semiárido.

As séries CHIRPS, IMERG-F, PERSIANN CDR, PERSIANN CCS-CDR e PERSIANN PDIR foram avaliadas sem correção de viés, e após correção de viés através de dois métodos de correção: $BIAS_{PIXEL}$ e $BIAS_{AREA}$.

Inicialmente para a bacia hidrográfica do rio Pajeú observa-se que as séries CHIRPS e IMERG-F possuem padrão de viés distintos para as vazões geradas. Verifica-se que ocorrem vazões acima do observado na maior parte do período da série IMERG-F, enquanto as vazões da série CHIRPS estão subestimadas na maior parte do ano, conforme observado na Figura 97.

Figura 97 – Vazões diárias médias de longo termo observadas e geradas para a bacia hidrográfica do rio Pajeú com séries de precipitação CHIRPS e IMERG-F.



Fonte: O Autor (2024).

Considerando as vazões geradas no HEC-HMS, para as bacias dos rios Sirinhaém, Una e Pajeú, tendo como entrada as precipitações observadas em pluviômetros, verificam-se resultados satisfatórios para os principais indicadores de performance NSE, P_{BIAS} e RSR. Na bacia hidrográfica do rio Sirinhaém os indicadores obtidos foram NSE de 0,77, P_{BIAS} igual a 1,4% e RSR de 0,50, no posto Floresta. Na

bacia do rio Una obteve-se NSE de 0,69, P_{BIAS} igual a 4,8% e RSR de 0,60 no posto Barreiros e na bacia do Pajeú os indicadores obtidos foram NSE igual a 0,70, P_{BIAS} de -2,7% e RSR de 0,70 para o posto Floresta, conforme apresentado na Tabela 17.

Os indicadores de performance das vazões geradas a partir das precipitações estimadas por satélite para as bacias Sirinhaém, Una e Pajeú são apresentados na Tabela 18. Tais resultados permitem verificar que as vazões geradas a partir de precipitações estimadas por sensoriamento remoto, em sua forma nativa, ou seja sem correção de viés, não forneceram resultados satisfatórios para as cinco séries e três bacias hidrográficas avaliadas.

Tabela 18 – Indicadores de performance para vazões geradas com precipitações estimadas por sensoriamento remoto com e sem métodos de correção de viés (BIAS).

Série	Bacia	Precipitação estimada sem correção			Precipitação ajustada $BIAS_{PIXEL}$			Precipitação ajustada $BIAS_{AREA}$		
		NSE	P_{BIAS}	RSR	NSE	P_{BIAS}	RSR	NSE	P_{BIAS}	RSR
CHIRPS	Sirinhaém	-1,34	88%	1,53	-7,12	76%	2,85	-40,97	24%	6,48
	Una	-0,52	91%	1,20	-3,93	73%	2,22	-27,4	-15%	5,33
	Pajeú	0,10	28%	0,95	0,36	-75%	0,80	0,64	36%	0,60
IMERG	Sirinhaém	-0,57	70%	1,02	-2,09	78%	1,44	-0,91	87%	1,13
	Una	-0,37	63%	1,17	-21,3	-3%	4,72	-22,9	10%	4,89
	Pajeú	-0,04	-104%	1,01	0,44	-19%	0,73	0,49	-12%	0,74
CDR	Sirinhaém	-1,99	73%	1,73	-410,3	-39%	20,28	-93,21	15%	9,71
	Una	-2,93	62%	1,98	-61,1	-16%	7,88	-26,4	27%	5,23
	Pajeú	0,32	-49%	0,82	0,45	4%	0,74	0,57	55%	0,65
CCS-CDR	Sirinhaém	-1,06	90%	1,44	-1090,0	-72%	33,03	-313,0	-17%	17,72
	Una	-0,57	85%	1,25	-273,0	-70%	16,6	-244,0	-33%	15,7
	Pajeú	-1,37	-213%	1,54	-0,72	-125%	1,31	-0,15	-44%	1,07
PDIR	Sirinhaém	-18,3	53%	3,60	-2,83	69%	1,60	-121,9	5%	9,08
	Una	-15,9	44%	4,12	-102,0	-29%	10,2	-54,3	11%	7,43
	Pajeú	-1,70	-152%	1,62	-0,39	-24%	1,16	-0,44	-31%	1,18

Fonte: O Autor (2024).


Para as bacias do Sirinhaém e Una o NSE é negativo em todas as séries de precipitação sem correção de viés, variando entre -2,93 e -0,37. Nenhum dos métodos de correção de viés trouxe resultados positivos para as vazões geradas nestas bacias hidrográficas, exceto pela melhoria do NSE na bacia do rio Sirinhaém após a correção pelo método $BIAS_{PIXEL}$.

As vazões geradas para as bacias dos rios Sirinhaém e Una com correção de viés nas séries de precipitações estimadas forneceram NSE variando entre -1090,0 e -0,92, P_{BIAS} variando entre -72% e 87% e o RSR entre 1,13 e 33,0. Estes resultados desfavoráveis indicaram que os métodos de correção de viés aplicados, melhoraram alguns indicadores de acurácia das precipitações, porém, em geral, degradaram a acurácia do coeficiente de Nash (NSE) sobre as vazões geradas.

O resultado mais favorável das simulações de vazão sem a correção de viés ocorreu na bacia do Pajeú e foi identificado para a série PERSIANN CDR com NSE de 0,32 e RSR de 0,82 e para a série CHIRPS com P_{BIAS} igual a 28%. De acordo com os indicadores de performance analisados, após a correção de viés, houve melhoria na acurácia das simulações de vazões em todas as séries de precipitação estimada por satélite na bacia do Pajeú, exceto para a série CHIRPS corrigida através do método $BIAS_{PIXEL}$.

Os resultados mais favoráveis no conjunto de simulações com precipitações estimadas por sensoriamento remoto ocorreram com aplicação do método $BIAS_{AREA}$ para série CHIRPS (Figura 98) com NSE de 0,64, P_{BIAS} de 36% e RSR de 0,6. Ainda entre os melhores resultados tem-se na série IMERG-F NSE de 0,49, P_{BIAS} de -12% e RSR de 0,74 e para a série CDR NSE de 0,57, P_{BIAS} de 55% e RSR de 0,65.

Figura 98 – Vazões diárias médias de longo termo observadas e geradas para a bacia hidrográfica do rio Pajeú com séries de precipitação CHIRPS ajustadas por $BIAS_{AREA}$.




Fonte: O Autor (2024).

Visando ilustrar o comparativo entre as vazões observadas e simuladas com precipitação observada e com precipitações estimadas por sensoriamento remoto apresenta-se o gráfico de caixa do tipo *boxplot* para as vazões diárias médias do calendário juliano na Figura 99, Figura 100 e Figura 101, respectivamente para as bacias hidrográficas do Sirinhaém, Una e Pajeú.

Na Figura 99 e na Figura 100, verifica-se que as vazões observadas nas bacias do Sirinhaém e do Una foram bem representadas através da simulação hidrológica com as precipitações observadas em pluviômetros e resultam numa condição muito boa segundo os indicadores de performance adotados. Também pode-se verificar que nestas bacias as vazões geradas a partir das séries originais de precipitação estimada por satélite resultam em escoamentos menores que as vazões observadas para todas as séries. A vazão média da série PDIR foi o resultado mais próximo das vazões médias observadas no Sirinhaém e registrou 56% do valor de referência, enquanto na bacia do Una as vazões médias mais próximas foram encontradas para a série IMERG, com 41% da vazão média observada.

Figura 99 – Vazões diárias médias de longo termo geradas com precipitações estimadas por sensoriamento remoto sem correção de BIAS, e com ajuste por $\text{BIAS}_{\text{PIXEL}}$ e $\text{BIAS}_{\text{AREA}}$, na bacia do rio Sirinhaém.




Fonte: O Autor (2024).

Na bacia do Sirinhaém a aplicação do método $\text{BIAS}_{\text{PIXEL}}$ trouxe ganhos de qualidade para a série PERSIANN CDR, porém ainda com 42% de diferença relativa à vazão média observada. O método de correção $\text{BIAS}_{\text{AREA}}$ se mostrou mais efetivo para as bacias úmidas, quando desconsiderados os *outliers*, trazendo ganhos de

qualidade as vazões mínimas, médias e máximas de todas as séries, exceto a série IMERG-F que teve degradação dos resultados após aplicação do método de correção. Os resultados mais próximos das vazões médias de referência foram obtidos para as séries do conjunto PERSIANN PDIR, CDR e CCS-CDR com o método de correção $\text{BIAS}_{\text{AREA}}$ onde as vazões simuladas resultaram em 4%, 13% e 16% abaixo das médias, respectivamente.

Para a bacia do Una, após correção de viés, as vazões simuladas mais próximas das médias observadas foram para obtidas na série PDIR com aplicação do método $\text{BIAS}_{\text{AREA}}$, com diferença de 3% da vazão observada e com a aplicação do método $\text{BIAS}_{\text{PIXEL}}$ a série PERSIANN CDR obteve melhor desempenho com diferente de 18% do valor de referência.

Figura 100 – Vazões diárias médias de longo termo geradas com precipitações estimadas por sensoriamento remoto sem correção de BIAS, e com ajuste por $\text{BIAS}_{\text{PIXEL}}$ e $\text{BIAS}_{\text{AREA}}$, na bacia do rio Una.



Fonte: O Autor (2024).


Na Figura 101 verifica-se que as vazões observadas na bacia do rio Pajeú foram bem representadas através da simulação hidrológica com a precipitação observada em pluviômetro e resultam numa condição boa segundo os indicadores de performance adotados. Também pode-se verificar que as vazões geradas a partir das séries originais de precipitação estimada por satélite resultam em vazões maiores que as observadas em todas as séries, exceto na série CHIRPS.

A correção de viés a partir do método de $\text{BIAS}_{\text{PIXEL}}$ trouxe ganhos de qualidade às vazões geradas na bacia do Pajeú para os dados IMERG-F e CDR cujos resultados

indicaram diferenças relativas com a vazão média observada, respetivamente, de 3% e 4%.

O método de correção $\text{BIAS}_{\text{AREA}}$ também se mostrou efetivo para as bacias de clima semiárido trazendo ganhos de qualidade para simulação das vazões mínimas, médias e máximas de todas as séries, quando desconsiderados os outliers. Os resultados mais próximos das vazões médias de referência foram obtidos para as séries CCS-CDR e PDIR, com as vazões simuladas 2% e 5% abaixo das médias, respectivamente.

Figura 101 – Vazões diárias médias de longo termo geradas com precipitações estimadas por sensoriamento remoto sem correção de BIAS, e com ajuste por $\text{BIAS}_{\text{PIXEL}}$ e $\text{BIAS}_{\text{AREA}}$, na bacia do rio Pajeú.



Fonte: O Autor (2024).

A assimilação dos dados de precipitação estimado por satélite em simulações hidrológicas ainda é um desafio técnico. Estudos regionais indicaram baixo desempenho na assimilação das precipitações estimadas em modelos hidrológicos sem correção de BIAS e mesmo após a aplicação de métodos de correção (Yang *et al.*, 2022; Zang *et al.*, 2022). Outros trabalhos identificaram resultados satisfatórios adotando modelos de calibração automática (Kunnath-Poovakka e Eldho, 2023; Alfieri *et al.*, 2022).

O presente estudo permite observar que embora um ajuste satisfatório na correção de BIAS para precipitações anuais e mensais tenha sido obtido, tais resultados não são suficientes para reproduzir o comportamento fluviométrico da bacia hidrográfica. Analisando as Figura 74, Figura 75 e Figura 76, verifica-se que os desvios relativos de precipitações médias anuais e mensais foram abaixo de 6% para a bacia do Sirinhaém em todos os meses do ano das séries CHIRPS e CDR corrigidas

através do método $\text{BIAS}_{\text{ÁREA}}$. Ainda assim os resultados obtidos foram aceitáveis em relação ao indicador P_{BIAS} , associado ao volume escoado, mas foram insatisfatórios ao verificar o NSE que é mais sensível quanto à precisão das séries diárias e vazões máximas. Além da abordagem sobre a acurácia dos dados de precipitação estimada por satélite e métodos de correção de BIAS, tais resultados ilustram a sensibilidade do comportamento hidrológico das bacias hidrográficas frente às pequenas perturbações provocadas por mudanças climáticas, uma vez que a mesma precipitação média anual pode gerar grandes variações de vazões médias dependendo da distribuição temporal dos eventos (Pino-Vargas *et al.*, 2022).

O método Delta para correção de BIAS pode trazer resultados distintos para uma mesma área em função da abordagem aplicada ou das características climáticas. A abordagem do método $\text{BIAS}_{\text{PIXEL}}$ resultou em desvios relativos de precipitações mensais superiores a 25% e indicadores de performance para avaliação das simulações hidrológicas insatisfatórios em todas as séries avaliada, exceto o P_{BIAS} da série CDR.

A abordagem do método $\text{BIAS}_{\text{ÁREA}}$ apresentou desvios relativos de precipitações mensais inferiores a 25% e indicadores de performance para avaliação das simulações hidrológicas satisfatórias para as séries CHIRPS, IMERG-F e PERSIANN CDR, para a bacia do Pajeú que possui predominância de clima semiárido.

Tais resultados permitem afirmar que, na área estudada, as precipitações estimadas por sensoriamento remoto possuem qualidade superior na região de clima semiárido e não possuem boa acurácia nas regiões de clima úmido. Verifica-se ainda que o método de correção de viés $\text{BIAS}_{\text{ÁREA}}$ obteve desempenho superior em relação ao método $\text{BIAS}_{\text{PIXEL}}$, uma vez que somente após a correção de viés $\text{BIAS}_{\text{ÁREA}}$ foram encontrados resultados satisfatórios para os indicadores NSE, P_{BIAS} e RSR.

Lober *et al.* (2023) correlacionam aumento da acurácia das precipitações estimadas por sensoriamento remoto às maiores altitudes, o que se alinha aos resultados encontrados neste trabalho onde a acurácia da região litorânea também foi inferior, sendo esta a região de maiores precipitações e grande importância hidrológica.

4.8 CORREÇÃO DE VIÉS EM VAZÕES CALCULADAS A PARTIR DE PRECIPITAÇÕES ESTIMADAS POR SENSORIAMENTO REMOTO

A partir dos resultados obtidos na modelagem hidrológica com precipitações estimadas por sensoriamento remoto foi possível verificar que embora tenha-se obtido resultados satisfatórios para a bacia hidrográfica do rio Pajeú, na região semiárida, estes resultados foram inferiores a performance das simulações com dados de chuva observados em pluviômetros. Tal situação motivou a avaliação de nova correção de viés sobre os dados das vazões geradas com base no processamento de dados por conjunto do tipo *ensemble*.

O método de correção adotado possibilita combinar 15 séries de vazões. O conjunto de vazões de entrada é formado por cinco séries de vazões geradas com as precipitações estimadas por sensoriamento remoto CHIRPS, IMERG, CDR, CCSCDR e PDIR, em sua forma nativa e sem correções, cinco séries de vazões geradas após aplicar o método de correção $BIAS_{PIXEL}$ sobre as precipitações e outras cinco séries de vazões geradas com as precipitações corrigidas pelo método $BIAS_{AREA}$.

Além da ponderação das 15 séries de vazão foi realizada a calibração de 12 coeficientes de correção mensal e 10 coeficientes de ajuste em função de magnitude das vazões geradas. Ou seja, 27 coeficientes foram calibrados para compor a combinação de correções de vazões e gerar uma série de vazão corrigida.

O processamento de dados por conjunto definiu as vazões que quando combinadas representam com maior precisão as vazões geradas nas bacias hidrográficas do Pajeú, Una e Sirinhaém. Os resultados obtidos mostraram que a série de precipitação CHIRPS corrigida pelos métodos $BIAS_{PIXEL}$ e $BIAS_{AREA}$ foi a mais representativa para a bacia do rio Pajeú, conforme os coeficientes de ponderação de cada série apresentados na Tabela 19.

Ainda na Tabela 19 observa-se que as bacias do rio Una e Sirinhaém possuem comportamento semelhante ao verificar que as séries CHIRPS, IMERG e CCS-CDR são as séries que melhor as vazões observadas quando realizado o processamento por conjunto *ensemble*. Para a bacia do Una não houve priorização de combinações com as séries de vazões cujas chuvas foram corrigidas pelos métodos $BIAS_{PIXEL}$ e $BIAS_{AREA}$.

Tabela 19 – Coeficientes de ponderação aplicados às séries vazões geradas com precipitações estimadas por sensoriamento remoto no processamento por conjunto.

Série	Método de Correção	Bacia hidrográfica / Posto				
		Sirinhaém / Eng. Mato Grosso	Una / Barreiros	Pajeú / Afogados	Pajeú / Serra Talhada	Pajeú / Floresta
CHIRPS	Sem correção	21,1	9,6	0,0	0,3	0,0
	BIAS _{PIXEL}	0,0	0,0	3,2	4,5	12,4
	BIAS _{AREA}	0,0	0,5	0,0	0,0	24,5
IMERG	Sem correção	0,3	19,4	2,2	0,5	0,0
	BIAS _{PIXEL}	0,2	0,4	1,9	1,0	0,0
	BIAS _{AREA}	16,7	0,1	0,0	0,0	3,0
CDR	Sem correção	0,0	0,0	0,0	0,0	0,0
	BIAS _{PIXEL}	0,0	0,0	0,0	0,2	1,9
	BIAS _{AREA}	0,0	0,2	4,6	6,7	0,0
CCS-CDR	Sem correção	40,0	8,8	0,0	0,0	0,1
	BIAS _{PIXEL}	0,0	0,1	0,0	0,0	0,0
	BIAS _{AREA}	0,0	0,0	0,0	0,0	0,0
PDIR	Sem correção	0,3	0,0	0,0	0,0	0,0
	BIAS _{PIXEL}	0,1	0,1	0,0	0,0	0,0
	BIAS _{AREA}	0,4	0,0	0,0	0,0	0,0

Fonte: O Autor (2024).

A Tabela 20 indica os coeficientes de ajuste mensal obtidos após a calibração da combinação de vazões calculadas com precipitações estimadas por sensoriamento remoto nas bacias do Sirinhaém, Una e Pajeú. Observa-se que a necessidade de ajustes mensais aumenta no sentido da bacia do Pajeú para a bacia do Sirinhaém, no litoral.

Tabela 20 – Coeficientes de ajuste mensal aplicados à correção de viés em vazões geradas com precipitações estimadas por sensoriamento remoto.

Mês	Bacia hidrográfica / Posto				
	Sirinhaém / Eng. Mato Grosso	Una / Barreiros	Pajeú / Afogados	Pajeú / Serra Talhada	Pajeú / Floresta
Janeiro	0,8	0,9	1,5	1,1	1,2
Fevereiro	0,8	0,8	1,0	1,0	1,3
Março	0,7	0,7	0,9	0,5	0,8
Abril	0,6	0,6	1,3	1,1	0,8
Maio	1,3	1,0	0,9	0,7	1,0
Junho	3,2	1,1	1,0	1,1	1,0
Julho	6,3	1,4	1,0	0,8	0,9
Agosto	6,4	2,1	1,0	1,0	0,9
Setembro	3,0	1,4	1,0	1,0	0,9
Outubro	1,7	1,3	1,0	1,0	0,9
Novembro	1,2	1,2	1,0	1,0	0,9
Dezembro	0,9	1,1	1,0	1,0	1,0
Média	2,2	1,1	1,0	0,9	1,0

Fonte: O Autor (2024).

No Pajeú os coeficientes de ajuste mensal variam entre 0,8 e 1,3, no Una de 0,6 a 2,1 e no Sirinhaém entre 0,6 e 6,4, sendo respectivamente, os coeficientes médios para cada bacia iguais a 1,0, 1,1 e 2,2.

Na Tabela 21 observa-se os coeficientes de correção associados às magnitudes das vazões. Estes coeficientes foram obtidos após a calibração do processamento de dados por conjunto das vazões calculadas nas bacias do Sirinhaém, Una e Pajeú. Observa-se que nas faixas de vazões de 0 até 50 m³/s ocorre necessidade de majoração das vazões calculadas, enquanto para vazões de magnitude superior a 50 m³/s ocorre tendência de necessidade de minoração das vazões.

Outra constatação sobre os coeficientes é que o fator de correção possui média de 1,12 na bacia do Pajeú, 0,87 na bacia do Una e 0,71 na bacia do Sirinhaém. Logo, entende-se que as vazões de entrada da bacia do Pajeú corrigidas com coeficientes de média mais próxima de 1 estão mais próximas das vazões observadas.

Tabela 21 – Coeficientes de ajuste de magnitude aplicados à correção de viés em vazões geradas com precipitações estimadas por sensoriamento remoto.

Faixa de vazão	Bacia hidrográfica / Posto				
	Sirinhaém / Eng. Mato Grosso	Una / Barreiros	Pajeú / Afogados	Pajeú / Serra Talhada	Pajeú / Floresta
0 - 10	2,63	2,14	1,48	1,71	2,75
10 - 25	1,61	1,79	1,00	1,57	1,15
25 - 50	1,02	1,25	0,78	1,57	0,99
50 - 100	0,68	0,81	1,05	1,49	0,96
100 - 250	0,38	0,58	1,51	2,50	0,54
250 - 500	0,23	0,37	-	1,39	0,59
500 - 1.000	0,12	0,28	-	-	0,89
1.000 - 2.500	0,06	0,08	-	-	1,11
2.500 - 10.000	0,03	0,12	-	-	-
10.000 - 100.000	0,02	-	-	-	-
Média	0,71	0,87	1,16	1,70	1,12


Fonte: O Autor (2024).

Ao avaliar os percentuais das séries de vazões adotados ao final do processamento de dados por conjunto verifica-se que, após a ponderação da bacia do Pajeú, 88% da vazão combinada está sendo representada pela série CHIRPS corrigida pelos métodos BIAS_{PIXEL} e BIAS_{AREA}, o que reforça a efetividade dos métodos de correção. A melhor combinação de vazões para a bacia do Una ocorre com 50% das vazões representadas pela série IMERG, enquanto na bacia do

Sirinhaém 51% das vazões foram representadas pela série CCSCDR, conforme ilustrado na Figura 102.

Ainda na Figura 102 verifica-se que as bacias do Una e Sirinhaém possuem uma composição de combinação de vazões com maior similaridade ao comparar com a bacia do rio Pajeú.

Figura 102 – Percentuais de vazões adotados no processamento de dados por conjunto ensemble nas bacias hidrográficas do Sirinhaém, Una e Pajeú.



Fonte: O Autor (2024).

Ao avaliar os indicadores de performance sobre as séries de vazões calculadas a partir de processamento de dados por conjunto (ensemble) verifica-se que as ocorre melhoria significativa nos resultados das bacias do Una e Sirinhaém, havendo resultados satisfatórios para o indicador P_{BIAS} abaixo de 5%, porém os indicadores NSE e RSR foram insatisfatórios com valores de NSE de 0,41 e 0,44 e RSR de 0,80 e 0,75, respectivamente. Embora tais resultados encontrem-se próximos ao aceitável de NSE maior que 0,5 e RSR menor que 0,7, conforme indicado na Tabela 22.

Adicionalmente observa-se novamente que ocorre maior similaridade entre os resultados das bacias hidrográficas do Una e Sirinhaém, independente da área de drenagem da estação fluviométrica, ao analisar comparativamente os resultados da bacia hidrográfica do Pajeú.

Tabela 22 – Indicadores de desempenho sobre séries de vazões calculadas a partir de processamento por conjunto ensemble.

Bacia	Estação	Área (km ²)	NSE	P _{BIAS} (%)	RSR
Sirinhaém	Engenho Mato Grosso	1.310	0,41	4,6	0,80
Una	Barreiros	6.550	0,44	4,5	0,75
Pajeú	Afogados da Ingazeira	3.540	0,72	7,3	0,53
Pajeú	Serra Talhada	5.910	0,79	1,0	0,45
Pajeú	Floresta	12.300	0,83	2,2	0,41

Fonte: O Autor (2024).

Os resultados da Tabela 22 indicam que a área de drenagem da bacia hidrográfica não possui influência preponderante sobre a qualidade das simulações, uma vez que a acurácia dos resultados da estação Engenho Mato Grosso e Barreiros foram similares e possuem área de drenagem entre 1.300 a 6.600 km², enquanto as estações Afogados da Ingazeira e Serra Talhada possuem resultados similares entre si, com maior acurácia e com áreas de drenagem entre 3.500 a 6.000 km², amplitude de áreas similares às estações Eng. Mato Grosso e Barreiros.


O processamento de dados por conjunto para ajuste de vazões na bacia hidrográfica do Pajeú, por sua vez, obteve desempenho satisfatório para os três indicadores avaliados em três estações fluviométricas: Afogados da Ingazeira, Serra Talhada e Floresta.

Na Figura 103 observa-se os percentuais de cada série de vazão após o processamento de dados por conjunto nas bacias hidrográficas do Sirinhaém, Una e Pajeú onde observa-se que todos os postos da bacia tiveram os melhores resultados a partir de combinações das séries CHIRPS, IMERG e CDR. As séries de vazão geradas com correção de viés de precipitação são as que possuem maior peso no resultado final. As vazões geradas com precipitações corrigidas pelo método BIAS_{ÁREA} representam a maior parcela na ponderação com 52% de total, as vazões geradas com precipitações corrigidas pelo método BIAS_{PIXEL} representam 41% e vazões geradas com as precipitações sem correção representam 7% do total.

Sendo assim, considera-se a correção de viés de vazões através do processamento de dados por conjunto eficaz para melhoria da qualidade dos dados de vazão gerada com precipitações estimadas por sensoriamento remoto. As séries corrigidas na bacia do rio Pajeú indicaram performance muito boa, com NSE de 0,83, P_{BIAS} de 2,2% e RSR de 0,41 resultando um desempenho com performance superior

às simulações com precipitação observada em pluviômetros (NSE 0,70, P_{BIAS} 2,7% e RSR 0,60).

Figura 103 – Percentuais de vazões adotados no processamento de dados por conjunto ensemble na bacia hidrográfica do Pajeú.




Fonte: O Autor (2024).

A visualização gráfica das vazões médias diárias de longo termo calculadas com as precipitações estimadas por sensoriamento remoto, as vazões observadas e a vazão corrigida por ensemble para a estação fluviométrica de maior área de drenagem das bacias hidrográficas do Sirinhaém, Una e Pajeú, conforme Figura 104, Figura 105 e Figura 106.

O principal desafio para representação das vazões na bacia do Sirinhaém com as séries CHIRPS, IMERG e PERSSIAN está associado ao método de correção de viés considerando médias mensais, onde eventualmente majora-se as precipitações nativas em até 90% no período chuvoso, nesses casos quando ocorre acerto da intensidade da precipitação os modelos geram picos de vazões extremas.


A bacia do rio Una possui características mais complexas que as do Sirinhaém e Pajeú, pois possui regiões com características climáticas distintas, reservatórios de contenção de cheias e solos arenosos, o que demanda simulações com intervalo computacional menor que um dia para boa representação das vazões diárias.

Figura 104 – Amplitude de vazões diárias médias de longo termo calculadas com precipitações estimadas por sensoriamento remoto, vazão média observada e vazão corrigida por ensemble na bacia hidrográfica do rio Sirinhaém, estação fluviométrica Engenho Mato Grosso.



Fonte: O Autor (2024).


Figura 105 – Amplitude de vazões diárias médias de longo termo calculadas com precipitações estimadas por sensoriamento remoto, vazão média observada e vazão corrigida por ensemble na bacia hidrográfica do rio Una, estação fluviométrica Barreiros.



Fonte: O Autor (2024).

Para a bacia do rio Pajeú foram obtidos os melhores resultados na geração de vazões com precipitações estimadas por sensoriamento remoto. Sugere-se que tais resultados estejam associados à melhor acurácia das séries de precipitações estimadas e a aderência aos métodos de correção de viés aplicados aos dados de chuva e vazão.

Figura 106 – Amplitude de vazões diárias médias de longo termo calculadas com precipitações estimadas por sensoriamento remoto, vazão média observada e vazão corrigida por ensemble na bacia hidrográfica do rio Pajeú, estação fluviométrica Floresta.



Fonte: O Autor (2024).

Os resultados obtidos a partir da correção de viés nas séries de vazão geradas com precipitações estimadas por sensoriamento remoto indicam que a avaliação da acurácia dos dados através de indicadores de performance demanda análise técnica sofisticada para determinar metodologias e aplicações.

A combinação de resultados através de processamento em um grande conjunto de resultados somente torna-se viável a partir da aplicação de técnicas de otimização ou inteligência artificial e é para esta direção que as pesquisas mais recentes exploram novos recursos e sofisticação científica, como Chen (2024) e Wegayehu e Muluneh (2024). O processamento de dados por conjunto associado a robustez e diversidade de ferramentas com aplicação de técnicas de aprendizado de máquina deverão contemplar as próximas grandes inovações relacionadas à temática de estimativa de precipitações com base em produtos de sensoriamento remoto.

5 CONCLUSÕES

O presente estudo realizou avaliação da acurácia de precipitação estimadas por sensoriamento remoto para as séries CHIRPS, IMERG-F, PERSIANN CDR, PERSIANN CCS-CDR e PERSIANN PDIR, adotou dois métodos de correção de viés para cada série, avaliou a assimilação de dados geoespaciais visando a redução da calibração de parâmetros, o desempenho dessas precipitações em simulações hidrológicas e alternativas de correção de viés em vazões. A partir dos resultados obtidos pode-se concluir que:

- As séries de precipitação estimada por sensoriamento remoto avaliadas em sua forma nativa, ou seja, sem correções, não representam satisfatoriamente o comportamento das normais climatológicas para a área de estudo, sendo observado viés (BIAS) em função da localização geográfica, características climáticas e distribuição temporal das precipitações;
- O método de correção de viés $BIAS_{AREA}$ se mostrou superior em relação ao método de correção $BIAS_{PIXEL}$. Após a correção de viés, desvios relativos de 69% nas precipitações médias anuais e 25% nas séries mensais foram reduzidos para valores menores que 1% e 5%, respectivamente, com melhor desempenho sobre as séries CHIRPS e PERSIANN CDR;
- A assimilação de dados geoespaciais para inicialização rápida do modelo hidrológico HEC-HMS se mostrou efetiva a partir da combinação do modelo digital do terreno do Pernambuco Tridimensional (PE3D), mapas de classificação dos solos da EMBRAPA e mapas de uso e ocupação do solo do projeto MapBiomass. A metodologia aplicada permitiu restringir a necessidade de parâmetros calibráveis apenas à vazão de base e obter simulações de vazões com performance satisfatória ou boa em 75% das estações avaliadas;
- A partir da análise dos indicadores de performance das vazões geradas no HEC-HMS verificam-se resultados com qualidade superior em solos mais argilosos e com menor taxa de infiltração, do que em solos mais arenosos;
- O comparativo entre modelo hidrológico concentrado CAWM V e semidistribuído HEC-HMS mostrou resultados satisfatórios nos dois modelos, sendo o modelo semidistribuído levemente superior para as bacias do Sirinhaém e Una ao avaliar os indicadores NSE, P_{BIAS} e RSR;

- Considerar a influência da operação de reservatórios no modelo HEC-HMS foi essencial para obtenção de resultados satisfatórios na bacia do rio Pajeú;
- As simulações hidrológicas para quantificar vazões a partir das séries de precipitação estimada por sensoriamento remoto sem correção de viés não apresentaram desempenho satisfatório na área de estudo, ao avaliar bacias de clima úmido ou semiárido;
- Os métodos de correção ($BIAS_{PIXEL}$ e $BIAS_{AREA}$) aplicados às precipitações estimadas por sensoriamento remoto foi satisfatório para gerar vazões na bacia semiárida do rio Pajeú. Apesar de ocorrer melhorias de acurácia, tais métodos não foram satisfatórios para a bacia litorânea de clima úmido do Sirinhaém e para a bacia do Una, susceptível aos sistemas meteorológicos característicos das áreas litorâneas e do semiárido;
- Com as vazões relacionadas ao método $BIAS_{AREA}$ se obteve desempenho superior em relação ao método $BIAS_{PIXEL}$ quanto às simulações hidrológicas no HEC-HMS. Entre as simulações realizadas para a bacia do rio Pajeú, com a série CHIRPS se obteve o melhor NSE de 0,64 e o melhor RSR de 0,57, enquanto que com a série IMERG-F foi alcançado o melhor P_{BIAS} de 4%;
- O processamento de dados por conjunto mostrou-se eficaz para melhoria da qualidade dos dados de vazão gerada com precipitações estimadas por sensoriamento remoto e correção de viés. As séries corrigidas na bacia do rio Pajeú indicaram performance muito boa, com NSE de 0,83, P_{BIAS} de 2,2% e RSR de 0,41 resultando um desempenho superior às simulações com precipitação observada em pluviômetros;
- O uso das precipitações estimadas por sensoriamento remoto leva a um conjunto de vantagens e aplicações técnicas. Considera-se que as aplicações associadas à modelagem hidrológica e geração de vazões são viáveis, porém ainda são limitadas e demandam análise sofisticada para determinar tal viabilidade.

6 RECOMENDAÇÕES E TRABALHOS FUTUROS

O desenvolvimento deste estudo favorece um conjunto de reflexões sobre as estratégias da pesquisa, etapas metodológicas, análise e interpretação de resultados até às conclusões apresentadas para de forma singela se obter mais discernimento sobre os temas abordados. Com base nessa trajetória, e compreendendo a amplitude científica a ser percorrida em trabalhos futuros, recomenda-se:

- Desenvolver as análises feitas aqui para outras escalas de bacias hidrográficas: principalmente para grandes regiões e com menor variabilidade espacial das precipitações e vazões, onde os resultados podem ser mais ajustados;
- Realizar estudos, trabalhos e, inclusive, investimentos para obtenção de séries de precipitação estimada por sensoriamento remoto específicas ao território brasileiro, visando ampliar a incorporação de dados climatológicos locais e a customização de produtos voltados às características climáticas e necessidades regionais;
- Utilizar outras séries de precipitação estimada por sensoriamento remoto e aplicar outros métodos de correção de viés, de modo que as inúmeras combinações de dados de entrada possam subsidiar processamentos por conjunto para se obter resultados mais promissores, o que demanda a continuidade da linha de pesquisa;
- Realizar estudos através de assimilação de dados geoespaciais para auxiliar a determinação dos parâmetros calibráveis da vazão de base no modelo hidrológico HEC-HMS;
- Desenvolver novas pesquisas para avaliação de ferramentas computacionais e melhorias metodológicas ao HEC-HMS para simulações hidrológicas mais eficientes em áreas com predominância de solos arenosos e regiões de clima semiárido;
- Avaliar metodologias para aprimorar a modelagem hidrológica considerando o efeito de milhares de pequenos reservatórios existentes no semiárido brasileiro, bem como avaliar a operação de reservatórios de forma sistêmica e considerando a complexidade operacional dos usos múltiplos;
- Estudar o processamento de dados por conjunto com a aplicação de métodos de inteligência artificial e aprendizado de máquina.

REFERÊNCIAS

- ACKER, J.; SOEBIYANTO, R.; KIANG, R.; KEMPLER, S. Use of the NASA Giovanni Data System for Geospatial Public Health Research: Example of Weather-Influenza Connection. **International Journal of Geo-Information**, v.3, n. 4, p. 1372–1386, 2014. doi:10.3390/ijgi3041372
- ALFIERI, L.; AVANZI, F.; DELOGU, F.; GABELLANI, S.; BRUNO, G.; CAMPO, L.; LIBERTINO, A.; MASSARI, C.; TARPANELLI, A.; RAINS, D.; et al. High-Resolution Satellite Products Improve Hydrological Modeling in Northern Italy. **Hydrology and Earth System Sciences**, 2022, 26, 3921–3939. <https://doi.org/10.5194/hess-26-3921-2022>.
- ALENCAR, A.; SHIMBO, J.Z.; LENTI, F.; BALZANI M.C.; ZIMBRES, B.; ROSA, M.; ARRUDA, V.; CASTRO, I.; RIBEIRO, F.M.J.P.; VARELA, V.; ALENCAR, I.; PIONTEKOWSKI, V. et al. Mapping Three Decades of Changes in the Brazilian Savanna Native Vegetation Using Landsat Data Processed in the Google Earth Engine Platform. **Remote Sensing**, v.12, 924, 2020. <https://doi.org/10.3390/rs12060924>
- ALQURAISH, M.M., KHADR, M., 2021. Remote-Sensing-Based Streamflow Forecasting Using Artificial Neural Network and Support Vector Machine Models. **Remote Sensing**. <https://doi.org/10.3390/rs13204147>
- ANA - Agência Nacional de Águas e Saneamento Básico, Ministério do Desenvolvimento Regional, **Hidroweb**, 2005. Disponível em: <https://www.snirh.gov.br/hidroweb/apresentacao> [Acesso em: 18/08/2021].
- ANA - Agência Nacional de Águas e Saneamento Básico, Ministério do Desenvolvimento Regional, **Produção de base vetorial com o Curve Number (CN) para BHO 2014 (BHO_CN)**, 2018. Disponível em: https://metadados.snirh.gov.br/geonetwork/srv/api/records/d1c36d85-a9d5-4f6a-85f7-71c2dc801a67/attachments/NOTA_TECNICA_46_2018_SPR.pdf [Acesso em: 18/08/2021].
- ANA. Agência Nacional de Águas e Saneamento Básico. **Dados Abertos**. 2020. Disponível em: <<https://dadosabertos.ana.gov.br/>> Acesso em: 30 de set. de 2020.
- ANDERSON, M.; KAVVAS, M. L. A global hydrology model. Mathematical models of watershed hydrology In: Singh, V. P.; Frevert, D. K. (eds.), Water Resources Publications, Littleton, Colo, 2002.
- ANDRADE, N.S.O. Radar de Abertura Sintética Polarimétrico do R-99b – Análise e Aplicações. Tese de Doutorado (Instituto de Geociências), Universidade de Brasília – UNB, 235p., 2012. Disponível em: https://repositorio.unb.br/bitstream/10482/10752/1/2012_NiloSergiodeOliveiraAndrade.pdf
- ANDRADE, N.S.O.; ROSA, A.N.C.S.; FARIA, P.C.C. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, Brasil, Instituto de Pesquisas Especiais, p. 4775-4782, 2007. Disponível em: <http://martes.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2006/10.24.00.28/doc/4775-4782.pdf>
- ANGELIS, C.F. **Radar Meteorológico: Teoria, Conceitos e Aplicações**, Instituto de Pesquisas Especiais. Disponível: http://chuvaproject.cptec.inpe.br/portal/saoluis/curso/angelis/UFRJ_radar.pdf
- ANTP. Ant webpage. **Ant Renamer 2.12.0**. 2020. Disponível em: <<https://antp.be/software/renamer/download>> Acesso em: 30 de set. de 2020.
- APAC. Agência Pernambucana de Águas e Clima. **Histórico de chuvas**. 2020. Disponível em: <<https://www.apac.pe.gov.br/#tabs>>. Acesso em: 30 de set de 2020.
- ARAYA, M.F. Use of satellite images to obtain accurate snowmelting runoff forecasts and to survey geothermal activity along Los Andes Range, Chile, **Advances in Space Research**, v. 4, n. 11, p. 235-240, 1984. [https://doi.org/10.1016/0273-1177\(84\)90417-4](https://doi.org/10.1016/0273-1177(84)90417-4).
- ARNOLD, J. G.; SRINIVASAN, R.; MUTTIAH, R. S.; WILLIAMS, J. R. Large area hydrologic modeling and assessment. Part I: Model development. **Journal of the American Water Resources Association**, v. 34, n. 1, p. 73–89, 1998. <https://doi.org/10.1111/j.1752-1688.1998.tb05961.x>

- ARRUDA, V.L.S.; PIONTEKOWSKI, V. J.; ALENCAR, A.; PEREIRA, R.S.; MATRICARDI, E.A.T. An alternative approach for mapping burn scars using Landsat imagery, Google Earth Engine, and Deep Learning in the Brazilian Savanna, **Remote Sensing Applications: Society and Environment**, v. 22, 100472, 2021. <https://doi.org/10.1016/j.rsase.2021.100472>.
- ASHOURI, H.; HSU, K.L.; SOROOSHIAN, S.; BRAITHWAITE, D.K.; KNAPP, K.R.; CECIL, L.D.; NELSON, B.R.; PRAT, O.P. PERSIANN-CDR: Daily Precipitation Climate Data Record from Multisatellite Observations for Hydrological and Climate Studies. **Bulletin of the American Meteorological Society**, v. 96, 6983. 2015. <http://dx.doi.org/10.1175/BAMS-D-13-00068.1>
- ATLAS, D. Advances in Radar Meteorology. **Advances in Geophysics**, v. 10, p.317-478. 1964. Doi:10.1016/s0065-2687(08)60009-6
- AYEHU, G.T.; TADESSE, T.; GESSESSE, B.; DINKU, T. Validation of new satellite rainfall products over the Upper Blue Nile Basin Ethiopia. **Atmospheric Measurement Techniques**, v. 11, n. 4, p. 1921-1936, 2018. Doi: 10.5194/amt-11-1921-2018
- BAI, L.; SHI, C.; LI, L.; YANG, Y.; WU, J. Accuracy of CHIRPS satellite-rainfall products over mainland China. **Remote Sensing**, v. 10, n. 3, p. 362. 2018. Doi: 10.3390/rs10030362
- BALL, J.; BABISTER, M.; NATHAN, R.; WEEKS, W.; WEINMANN, E.; RETALLICK, M.; TESTONI, I. (Eds). **Australian Rainfall and Runoff: A Guide to Flood Estimation**, Commonwealth of Australia (Geoscience Australia), 2019.
- BARBERA, P., LANZA L.G., STAGI, L. Tipping Bucket Mechanical Errors and their Influence on Rainfall Statistics and Extremes, **Water Science and Technology**, v. 45, n. 2, p. 1-10, 2002.
- BARRETT C.G. Satellite remote sensing of rainfall. In: **Applications of remote sensing in agriculture**. E Toselli (Ed.) Kluwer, Dordrecht. 1989.
- BAYAT, B., HOSSEINI, K., NASSERI, M., KARAMI, H., 2019. Challenge of rainfall network design considering spatial versus spatiotemporal variations. **Journal of Hydrology**. <https://doi.org/10.1016/j.jhydrol.2019.04.091>
- BECK, H.E.; PAN, M.; ROY, T.; WEEDON, G.P.; PAPPENBERGER, F.; VAN DIJK, A.I.J.M., HUFFMAN, G. J., ADLER, R. F., AND WOOD, E. F.: Daily evaluation of 26 precipitation datasets using Stage-IV gauge-radar data for the CONUS, **Hydrology and Earth System Sciences**, v. 23, 207–224. 2019. <https://doi.org/10.5194/hess-23-207-2019>.
- BECKER, A.; FINGER, P.; MEYER-CHRISTOFFER, A.; RUDOLF, B.; SCHAMM, K.; SCHNEIDER, U.; ZIESE, M. A description of the global land-surface precipitation data products of the Global Precipitation Climatology Centre with sample applications including centennial (trend) analysis from 1901–present, **Earth System Science Data**, v. 5, 71-99, 2013 .<https://doi.org/10.5194/essd-5-71-2013>.
- BENNETT, T. **Development and application of a continuous soil moisture accounting algorithm for the Hydrologic Engineering Center Hydrologic Modeling System (HEC-HMS)**. Dissertação (Mestrado), Dept. of Civil and Environmental Engineering, University of California, Davis, 1998.
- BERGÉ-NGUYEN, M.; CRETAUX, J.F.; CALMANT, S.; FLEURY, S.R.; CHONTOEV, D.; BONNEFOND, P. Mapping mean lake surface from satellite altimetry and GPS kinematic surveys, **Advances in Space Research**, v. 67, 985-1001, 2021, <https://doi.org/10.1016/j.asr.2020.11.001>.
- BERNE, A.; KRAJEWSKI, W. F. Radar for hydrology: unfulfilled promise or unrecognized potential? **Advances in Water Resources**, v. 51, p. 357–366, 2013.
- BEVEN, K. J.; KIRKBY, M. J. A physically-based variable contributing area model of basin hydrology. **Hydrological Sciences Bulletin**, v. 24, n.1, 43–69, 1979.

BHATT, G.; KUMAR, M.; DUFFY, C.J. A tightly coupled GIS and distributed hydrologic modeling framework, **Environmental Modelling & Software**, v. 62, p. 70-84, 2014. <https://doi.org/10.1016/j.envsoft.2014.08.003>.

BIGIARINI, M.; NAUDITT, A.; BIRKEL, C.; VERBIST, K.; RIBBE, L. Temporal and spatial evaluation of satellite-based rainfall estimates across the complex topographical and climatic gradients of Chile. **Hydrology and Earth System Sciences**, v. 21, n.2, 1295–1320, 2017. doi:10.5194/hess-21-1295-2017

BLACK, P. G.; CARDONE, V. J.; GENTRY, R. C.; HAWKINS, J. D. Chapter 6 Seasat Microwave Wind and Rain Observations in Severe Tropical and Midlatitude Marine Storms. **Satellite Oceanic Remote Sensing**, 197–277. 1985. doi:10.1016/s0065-2687(08)60406-9

BOLVIN, D.T.; BRAITHWAITE, D.; HSU, K.; JOYCE, R.; KIDD, C.; NELKIN, E.J.; SOROOSHIAN, S.; TAN, J.; XIE, P. **NASA Global Precipitation Measurement (GPM) Integrated Multi-Satellite Retrievals for GPM (IMERG)**. Algorithm Theoretical Basis Document., Version 4.5, 22 p. 2015. Disponível: http://pmm.nasa.gov/sites/default/files/document_files/IMERG_ATBD_V4.5.pdf

BRIER, G. W. VERIFICATION OF FORECASTS EXPRESSED IN TERMS OF PROBABILITY. Monthly Weather Review. **American Meteorological Society**. Disponível em: <[http://dx.doi.org/10.1175/1520-0493\(1950\)078<0001:VOFEIT>2.0.CO;2](http://dx.doi.org/10.1175/1520-0493(1950)078<0001:VOFEIT>2.0.CO;2)>.

BRITO, C.S.; SILVA, R.M.; SANTOS, C.A.G.; BRASIL NETO, R.M.; COELHO, V.H.R. Monitoring meteorological drought in a semiarid region using two long-term satellite-estimated rainfall datasets: A case study of the Piranhas River basin, northeastern Brazil, **Atmospheric Research**, v. 250, n. 105380, 2021. <https://doi.org/10.1016/j.atmosres.2020.105380>.

CALVET, J.-C., DE ROSNAY, P., PENNY, S.G., 2019. Editorial for the Special Issue “Assimilation of Remote Sensing Data into Earth System Models.” **Remote Sensing**. <https://doi.org/10.3390/rs11182177>

CARVALHO, W.M. **HydroBr: A Python package to work with Brazilian hydrometeorological time series**, 2020. Disponível em: https://zenodo.org/record/3931027#.YTtm_p1KiUk [Acesso em: 18/08/2021].

CASTRO, C.V.; MAIDMENT, D.R. GIS preprocessing for rapid initialization of HEC-HMS hydrological basin models using web-based data services, **Environmental Modelling & Software**, v. 130, 104732, 2020. <https://doi.org/10.1016/j.envsoft.2020.104732>.

CAVALCANTE, R.B.L.; FERREIRA, D.B.S.; PONTES, P.R.M.; TEDESCHI, R.G.; COSTA, C.P.W.; SOUZA, E.B. Evaluation of extreme rainfall indices from CHIRPS precipitation estimates over the Brazilian Amazonia, **Atmospheric Research**, v. 238, 104879, 2020. <https://doi.org/10.1016/j.atmosres.2020.104879>.

CHA, S.M.; LEE, S.W. Advanced hydrological streamflow simulation in a watershed using adjusted radar-rainfall estimates as meteorological input data, **Journal of Environmental Management**, v. 277, 111393, 2021. <https://doi.org/10.1016/j.jenvman.2020.111393>.

CHARLEY, W.J. **The estimation of rainfall for flood forecasting using radar and rain gage data**, Proceeding Paper, US Army Corps of Engineers, Hydrologic Engineering Center, v. 121. 1988.

CHC - CLIMATE HAZARDS CENTER, **About the Climate Hazards Center**, 2021. Disponível em:<https://chc.ucsb.edu/about> [Acesso em: 18/08/2021].

CHEN, F.; FU, Y.; LIU, P.; YANG, Y. Seasonal Variability of Storm Top Altitudes in the Tropics and Subtropics Observed by TRMM PR, **Atmospheric Research**, v. 169, Part A, p. 113-126, 2016. <https://doi.org/10.1016/j.atmosres.2015.09.017>.

CHEN, S.; HONG, Y.; GOURLEY, J.; HUFFMAN, G.; TIAN, Y.; CAO, Q.; YONG, B.; KIRSTETTER, P.; HU, J.; HARDY, J.; LI, Z.; KHAN, S.; XUE, X. Evaluation of the successive V6 and V7 TRMM

multisatellite precipitation analysis over the Continental United States. **Water Resources Research**, v. 49, 8174-8186. 2013. doi:10.1002/2012wr012795

CHEN, W.; HUANG, C.; YANG, Z.-L. More severe drought detected by the assimilation of brightness temperature and terrestrial water storage anomalies in Texas during 2010–2013. **Journal of Hydrology**. 2021. Disponível em: <http://dx.doi.org/10.1016/j.jhydrol.2021.126802>

CHEN, H.; WANG, T.; MONTZKA, C.; GAO, H.; GUO, N.; CHEN, X.; VEREECKEN, H. Toward an improved ensemble of multi-source daily precipitation via joint machine learning classification and regression. **Atmospheric Research**. 2024. <http://dx.doi.org/10.1016/j.atmosres.2024.107385>.

CHINTALAPUDI, S.; SHARIF, H.O.; XIE, H. Sensitivity of distributed hydrologic simulations to ground and satellite-based rainfall products. **Water**, v. 6, 1221–1245, 2014. <https://doi.org/10.3390/w6051221>

CHO, Y. Application of NEXRAD Radar-Based Quantitative Precipitation Estimations for Hydrologic Simulation Using ArcPy and HEC Software. **Water**, v.12, 273. 2020. <https://doi.org/10.3390/w12010273>

CHO, Y.; ENGEL, B.A.; MERWADE, V.M. A spatially distributed Clark's unit hydrograph based hybrid hydrologic model (Distributed-Clark), **Hydrological Sciences Journal**, v. 63, n.10, p. 1519-1539, 2018. DOI: 10.1080/02626667.2018.1516042

CHOW, V.T.; MAIDMENT, D.R.; MAYS, L.W. **Applied Hydrology**. McGraw-Hill Book Company, Singapore, 1988. Disponível em: http://ponce.sdsu.edu/Applied_Hydrology_Chow_1988.pdf

CIRILO, J.A.; VERÇOSA, L.F.M.; GOMES, M.M.A.; FEITOZA, A.M.A.B.; FERRAZ, G.F.; SILVA, B.M. Development and application of a rainfall-runoff model for semi-arid regions. **Revista Brasileira de Recursos Hídricos** (online), v. 25, 2020. Disponível em: <https://doi.org/10.1590/2318-0331.252020190106> [Acesso em: 18/08/2021].

CLARK, C. O. Storage and the unit hydrograph. **Transactions of the American Society of Civil Engineers**, v. 110, p. 1419-1446. 1945.

COLLISCHONN, W.; ALLASIA, D. G.; SILVA, B. C.; TUCCI, C. E. M. The MGB-IPH model for large scale rainfall-runoff modelling. **Hydrological Sciences Journal**, v. 52, p. 878-895, 2007.

COSTA, I.C. **Influências das propriedades microfísicas e radiativas das nuvens nas incertezas das estimativas de precipitação por sensores remotos passivos**, Tese (Doutorado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

CPRM - SERVIÇO GEOLÓGICO DO BRASIL. **Atlas pluviométrico do Brasil: versão 2.0 atualizada**. Programa Geologia do Brasil. Levantamento da Geodiversidade. 2011. Disponível em: <https://rigeo.cprm.gov.br/xmlui/handle/doc/11558?show=full>

CRAWFORD, N. H.; LINSLEY, R. K. **Digital Simulation in Hydrology: Stanford Watershed Model IV**. Stanford, Calif: Dept. of Civil Engineering, Stanford University, 1966.

CSI. Consortium for Spatial Information. **Platform for Big Data in Agriculture**. Disponível em: <https://cgiares.com/community/category/data/> Acesso em: 30 de set. de 2020.

CUNGE, J. A. On the subject of a flood propagation computational method (Muskingum method). **Journal of Hydraulic Research**, v.7, n. 2, p. 205-230, 1969. doi:10.1080/00221686909500264

DARIANE A.B.; JAVADIANZADEH M.M.; JAMES, L.D. Developing an efficient auto-calibration algorithm for HEC-HMS program. **Water Resources Management**, v. 30, n. 6, p. 1923–1937, 2016. Doi: 10.1007/s11269-016-1260-7

DASTOUR, H., HASSAN, Q.K., 2023. A Machine-Learning Framework for Modeling and Predicting Monthly Streamflow Time Series. **Hydrology**. <https://doi.org/10.3390/hydrology10040095>

DAT. Data Assimilation Research Team, 2022. Japão. Disponível em: <https://www.data-assimilation.riken.jp/en/research/index.html> Acesso em 02 de março de 2024.

DAWDY, D. R.; LITCHY, R. W.; BERGMANN, J. M. Rainfall-runoff simulation model for estimation of flood peaks for small drainage basins. **Synthesis In Hydrology**, USGS Open File Rep., Washington, D.C. 1970.

DEVI, G.K.; GANASRI, B.P.; DWARAKISH, G.S. A Review on Hydrological Models. **Aquatic Procedia**, v. 4, 1001–1007. 2015. doi:10.1016/j.aqpro.2015.02.126

DINIZ, C.; CORTINHAS, L.; NERINO, G.; RODRIGUES, J.; SADECK, L.; ADAMI, M.; SOUZA-FILHO, P. Brazilian Mangrove Status: Three Decades of Satellite Data Analysis. **Remote Sensing**, v. 11, n. 7, 808, 2019. doi:10.3390/rs11070808

DORE, M.H.I., 2005. Climate change and changes in global precipitation patterns: What do we know? **Environment International**. <https://doi.org/10.1016/j.envint.2005.03.004>

DUARTE, B.M.; FRANÇA, J.R.A.; JUSTO, L.A.J. Uso dos Dados do Satélite Cloudsat para Caracterização da Estrutura Microfísica de Eventos de Precipitação Extrema Sobre as Regiões Sul e Sudeste do Brasil, **Anuário do Instituto de Geociências - UFRJ**, v. 41, n. 1, 2018. http://dx.doi.org/10.11137/2018_1_15_27

DUBOVİK, O., SCHUSTER, G.L., XU, F., HU, Y., BÖSCH, H., LANDGRAF, J., LI, Z., 2021. Grand Challenges in Satellite Remote Sensing. **Front. Remote Sens.** <https://doi.org/10.3389/frsen.2021.619818>

DWD - DEUTSCHER WETTERDIENST - **GPCC Visualizer**, 2021. Disponível em: <https://kunden.dwd.de/GPCC/Visualizer>

EAST, T. W. R.; BORE, B. V. **An electronic constant-altitude display**. Proc. 6th Weather Radar Conf., Am. Meteorol. SOC., Boston, p. 325-330, 1957.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária (2022). **Avaliação, previsão e mapeamento de água disponível em solos do Brasil**. E-book: Boletim de pesquisa e desenvolvimento / Embrapa Solos, ISSN 1678-0892. 282p. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/243230/1/CNPS-BPD-282-2022.pdf>

EMÍDIO, Z.P.O.; LANDIM, P.M.B. Trend surface analysis applied to rainfall, measured by meteorological radar in the regions of Assis and Piracicaba, SP. **Geociências**, v. 27, n. 4, p. 439-449, 2008. Disponível em: <http://www.ppegeo.igc.usp.br/index.php/GEOSP/article/view/7072>

FANG, G.H., YANG, J., CHEN, Y.N., ZAMMIT, C., 2015. Comparing bias correction methods in downscaling meteorological variables for a hydrologic impact study in an arid area in China. **Hydrol. Earth Syst. Sci.** <https://doi.org/10.5194/hess-19-2547-2015>

FELDMAN, A. D. HEC models for water resources system simulation: Theory and experience. **Advances in Hydroscience**, v. 12, p. 297–423, 1981. Disponível em: <https://www.hec.usace.army.mil/publications/TechnicalPapers/TP-141.pdf>

FENDRICH, A.N.; BARRETTO, A.; FARIA, V.G.; BASTIANI, F.; TENNESON, K.; PINTO, L.F.; SPAROVEK, G. Disclosing contrasting scenarios for future land cover in Brazil: Results from a high-resolution spatiotemporal model, **Science of The Total Environment**, v. 742, n. 140477, 2020. <https://doi.org/10.1016/j.scitotenv.2020.140477>.

FERRARO, R. R.; SKOFRONICK-JACKSON, G.; HONG, Y.; ZHANG, K. **Precipitation. Comprehensive Remote Sensing**, NASA, 4–24. 2018. doi:10.1016/b978-0-12-409548-9.10385-9

FERRAZ, G.F. **Simulação hidrológica e hidrodinâmica do impacto de enchentes na bacia do rio Sirinhaém e avaliação de sistema de controle proposto**. Dissertação (Mestrado) – Universidade Federal de Pernambuco. Programa de Pós-Graduação em Engenharia Civil, 2019.

FERREIRA, E.P.M.; SOARES, P.H.F.; REDA, A.L.L.; DURO, M.A.S.; CYMROT, R.; CRIVELARI, R. **Metodologia para corrigir dados de pluviômetros automáticos comerciais antes da sua**

publicação: um estudo de caso. XVII Safety, Health and Environment World Congress, Vila Real, Portugal, 2017. DOI 10.14684/SHEWC.17.2017.40-44

FLEMING, M.; NEARY, V. Continuous Hydrologic Modeling Study with the Hydrologic Modeling System. **Journal of Hydrologic Engineering**, v.9, n.3, 175–183. 2004. doi:10.1061/(asce)1084-0699(2004)9:3(175)

FLEMING, P.M.; SMILES, D.E.: Infiltration of Water into Soil, In: CHAPMAN, T.C.; DONIN, F.X. (Eds.), **Prediction in Catchment Hydrology**, Australian Academy of Science, Canberra, 83p. 1975.

FOEHN, A.; HERNÁNDEZ, J.G.; SCHAEFLI, B.; CESARE, G. Spatial interpolation of precipitation from multiple rain gauge networks and weather radar data for operational applications in Alpine catchments, **Journal of Hydrology**, v. 563, p. 1092-1110, 2018. <https://doi.org/10.1016/j.jhydrol.2018.05.027>.

FRANZ, M. Spaceborne Synthetic Aperture Radar – Principles, Data Access, and Basic Processing Techniques. In: FLORES, A., HERNDON, K., THAPA, R., CHERRINGTON, E. (Eds.). **SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation**. NASA. 2019. doi:10.25966/ez4f-mg98

FUENTE, A.; MERUANE, C.; SUÁREZ, F. Long-term spatiotemporal variability in high Andean wetlands in northern Chile, **Science of The Total Environment**, v. 756, n. 143830, 2021. <https://doi.org/10.1016/j.scitotenv.2020.143830>.

FUJITA, M.; SATAKE, M. Rainfall rate profiling with attenuation-frequency radar using nonlinear LMS technique under a constraint on path-integrated rainfall rate. **International Journal of Remote Sensing**, 18, 1137–1147, 1997.

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; ROWLAND, J.; ROMERO, B.; HUSAK, G.; MICHAELSEN, J.; VERDIN, A. **A quasi-global precipitation time series for drought monitoring**, Technical Report, U.S Geological Survey Data Series, 832, 2014. doi:10.3133/ds832

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; S. SHUKLA, HUSAK, G.; ROWLAND, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations – A new environmental record for monitoring extremes. **Scientific Data**, v. 2, n. 150066, 2015. doi: 10.1038/sdata.2015.66

GAO, P.; CARBONE G.J.; LU, J. Flood simulation in South Carolina watersheds using different precipitation inputs. **Advances in Meteorology**, 1–10, 2018. <https://doi.org/10.1155/2018/4085463>

GENOVEZ, A.M.; LOMBARDI NETO, F.; SARTORI, A. Classificação Hidrológica de Solos Brasileiros para a Estimativa da Chuva Excedente com o Método do Serviço de Conservação do Solo dos Estados Unidos Parte 1: Classificação, **Revista Brasileira de Recursos Hídricos**, v. 10, n. 4, 2005.

GILEWSKI P.; NAWALANY, M. Inter-comparison of rain-gauge, radar, and satellite (IMERG GPM) precipitation estimates performance for rainfall-runoff modeling in a mountainous catchment in Poland. **Water**, v. 10, n. 11, 1665, 2018. <https://doi.org/10.3390/w10111665>

GOMES, G.T.C. **Erros na estimativa de eventos extremos de vazão usando precipitação estimada por radar**. Dissertação (Mestrado em Recursos Hídricos e Saneamento) – Universidade Federal de Alagoas. Centro de Tecnologia. Programa de Pós-Graduação em Recursos Hídricos e Saneamento. Maceió, p. 54. 2019.

GOMES, M.M.A. **Abordagem integrada de modelagem hidrológica e operação de barragens para avaliação da eficiência do controle de cheias na Bacia do Rio Capibaribe**. Dissertação (Mestrado) – Universidade Federal de Pernambuco. Programa de Pós-Graduação em Engenharia Civil, 2019.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone, **Remote Sensing of Environment**, v. 202, 18-27, 2017. <https://doi.org/10.1016/j.rse.2017.06.031>.

GRIFFITH, C.G.; WOODLEY, W.L.; GRUBE, P.G.; MARTIN, D.W.; STOUT, J.; SIKDAR, D.N. Rain estimation from geosynchronous satellite imagery—visible and infrared studies, **Monthly Weather Review**, v. 106, n.8, p. 1153-1171, 1978.

GUILLOD, B.P.; JONES, R.G.; DADSON, S.J.; COXON, G.; BUSSI, G.; FREER, J.; KAY, A.L.; MASSEY, N.R.; SPARROW, S.N.; WALLOM, D.C.H.; ALLEN, M.R.; HALL, J.W., 2018. A large set of potential past, present and future hydro-meteorological time series for the UK. **Hydrol. Earth Syst. Sci.** <https://doi.org/10.5194/hess-22-611-2018>

GUMINDOGA, W.; RWASOKA, D.T.; NHAPI, I.; DUBE, T. Ungauged runoff simulation in upper Manyame catchment, Zimbabwe: application of the HEC-HMS model. **Physics and Chemistry of the Earth**, v. 100, 371–382, 2017. <https://doi.org/10.1016/j.pce.2016.05.002>

GUNATHILAKE, M.B.; AMARATUNGA, Y.V.; PERERA, A.; KARUNANAYAKE, C.; GUNATHILAKE, A.S.; RATHNAYAKE, U. Statistical evaluation and hydrologic simulation capacity of different satellite-based precipitation products (SbPPs) in the Upper Nan River Basin, Northern Thailand. **Journal of Hydrology: Regional Studies**, 32, 100743, 2020.

HAN, Z.; LONG, D.; HUANG, Q.; LI, X.; ZHAO, F.; WANG, J. Improving Reservoir Outflow Estimation for Ungauged Basins Using Satellite Observations and a Hydrological Model. **Water Resources Research**, v. 56, n. 9, 2020. <https://doi.org/10.1029/2020WR027590>

HARRIS, R.; BAUMANN, I. Satellite Earth Observation and National Data Regulation, **Space Policy**, v. 56, 101422, 2021. <https://doi.org/10.1016/j.spacepol.2021.101422>.

HASHEMI, H.; NORDIN, M.; LAKSHMI, V.; HUFFMAN, G.J.; KNIGHT, R., 2017. Bias Correction of Long-Term Satellite Monthly Precipitation Product (TRMM 3B43) over the Conterminous United States. **Journal of Hydrometeorology**. <https://doi.org/10.1175/jhm-d-17-0025.1>

HAY, L.E.; WILBY, R.L.; LEAVESLEY, G.H., 2000. A comparison of delta change and downscaled GCM scenarios for three mountainous basins in the United States. **JAWRA Journal of the American Water Resources Association**. <https://doi.org/10.1111/j.1752-1688.2000.tb04276.x>

HEC - Hydrologic Engineering Center, Hydrologic modeling system. **HEC-HMS User's Manual**. Version 4.12. US Army Corps of Engineers, 671p, 2023. <https://www.hec.usace.army.mil/confluence/hmsdocs/hmsum/latest>

HERSBACH, H. Decomposition of the Continuous Ranked Probability Score for Ensemble Prediction Systems. Weather and Forecasting. **American Meteorological Society**, out. 2000. Disponível em: <[http://dx.doi.org/10.1175/1520-0434\(2000\)015<0559:DOTCRP>2.0.CO;2](http://dx.doi.org/10.1175/1520-0434(2000)015<0559:DOTCRP>2.0.CO;2)>

HIDAYAH, E.; WIDIARTI, W.; PUTRA, P.; DEWANTIE, A.; ALHAMDA, M.; PRASTIKA, H. Evaluation of Hydrologic Modelling Using Satellite Product, and MMR Rainfall in East Java, Indonesia. **Journal of Ecological Engineering**, 2021, 22, 246–260. <https://doi.org/10.12911/22998993/142843>.

HINGE, G.; HAMOUDA, M.A.; LONG, D.; MOHAMED, M.M., 2022. Hydrologic utility of satellite precipitation products in flood prediction: A meta-data analysis and lessons learnt. **Journal of Hydrology**. <https://doi.org/10.1016/j.jhydrol.2022.128103>

HOLBERG, J. **Tutorial on using HEC-GeoHMS to develop Soil Moisture Accounting Method Inputs for HEC-HMS**. 2021. Disponível em: https://web.ics.purdue.edu/~vmerwade/education/hechms_sma.pdf

HONG, Y.; HSU, K.; SOROOSHIAN, S.; GAO, X. Precipitation estimation from remotely sensed imagery using an artificial neural network cloud classification system, **Journal of Applied Meteorology and Climatology**, v. 43, p. 1834-1852, 2004.

HONG, Y.; LIU, G. The characteristics of ice cloud properties derived from CloudSat and CALIPSO measurements, **Journal of Climate**, 28, 3880–3901, 2015.

HONG, Y., TANG, G., MA, Y., HUANG, Q., HAN, Z., ZENG, Z., YANG, Y., WANG, C., GUO, X., 2018. Remote Sensing Precipitation: Sensors, Retrievals, Validations, and Applications. **Observation and Measurement**. https://doi.org/10.1007/978-3-662-47871-4_4-1

HOOKE, J., DUVEILLER, G., CESCATTI, A., 2018. A global dataset of air temperature derived from satellite remote sensing and weather stations. **Sci Data**. <https://doi.org/10.1038/sdata.2018.246>

HORTON, R. E. An approach toward a physical interpretation of infiltration capacity, **Soil Science Society of America Journal**, v. 5, p. 399-417, 1940.

HOU, A. Y.; KAKAR, R. K.; NEECK, S.; AZARBARZIN, A. A.; KUMMEROW, C. D.; KOJIMA, M.; Oki, R.; NAKAMURA, K.; IGUCHI, T. The Global Precipitation Measurement Mission. **Bulletin of the American Meteorological Society**, 2014, 95, 701–722. <https://doi.org/10.1175/bams-d-13-00164.1>.

HOUZE, R. A. **Remote Sensing of Clouds and Precipitation**. Cloud Dynamics, 77–97, 2014. doi:10.1016/b978-0-12-374266-7.00004-4

HSU, K.; GAO, X.; SOROOSHIAN, S.; GUPTA, H.V. Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks, **Journal of Applied Meteorology**, v. 36, n. 9, 1176-1190, 1997. <https://doi.org/10.1016/j.jhydrol.2020.125474>.

HUANG, J., GÓMEZ-DANS, J.L., HUANG, H., MA, H., WU, Q., LEWIS, P.E., LIANG, S., CHEN, Z., XUE, J.-H., WU, Y., ZHAO, F., WANG, J., XIE, X., 2019. Assimilation of remote sensing into crop growth models: Current status and perspectives. **Agricultural and Forest Meteorology**. <https://doi.org/10.1016/j.agrformet.2019.06.008>

HUANG, W.-R., LIU, P.-Y., HSU, J., LI, X., DENG, L., 2021. Assessment of Near-Real-Time Satellite Precipitation Products from GSMaP in Monitoring Rainfall Variations over Taiwan. **Remote Sensing**. <https://doi.org/10.3390/rs13020202>

HUFF, F. A. Sampling errors in measurement of mean precipitation, **Journal of Applied Meteorology**, v. 9, n. 1, p. 35-44, 1971. doi:10.1175/1520-0450(1970)0092.0.CO;2

HUFFMAN, G. J.; ADLER, R. F.; BOLVIN, D. T.; GU, G.; NELKIN, E. J.; BOWMAN, K. P.; HONG, Y.; STOCKER, E.; WOLFF, D. The TRMM multisatellite precipitation analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. **Journal of Hydrometeorology**, v. 8, 38–55, 2007.

HUFFMAN, G. J.; BOLVIN, D.T.; BRAITHWAITE, D.; HSU, K.; JOYCE, R.; KIDD, C.; NELKIN, E.J.; XIE, P. NASA Global Precipitation Measurement (GPM) Integrated Multi-Satellite Retrievals for GPM (IMERG). **Algorithm Theoretical Basis Document**, version 4.5, 22p., 2015. Disponível em: http://pmm.nasa.gov/sites/default/files/document_files/IMERG_ATBD_V4.5.pdf

IBGE - Instituto Brasileiro de Geografia e Estatística - **Bases cartográficas contínuas - Brasil**, 2018. Disponível em: <https://www.ibge.gov.br/geociencias/cartas-e-mapas/bases-cartograficas-continuas/15759-brasil.html?=&t=downloads> [Acesso em: 27/07/2021].

IBGE. Instituto Brasileiro de Geografia e Estatística. Geociências. 2020. Disponível em: <https://www.ibge.gov.br/geociencias/downloads-geociencias> Acesso em: 30 de set. de 2020.

IBGE - Instituto Brasileiro de Geografia e Estatística - **Mapa de Clima**, 2002. Disponível em: <https://www.ibge.gov.br/geociencias/informacoes-ambientais/climatologia/15817-clima.html?=&t=o-que-e> [Acesso em: 27/07/2021].

IBGE - Instituto Brasileiro de Geografia e Estatística - Diretoria de Pesquisas, Coordenação de População e Indicadores Sociais, **Estimativas da população residente com data de referência 1º de julho de 2021**, 2021. Disponível em: <https://cidades.ibge.gov.br/brasil/pe> [Acesso: 03/07/2021].

INMET. Instituto Nacional de Meteorologia. **Banco de Dados Meteorológicos**. 2020. Disponível em: <https://bdmep.inmet.gov.br/> Acesso em: 30 de set. de 2020.

INPE. Instituto Nacional de Pesquisas Espaciais. **Hidroestimador**. 2017. Disponível em: <<http://ftp.cptec.inpe.br/goes/goes16/hidroest/>> Acesso em: 30 de set. de 2017.

INPE. Instituto Nacional de Pesquisas Espaciais. **Catálogo de Imagens**. 2020. Disponível em: <<http://www.dgi.inpe.br/catalogo/explore>> Acesso em: 30 de set. de 2020.

ISLAM, A.; YU, B.; CARTWRIGHT, N. Assessment and comparison of five satellite precipitation products in Australia, **Journal of Hydrology**, v. 590, 125474, 2020. <https://doi.org/10.1016/j.jhydrol.2020.125474>.

JIA, M.; WANG, Z.; MAO, D.; REN, C.; WANG, C.; WANG, Y. Rapid, robust, and automated mapping of tidal flats in China using time series Sentinel-2 images and Google Earth Engine, **Remote Sensing of Environment**, v. 255, 112285, 2021. <https://doi.org/10.1016/j.rse.2021.112285>.

JOHNSTON, A.K. **Berghaus Hyetographic or Rain Map of the World**. Meteorology, n.3, Series:71, William Blackwood, Edinburgh, 1804-1871.

JOYCE, R.J.; JANOWIAK, J.E.; ARKIN, P.A.; XIE, P. CMORPH: A method that produces global precipitation estimates from passive microwave and infrared data at high spatial and temporal resolution. **Journal of Hydrometeorology**, v. 5, n. 3, 487–503. 2004. [https://doi.org/10.1175/1525-7541\(2004\)0052.0.CO;2](https://doi.org/10.1175/1525-7541(2004)0052.0.CO;2).

KAN, G.; HE, X.; DING, L.; LI, J.; LIANG, K.; HONG, Y. Study on Applicability of Conceptual Hydrological Models for Flood Forecasting in Humid, Semi-Humid Semi-Arid and Arid Basins in China. **Water (Basel)**, v. 09, n. 10, 2017. Disponível em: <http://dx.doi.org/10.3390/w9100719>.

KIM, T.J.; KWON, H.H.; KIM, K.B. Calibration of the reflectivity-rainfall rate (Z-R) relationship using long-term radar reflectivity factor over the entire South Korea region in a Bayesian perspective, **Journal of Hydrology**, v. 593, 125790, 2021. <https://doi.org/10.1016/j.jhydrol.2020.125790>.

KOUTROULIS, A.G.; TSANIS, I.K. A method for estimating flash flood peak discharge in a poorly gauged basin: Case study for the 13–14 January 1994 flood, Giofiros basin, Crete, Greece, **Journal of Hydrology**, v. 385, n. 1–4, p. 150-164, 2010. <https://doi.org/10.1016/j.jhydrol.2010.02.012>.

KATIRAIE-BOROUJERDY, P.-S.; RAHNAMAY NAEINI, M.; AKBARI ASANJAN, A.; CHAVOSHIAN, A.; HSU, K.; SOROOSHIAN, S. Bias Correction of Satellite-Based Precipitation Estimations Using Quantile Mapping Approach in Different Climate Regions of Iran. **Remote Sensing**, 2020, 12, 2102. <https://doi.org/10.3390/rs12132102>.

KULL, D.W.; FELDMAN, A.D. Evolution of Clark's Unit Graph Method To Spatially Distributed. **Journal of Hydraulic Engineering**, v. 3, n. 1, 9-19, 1998.

KUNNATH-POOVAKKA, A.; ELDHO, T. I. Bias Correction of Satellite Precipitation Products for Hydrologic Modeling in Western Ghats Region, India. **Journal of Hydrologic Engineering**, 2023, 28. <https://doi.org/10.1061/jhyeff.heeng-5699>.

LANNA, A.E.L.; SCHWARZBACH, M.M. **Modelo hidrológico autocalibrável**, 1989.

LE, M.H.; LAKSHMI, V.; BOLTON, J.; DU BUI, D. Adequacy of Satellite-derived Precipitation Estimate for Hydrological Modeling in Vietnam Basins, **Journal of Hydrology**, Volume 586, 124820, 2020. <https://doi.org/10.1016/j.jhydrol.2020.124820>.

LI, J., YUAN, D., LIU, J., JIANG, Y., CHEN, Y., HSU, K. L., AND SOROOSHIAN, S.: Predicting floods in a large karst river basin by coupling PERSIANN-CCS QPEs with a physically based distributed hydrological model, **Hydrology and Earth System Sciences**, 23, 1505–1532, 2019. <https://doi.org/10.5194/hess-23-1505-2019>

LI, X.; SUNGMIN, S.; WANG, N.; LIU, L.; HUANG, Y. Evaluation of the GPM IMERG V06 products for light rain over Mainland China, **Atmospheric Research**, v. 253, 105-110, 2021. <https://doi.org/10.1016/j.atmosres.2021.105510>

LI, P., YU, Z., JIANG, P., WU, C., 2021. Spatiotemporal characteristics of regional extreme precipitation in Yangtze River basin. **Journal of Hydrology**. <https://doi.org/10.1016/j.jhydrol.2021.126910>

LI, D. et al. Hydrologic multi-model ensemble predictions using variational Bayesian deep learning. **Journal of Hydrology**. 2022. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2021.127221>>

LIANG, H.; WANG, J.; LIU, J.; LIU, P. Guidance strategies for interceptor against active defense spacecraft in two-on-two engagement, **Aerospace Science and Technology**, v. 96, 105529, 2020. <https://doi.org/10.1016/j.ast.2019.105529>.

LIGHTHILL, M.J.; WHITHAM, G.B. **On kinematic waves: I. Flood movement in long rivers**. Proceedings of the Royal Society of London. Series A, 229, 281–316, 1955.

LINSLEY, R.K.; KOHLER, M.A.; PAULHUS, J.L.; SERRA, M.F.; APARICIO, F.D. **Hidrología para ingenieros**. McGraw-Hill. 386 p., 1977.

LIU, C.; ZIPSER, E.J. “Warm Rain” in the Tropics: Seasonal and Regional Distributions Based on 9 Yr of TRMM Data. **Journal of Climate**, 2009, 22, 767–779. <https://doi.org/10.1175/2008jcli2641.1>.

LOBER, C., FAYNE, J., HASHEMI, H., SMITH, L.C. Bias correction of 20 years of IMERG satellite precipitation data over Canada and Alaska. **Journal of Hydrology: Regional Studies**, v 43, 101192, 2023. <https://doi.org/10.1016/j.ejrh.2023.101386>

LOPES, J.E.G.; BRAGA, B.P.F.; CONEJO, J.G.L. **A simplified hydrological model, applied modelling in catchment hydrology**. SINGH, V.P. (Ed.) Water Resources Publications, 1982.

LU, X.; WONG, W. K.; AU-YEUNG, K. C.; CHOY, C. W.; YU, H. Verification of tropical cyclones (TC) wind structure forecasts from global NWP models and ensemble prediction systems (EPSs). **Tropical Cyclone Research and Review**. Elsevier BV, jun. 2022. DOI 10.1016/j.tccr.2022.07.002. Disponível em: <http://dx.doi.org/10.1016/j.tccr.2022.07.002>.

MACHADO, T.D.; BUCCIERI, G.P.; RIZOL, P.M.S.R. Photovoltaic systems in residences: A concept of efficiency, energy consumption and sustainability in Brazilian culture, **Journal of Cleaner Production**, v. 298, 126836, 2021. <https://doi.org/10.1016/j.jclepro.2021.126836>.

MAPBIOMAS. **MapBiomass General “Handbook”: Algorithm Theoretical Basis Document (ATBD)**, Collection 8. 57p., 2023. Disponível em: <https://brasil.mapbiomas.org/wp-content/uploads/sites/4/2023/09/ATBD-Collection-8-v1.1.docx.pdf> [Acesso em: 08/12/2023].

MAPBIOMAS. **Visão geral da metodologia, conheça os passos da metodologia MAPBIOMAS**, 2021. Disponível em: <https://mapbiomas.org/visao-geral-da-metodologia>. [Acesso em: 30/04/2021].

MARENGO, J. A., TORRES, R. R., & ALVES, L. M. (2016). Drought in Northeast Brazil—past, present, and future. **Theoretical and Applied Climatology**, v. 129, n. 3-4, p.1189-1200. Springer Science and Business Media LLC. <https://doi.org/10.1007/s00704-016-1840-8>

MARENGO, J.A., GALDOS, M.V., CHALLINOR, A., CUNHA, A.P., MARIN, F.R., VIANNA, M. DOS S., ALVALA, R.C.S., ALVES, L.M., MORAES, O.L., BENDER, F., 2021. Drought in Northeast Brazil: A review of agricultural and policy adaptation options for food security. **Climate Resilience**. <https://doi.org/10.1002/cli2.17>

MARSHALL, J.S.; HITSCHFELD, W. The interpretation of the fluctuating echo for randomly distributed scatterers, Part I, **Canadian Journal of Physics**, v. 31, n. 962-994. 1953.

MARSHALL, J.S.; LANGILLE, R. C.; PALMER, W. MCK. Measurement of rainfall by radar. **Journal of Atmospheric Sciences**. v. 4, n. 6, p. 186-192, 1947. [https://doi.org/10.1175/1520-0469\(1947\)004<0186:MORBR>2.0.CO;2](https://doi.org/10.1175/1520-0469(1947)004<0186:MORBR>2.0.CO;2)

MARSHALL, J.S.; PALMER, W.M.K. The distribution of raindrops with size. **Journal of Meteorology**, v. 5, n. 4, p.165-166, 1948.

MARSHALL, J.S. **The constant-altitude presentation of radar weather patterns**. Proc. 6th Weather Radar Conf. Am. Meteorol. SOC., Boston, p. 321-324.5. 1957.

MARTÍN-MARTÍN, A.; COSTAS, R.; VAN LEEUWEN, T.; LÓPEZ-CÓZAR, E.D. Evidence of open access of scientific publications in Google Scholar: A large-scale analysis, **Journal of Informetrics**, v. 12, n. 3, p. 819-841, 2018. <https://doi.org/10.1016/j.joi.2018.06.012>.

MAZION, E.; YEN, B.C. Computational discretization effect on rainfall-runoff simulation. **Journal of Water Resources Planning and Management**, v. 120, n. 5, p. 715–734. 1994.

MEI, Y.; ANAGNOSTOU, E. N.; NIKOLOPOULOS, E. I.; BORGA, M. Error Analysis of Satellite Precipitation Products in Mountainous Basins. **Journal of Hydrometeorology**, 2014, 15, 1778–1793. <https://doi.org/10.1175/jhm-d-13-0194.1>.

METCALF; EDDY. Storm water management model, Vol. 1—Final report. University of Florida, and Water Resources Engineers, EPA Rep. n. 11024DOC07/71 (NITS PB-203289), EPA, Washington, D.C. 1971.

MHAWAJ, M.; FAOUR, G. Open-source Google Earth Engine 30-m evapotranspiration rates retrieval: The SEBALIGEE system, **Environmental Modelling & Software**, v. 133, 104845, 2020. <https://doi.org/10.1016/j.envsoft.2020.104845>.

MIYURU, B.; GUNATHILAKE, Y.V.A.; ANUSHKA P.A.; KARUNANAYAKE, C.; GUNATHILAKE, A.S.; UPAKA, R. Statistical evaluation and hydrologic simulation capacity of different satellite-based precipitation products (SbPPs) in the Upper Nan River Basin, Northern Thailand, **Journal of Hydrology: Regional Studies**, Volume 32, 100743, 2020. <https://doi.org/10.1016/j.ejrh.2020.100743>.

MOAZAMI, S.; NAJAFI, M.R.A comprehensive evaluation of GPM-IMERG V06 and MRMS with hourly ground-based precipitation observations across Canada, **Journal of Hydrology**, v. 594, 125929, 2021. <https://doi.org/10.1016/j.jhydrol.2020.125929>.

MOHSENI, F.; SADR, M.K.; ESLAMIAN, S.; AREFFIAN, A.; KHOSHFETRAT, A. Spatial and temporal monitoring of drought conditions using the satellite rainfall estimates and remote sensing optical and thermal measurements, **Advances in Space Research**, v. 67, n. 12, p. 3942-3959, 2021. <https://doi.org/10.1016/j.asr.2021.02.017>.

MONDAL, A. LAKSHMI, V.; HASHEMI, H. Intercomparison of trend analysis of Multisatellite Monthly Precipitation Products and Gauge Measurements for River Basins of India, **Journal of Hydrology**, v. 565, p. 779-790, 2018. <https://doi.org/10.1016/j.jhydrol.2018.08.083>.

MORIASI, D. N.; ARNOLD, J. G.; VAN LIEW, M.W.; BINGNER, R.L.; HARMEL, R.D.; VEITH, T. L. Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations, **American Society of Agricultural and Biological Engineers**, v. 50, n. 3, p. 885–900, 2007. doi:10.13031/2013.23153

NASA. National Aeronautics and Space Administration. **Earth Data: Open access for open science**. 2019. Página inicial. Disponível em: <<https://earthdata.nasa.gov/>>. Acesso em: 10 de jun. de 2019.

NASA. National Aeronautics and Space Administration. **ClimateServer 2.0: Data and tools for sustainable development**. 2020. Disponível em: <<https://climateserv.servirglobal.net/>>. Acesso em: 10 de jun. de 2020.

NASA. National Aeronautics and Space Administration. **Giovanni: The Bridge Between Data and Science**. V 4.40. 2021. Disponível em: <<https://giovanni.gsfc.nasa.gov/giovanni/>>. Acesso em: 10 de out. de 2021.

NASA - Goddard Earth Sciences Data and Information Services Center (GES DISC), **Data archive and information services for Atmospheric Composition Water & Energy Cycles Climate Variability**. 2021. Disponível em: <https://disc.gsfc.nasa.gov/> [Acesso em: 28/04/2021].

NASH, J.E.; SUTCLIFFE, J.V. River flow forecasting through conceptual models part I - A discussion of principles. **Journal of Hydrology**, v. 10, n. 3, 282-290, 1970. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6).

NAWAZ, M; IQBAL, M.F.; IRFAN, M. Validation of CHIRPS satellite-based precipitation dataset over Pakistan, **Atmospheric Research**, v. 248, 105289, 2021. <https://doi.org/10.1016/j.atmosres.2020.105289>.

NEMANI, R.; VOTAVA, P.; MICHAELIS, A.; MELTON, F.; MILESI, C. Collaborative supercomputing for global change Science. EOS Trans. **American Geophysical Union**, v. 92, n. 13, p. 109-110, 2011.

NGUYEN, P.; OMBADI, M.; GOROOH, V.A.; SHEARER, E.J.; SADEGHI, M.; SOROOSHIAN, S.; HSU, K.; BOLVIN, D.; RALPH, M. F. Dynamic Infrared-Rain Rate (PDIR-Now): A Near-real time, Quasi-Global Satellite Precipitation Dataset. **Journal of Hydrometeorology**. 2020. <https://doi.org/10.1175/JHM-D-20-0177.1>

NGUYEN, P.; SHEARER, E. J.; OMBADI, M.; GOROOH, V. A.; HSU, K.; SOROOSHIAN, S.; LOGAN, W. S.; RALPH, M. PERSIANN Dynamic Infrared–Rain Rate Model (PDIR) for High-Resolution, Real-Time Satellite Precipitation Estimation. **Bulletin of the American Meteorological Society**, v. 101, E286–E302, 2020. <https://doi.org/10.1175/BAMS-D-19-0118.1>

NGUYEN, P.; SHEARER, E.J.; TRAN, H.; OMBADI, M.; HAYATBINI, N.; PALACIOS, T.; HUYNH, P.; UPDEGRAFF, G.; HSU, K.; KULIGOWSKI, B.; LOGAN, W.S.; SOROOSHIAN, S. The CHRS Data Portal, an easily accessible public repository for PERSIANN global satellite precipitation data, **Nature Scientific Data**, v. 6, 180296, 2019. doi: <https://doi.org/10.1038/sdata.2018.296>

NOVO, E.M.L.M. **Sensoriamento Remoto. Princípios e Aplicações**, 4ª Ed. 387p., 2010.

OMBADI, M.; NGUYEN, P.; SOROOSHIAN, S.; HSU, K. How much information on precipitation is contained in satellite infrared imagery? **Atmospheric Research**, v. 256, 105578, 2021. <https://doi.org/10.1016/j.atmosres.2021.105578>

OPEN KNOWLEDGE. **Open data handbook**. 2012. Disponível em: <<http://opendatahandbook.org/>>. [Acesso em: 28/04/21].

OUYANG, W.; LAWSON, K.; FENG, D.; YE, L.; ZHANG, C.; SHEN, C. Continental-scale streamflow modeling of basins with reservoirs: Towards a coherent deep-learning-based strategy, **Journal of Hydrology**, v. 599, 126455. 2021. <https://doi.org/10.1016/j.jhydrol.2021.126455>.

PAREDES-TREJO, F.J.; BARBOSA, H.A.; LAKSHMI, K.T.V. Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil, **Journal of Arid Environments**, v. 139, p. 26-40, 2017. <https://doi.org/10.1016/j.jaridenv.2016.12.009>.

PENG, J., LIU, T., HUANG, Y., LING, Y., Li, Z., BAO, A., CHEN, X., KURBAN, A., DE MAEYER, P., 2021. Satellite-Based Precipitation Datasets Evaluation Using Gauge Observation and Hydrological Modeling in a Typical Arid Land Watershed of Central Asia. **Remote Sensing**. <https://doi.org/10.3390/rs13020221>

PERNAMBUCO - Secretaria de Ciência, Tecnologia e Meio Ambiente. **Plano Estadual de Recursos Hídricos**, 8 volumes, Recife, 1998.

PERNAMBUCO. **Pernambuco Tridimensional (PE3D)**. Disponível em: <<http://www.pe3d.pe.gov.br/>>. Acesso em: 30 de set. de 2020.

PETRY, I.; FAN, F. M.; SIQUEIRA, V. A.; COLLISHONN, W.; DE PAIVA, R. C. D.; QUEDI, E.; DE ARAÚJO GAMA, C. H.; SILVEIRA, R.; FREITAS, C.; PARANHOS, C. S. A. Seasonal streamflow forecasting in South America's largest rivers. **Journal of Hydrology: Regional Studies**. Elsevier BV, out. 2023. DOI 10.1016/j.ejrh.2023.101487.

PFREUNDSCHUH, S., INGEMARSSON, I., ERIKSSON, P., VILA, D.A., CALHEIROS, A.J.P., 2022. An improved near-real-time precipitation retrieval for Brazil. **Atmos. Meas. Tech.** <https://doi.org/10.5194/amt-15-6907-2022>

PINO-VARGAS, E.; CHÁVARRI-VELARDE, E.; INGOL-BLANCO, E.; MEJÍA, F.; CRUZ, A.; VERA, A. Impacts of Climate Change and Variability on Precipitation and Maximum Flows in Devil's Creek, Tacna, Peru. **Hydrology**, 2022, 9, 10. <https://doi.org/10.3390/hydrology9010010>.

PRAKASH, S., BHAN, S.C., 2023. How accurate are infrared-only and rain gauge-adjusted multi-satellite precipitation products in the southwest monsoon precipitation estimation across India? **Environ Monit Assess.** <https://doi.org/10.1007/s10661-023-11148-2>

PULS, L.G. **Flood regulation of the Tennessee River**. Proc., 70th Congress, 1st Session, H. D. 185, Part 2, Appendix B. 1928.

QIN, J.; TIAN, J.; YANG, K.; LU, H.; LI, X.; YAO, L.; SHI, J. Bias correction of satellite soil moisture through data assimilation. **Journal of Hydrology**. 2022. Disponível em: <http://dx.doi.org/10.1016/j.jhydrol.2022.127947>.

RAMLY, S; TAHIR, W.; ABDULLAH, J.; JANI, J. RAMLI, S.; ASMAT, A.; RAWLS, J.W; BRAKENSIEK, D.L.; MILLER, N. Green-ampt Infiltration Parameters from Soils Data. **Journal of Hydraulic Engineering**, v. 109, n. 1, 62-70, 1983.

REFSGAARD, J. C.; STORM, B. **Computer models of watershed hydrology**, In: V. P. SINGH (ed.), Water Resources Publications, Littleton, Colo, 1995.

REIS J.B.C.; RENNÓ C.D.; LOPES E.S.S. Validation of Satellite Rainfall Products over a Mountainous Watershed in a Humid Subtropical Climate Region of Brazil, **Remote Sensing**, v. 9, n. 12, 1240. 2017. <https://doi.org/10.3390/rs9121240>

REIS, J.B.C. **Modelo hidrológico distribuído para o monitoramento de inundações na bacia do rio Sapucaí**, Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

RIBEIRO, A.A.S.; OLIVEIRA, G.A.; CIRILO, J.A.; ALVES, F.H.B.; FERREIRA, L.; BATISTA, D.R.; MELO, V.B. Reconstituição de manchas de inundação baseada em dados coletados via smartphones: uma abordagem metodológica para o mapeamento de riscos hidrológicos. **Revista Brasileira de Recursos Hídricos** (online). v. 25, 41, 2020. <https://doi.org/10.1590/2318-0331.252020190179>.

RIVERA, J.A.; MARIANETTI, G.; HINRICHS, S. Validation of CHIRPS precipitation dataset along the Central Andes of Argentina, **Atmospheric Research**, v. 213, p. 437-449, 2018. Doi:10.1016/j.atmosres.2018.06.023

SABZIPOUR, B.; ARSENAULT, R.; TROIN, M.; MARTEL, J.-L.; BRISSETTE, F. Sensitivity analysis of the hyperparameters of an ensemble Kalman filter application on a semi-distributed hydrological model for streamflow forecasting. **Journal of Hydrology**. Elsevier BV, nov. 2023. DOI 10.1016/j.jhydrol.2023.130251.

SADEGHI, M.; LEE, J.; NGUYEN, P.; HSU, K. L.; SOROOSHIAN, S. BRAITHWAITE, D. Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks-Cloud Classification System-Climate Data Record (PERSIANN-CCS-CDR). **AGU Fall Meeting Abstracts**, H13P-1964, 2019.

SALMANI-DEHAGHI, N.; SAMANI, N. Development of bias-correction PERSIANN-CDR models for the simulation and completion of precipitation time series, **Atmospheric Environment**, v. 246, n. 117981, 2021. <https://doi.org/10.1016/j.atmosenv.2020.117981>.

SAMUEL, S.; DOSIO, A.; MPHALE, K.; FAKA, D. N.; WISTON, M. Comparison of multi-model ensembles of global and regional climate model projections for daily characteristics of precipitation over four major river basins in southern Africa. Part II: Future changes under 1.5 °C, 2.0 °C and 3.0 °C warming levels. **Atmospheric Research**. set. 2023. DOI 10.1016/j.atmosres.2023.106921.

SANT'ANNA, J.L.N. A Gênese da Climatologia no Brasil: o Despertar de uma Ciência, **Geografia**, v. 28, n. 1, p. 5-27, 2003.

SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A.; ARAUJO FILHO, J. C.; OLIVEIRA, J. B.; CUNHA, T. J. F. **Sistema Brasileiro de Classificação de Solos**, Embrapa Solos, 2018.

SARAIVA M.; PROTAS É.; SALGADO M.; SOUZA C. Automatic Mapping of Center Pivot Irrigation Systems from Satellite Images Using Deep Learning. **Remote Sensing**, v. 12, n. 3, 558, 2020. <https://doi.org/10.3390/rs12030558>

SCHMUGGE, T.J., KUSTAS, W.P., RITCHIE, J.C., JACKSON, T.J., RANGO, A., 2002. Remote sensing in hydrology. **Advances in Water Resources**.[https://doi.org/10.1016/s0309-1708\(02\)00065-9](https://doi.org/10.1016/s0309-1708(02)00065-9)

SCHNEIDER, U.; FUCHS, T.; MEYER-CHRISTOFFER, A.; RUDOLF, B. **Global Precipitation Analysis Products of the GPCC**. Global Precipitation Climatology Centre (GPCC), DWD, Internet Publikation, 1-12. 2008. Disponível em: <https://kunden.dwd.de/GPCC/Visualizer>

SCS - Soil Conservation Service, In: **Hydrology, National Engineering of Handbook**, Supplement A, Section 4, Chap. 10, USDA, Washington DC. 1956.

SELIGA, T. A.; BRINGI, V. N. Potential Use of Radar Differential Reflectivity Measurements at Orthogonal Polarizations for Measuring Precipitation. **Journal of Applied Meteorology**, v. 15, n. 1, p. 69–76, 1976. doi:10.1175/1520-0450(1976)015<0069:puordr>2.0.co;2

SEO, B.C.; KRAJEWSKI, W.F. Statewide real-time quantitative precipitation estimation using weather radar and NWP model analysis: Algorithm description and product evaluation, **Environmental Modelling & Software**, v. 132, 104791, 2020 <https://doi.org/10.1016/j.envsoft.2020.104791>.

SHEHU, B.; HABERLANDT, U. Relevance of merging radar and rainfall gauge data for rainfall nowcasting in urban hydrology, **Journal of Hydrology**, v. 594, 125931, 2021. <https://doi.org/10.1016/j.jhydrol.2020.125931>.

SHEN, Z.; YONG, B.; GOURLEY, J.J.; QI, W.; LU, D.; LIU, J.; REN, L. HONG, Y.; ZHANG, J. Recent global performance of the Climate Hazards group Infrared Precipitation (CHIRP) with Stations (CHIRPS), **Journal of Hydrology**. 2020. <https://doi.org/10.1016/j.jhydrol.2020.125284>.

SIEMER, J. **International Encyclopedia of Human Geography**, p. 229–233, 2020. doi:10.1016/b978-0-08-102295-5.10511-6

SIENA, M., LEVIZZANI, V., MARRA, F., 2023. A method to derive satellite-based extreme precipitation return levels in poorly gauged areas. **Journal of Hydrology**. <https://doi.org/10.1016/j.jhydrol.2023.130295>

SILVA, A.F. **Jardins do Recife: uma história do paisagismo no Brasil (1872-1937)**. Recife: CEPE, 2010.

SINGH, V.P.; WOOLHISER, D.A. Mathematical Modeling of Watershed Hydrology. **Journal of Hydrologic Engineering**, v. 7, n. 4, p. 270-292, 2002. doi:10.1061/(asce)1084-0699(2002)7:4(270)

SIQUEIRA, J. **MAPBIOMAS Brazil collection release**, 2020. Disponível em: <https://github.com/mapbiomas-brazil/user-toolkit>

SOBRAL, B.S.; OLIVEIRA-JÚNIOR, J.F.; ALECRIM, F.; GOIS, G.; MUNIZ-JÚNIOR, J.G.; TERASSI, P.; BODAS, M.; PEREIRA-JÚNIOR, E.R.; LYRA, G.B.; ZERI, M. PERSIANN-CDR based characterization and trend analysis of annual rainfall in Rio de Janeiro State, Brazil, **Atmospheric Research**, v. 238, 104873, 2020. <https://doi.org/10.1016/j.atmosres.2020.104873>.

SOROOSHIAN, S.; HSU, K.-L.; COPPOLA, E.; TOMASSETTI, B.; VERDECCHIA, M.; VISCONTI, G. (Eds.). **Hydrological Modelling and the Water Cycle**. Water Science and Technology. Library. 2008. doi:10.1007/978-3-540-77843-1

SOUZA C.M.Jr.; SHIMBO J.Z.; ROSA M.R.; PARENTE L.L.; ALENCAR, A.A.; RUDORFF, B.F.T.; HASENACK, H.; MATSUMOTO M.; FERREIRA L.G.; SOUZA-FILHO P.W.M.; OLIVEIRA S.W.; ROCHA W.F.; FONSECA, A.V.; MARQUES, C.B.; DINIZ, C.G. *et al.* Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**, v. 12, n. 17, 2735, 2020. <https://doi.org/10.3390/rs12172735>

SSCE. Space Science and Engineering Center. **Real Earth™: Visualize your data**. 2019. Página inicial. Disponível em: <<https://www.ssec.wisc.edu/realearth/>>. Acesso em: 10 de jun. de 2019.

TRABUCCO, A.; ZOMER, R.J. **Global Aridity Index and Potential Evapo-Transpiration (ET0) Climate Database v2**. CGIAR, Consortium for Spatial Information (CGIAR-CSI). 2019. <https://doi.org/10.6084/m9.figshare.7504448.v3>

TUCCI, C.E.M. **Hidrologia: Ciência e Aplicação**, 4a. Edição, ABRH, Porto Alegre, 2012.

UCI. University of California, Irvine. Center for Hydrometeorology and Remote Sensing (CHRS). **Data Portal**. 2020. Disponível em: <<http://chrsdata.eng.uci.edu/>> Acesso em: 30 de set. de 2020.

USACE - U.S. Army Corps of Engineers. **Method of flow routing**. Rep. on Survey for Flood Control, Connecticut River Valley, Providence, R. I., Vol. 1, Section 1, Appendix. 1936.

USBR - United States Bureau of Reclamation. Chapter 6.10: Flood routing. **Water Studies, Part 6: Flood hydrology**, Washington, D.C., Vol. IV, 1949.

USBR. United States Bureau of Reclamation. **Design of Small Dams**, United States Department of the Interior, Washington DC, 1987. Disponível em: <https://www.usbr.gov/tsc/techreferences/mands/mands-pdfs/SmallDams.pdf>

USDA - United States Department of Agriculture - Natural Resources Conservation Service - Part 630 Hydrology, **National Engineering Handbook**, Cap. 9, Hydrologic Soil-Cover Complexes, 2004a.

USDA - United States Department of Agriculture - Natural Resources Conservation Service - Part 630 Hydrology, **National Engineering Handbook**, Cap.10: Estimation of Direct Runoff

USGS. United States Geological Survey. **Earth Explorer**. 2019. Página inicial. Disponível em: <<https://earthexplorer.usgs.gov/>>. Acesso em: 10 de jun. de 2019.

VANSTEENKISTE, T.; TAVAKOLI, M.; STEENBERGEN, N.V.; SMEDT, F.; BATELAAN, O.; PEREIRA, F.; WILLEMS, P. Intercomparison of five lumped and distributed models for catchment runoff and extreme flow simulation, **Journal of Hydrology**, v. 511, p. 335-349, 2014. <https://doi.org/10.1016/j.jhydrol.2014.01.050>.

VICENTE, G.A.; DAVENPORT, J. C.; SCOFIELD, R.A. The role of orographic and parallax corrections on real-time high-resolution satellite estimation. **International Journal of Remote Sensing**, 23, 221-230. 2002.

VIEIRA, R.M.S.P.; TOMASELLA, J.; BARBOSA, A.A.; POLIZEL, S.P.; BALBAUD, J.P.; OMETTO, H. SANTOS, F.C.; FERREIRA, Y.C.; TOLEDO, P.M. Land degradation mapping in the MATOPIBA region

(Brazil) using remote sensing data and decision-tree analysis, **Science of The Total Environment**, v. 782, 146900, 2021. <https://doi.org/10.1016/j.scitotenv.2021.146900>.

WAKIGARI, S.A., LECONTE, R., 2023. Exploring the utility of the downscaled SMAP soil moisture products in improving streamflow simulation. **Journal of Hydrology: Regional Studies**. <https://doi.org/10.1016/j.ejrh.2023.101380>

WALLISSON, M. C. **HydroBr: A Python package to work with Brazilian hydrometeorological time series**. (0.1.1). Zenodo. 2020. Disponível em: <https://doi.org/10.5281/zenodo.3931027>

WANG, Y.; CHEN, Y.; FU, Y.; LIU, G. Identification of precipitation onset based on Cloudsat observations, **Journal of Quantitative Spectroscopy and Radiative Transfer**, v. 188, p. 142-147, 2017. <https://doi.org/10.1016/j.jqsrt.2016.06.028>.

WEGAYEHU, E. B.; MULUNEH, F. B. Comparing conceptual and super ensemble deep learning models for streamflow simulation in data-scarce catchments. **Journal of Hydrology: Regional Studies**. [S. l.]: Elsevier BV, abr. 2024. DOI 10.1016/j.ejrh.2024.101694.

WILLIAMS, J.R.; NICKS, A.D.; ARNOLD, J.G. Simulator for water resources in rural basins. **Journal of Hydraulic Engineering**, v. 111, n. 6, 970–986, 1985.

WILSON, J.W.; BRANDES, E.A. Radar Measurement of Rainfall: a Summary, **Bulletin of the American Meteorological Society**, v. 60, n. 9, p. 1048-1060, 1979. [https://doi.org/10.1175/1520-0477\(1979\)060<1048:RMORS>2.0.CO;2](https://doi.org/10.1175/1520-0477(1979)060<1048:RMORS>2.0.CO;2)

WU, H.; YONG, B.; SHEN, Z.; QI, W. Comprehensive Error Analysis of Satellite Precipitation Estimates Based on Fengyun-2 and GPM over Chinese Mainland. **Atmospheric Research**, 2021, 263, 105805. <https://doi.org/10.1016/j.atmosres.2021.105805>.

WURBS, R. A. Dissemination of Generalized Water Resources Models in the United States, **Water International**, v. 23, n. 3, p. 190–198, 1998. doi:10.1080/02508069808686767

XIANG, Y., CHEN, J., LI, L., PENG, T., YIN, Z., 2021. Evaluation of Eight Global Precipitation Datasets in Hydrological Modeling. **Remote Sensing**. <https://doi.org/10.3390/rs13142831>

YANG, L., LIN, L., FAN, L., LIU, N., HUANG, L., XU, Y., MERTIKAS, S.P., JIA, Y., LIN, M., 2022a. Satellite Altimetry: Achievements and Future Trends by a Scientometrics Analysis. **Remote Sensing**. <https://doi.org/10.3390/rs14143332>

YANG, X.; YANG, S.; TAN, M. L.; PAN, H.; ZHANG, H.; WANG, G.; HE, R.; WANG, Z. Correcting the Bias of Daily Satellite Precipitation Estimates in Tropical Regions Using Deep Neural Network. **Journal of Hydrology**, 2022, 608, 127656. <https://doi.org/10.1016/j.jhydrol.2022.127656>.

YONG, B.; REN, L.L.; HONG, Y.; WANG, J.H.; GOURLEY, J.J.; JIANG, S.H.; CHEN, X.; WANG, W. Hydrologic evaluation of Multisatellite Precipitation Analysis standard precipitation products in basins beyond its inclined latitude band: A case study in Laohahe basin China, **Water Resources Research**, v. 46, W07542, 2010. doi:10.1029/2009WR008965

YU, H.; HU, D.; LIU, M.; WANG, S.; DI, Y. Spatio-temporal accuracy evaluation of three high-resolution satellite precipitation products in China area, **Atmospheric Research**, v. 241, 104952, 2020. <https://doi.org/10.1016/j.atmosres.2020.104952>.

YU, S., LU, F., ZHOU, Y., WANG, X., WANG, K., SONG, X., ZHANG, M., 2022. Evaluation of Three High-Resolution Remote Sensing Precipitation Products on the Tibetan Plateau. **Water**. <https://doi.org/10.3390/w14142169>

ZAMBRANO, F.; WARDLOW, B.; TADESSE, T.; LILLO-SAAVEDRA, M.; LAGOS, O. Evaluating satellite-derived long-term historical precipitation datasets for drought monitoring in Chile, **Atmospheric Research**, 186, p. 26-42, 2017. doi: 10.1016/j.atmosres.2016.11.006

ZENG, Q.; CHEN, H.; XU, CY.; JIE, MX.; CHEN, J.; GUO, SL.; LIU, J. The effect of rain gauge density and distribution on runoff simulation using a lumped hydrological modelling approach, **Journal of Hydrology**, v. 563, p. 106-122, 2018. <https://doi.org/10.1016/j.jhydrol.2018.05.058>.

ZHANG, J., CAI, X., LEI, X., LIU, P., WANG, H., 2021. Real-time reservoir flood control operation enhanced by data assimilation. **Journal of Hydrology**. <https://doi.org/10.1016/j.jhydrol.2021.126426>

ZHANG, Y.; YE, A.; NGUYEN, P.; ANALUI, B.; SOROOSHIAN, S.; HSU, K. Error Characteristics and Scale Dependence of Current Satellite Precipitation Estimates Products in Hydrological Modeling. **Remote Sensing**, 2021, 13, 3061. <https://doi.org/10.3390/rs13163061>.

ZHANG, L.; XIN, Z.; ZHANG, C.; SONG, C.; ZHOU, H. Exploring the Potential of Satellite Precipitation after Bias Correction in Streamflow Simulation in a Semi-Arid Watershed in Northeastern China. **Journal of Hydrology: Regional Studies**, 2022, 43, 101192. <https://doi.org/10.1016/j.ejrh.2022.101192>.

ZHANG, T., LIANG, Z., LI, W., WANG, J., HU, Y., LI, B., 2023. Statistical post-processing of precipitation forecasts using circulation classifications and spatiotemporal deep neural networks. **Hydrol. Earth Syst. Sci.** <https://doi.org/10.5194/hess-27-1945-2023>

ZHONG, R., CHEN, X., LAI, C., WANG, Z., LIAN, Y., YU, H., WU, X., 2019. Drought monitoring utility of satellite-based precipitation products across mainland China. **Journal of Hydrology**. <https://doi.org/10.1016/j.jhydrol.2018.10.072>

ZHOU, Z.; GUO, B.; XING, W.; ZHOU, J.; XU, F.; XU, Y. Comprehensive evaluation of latest GPM era IMERG and GSMaP precipitation products over mainland China, **Atmospheric Research**, v. 246, 105132, 2020. <https://doi.org/10.1016/j.atmosres.2020.105132>.

ZINKE, P. J. Forest interception studies in the United States. In: W. E. Sopper and H. W. Lull, Eds. International Symposium on Forest Hydrology, Pergamon Press, New York, p. 137-161. 1967.

ANEXO A – Relação de estações pluviométricas Apac

Código Apac	Nome	Longitude	Latitude	Tipo	Bacia hidrográfica
1	Afrânio	-8.5167	-41.005	Convencional	Pontal
2	Araripina (IPA)	-7.4583	-40.4167	Convencional	Brígida
3	Araripina	-7.5767	-40.5058	Convencional	Brígida
4	Petrolina	-9.3992	-40.5175	Convencional	GI-8
5	Ouricuri	-7.8861	-40.0881	Convencional	Brígida
6	Santa Maria da Boa Vista	-8.8000	-39.8228	Convencional	Garças
7	Cabrobó	-8.5278	-39.2681	Convencional	Terra Nova
8	Salgueiro	-8.0733	-39.1297	Convencional	Terra Nova
9	Belém de São Francisco (IPA)	-8.7583	-38.9822	Convencional	GI-4
10	Belém de São Francisco	-8.7494	-38.9553	Convencional	GI-4
11	São José do Belmonte	-7.8639	-38.7619	Convencional	Pajeú
12	Serra Talhada (IPA)	-7.9306	-38.2889	Convencional	Pajeú
13	Serra Talhada	-7.9931	-38.2936	Convencional	Pajeú
14	Ibimirim (IPA)	-8.5378	-37.6786	Convencional	Moxotó
15	São José do Belmonte (Bom Nome)	-7.9969	-38.6236	Convencional	Pajeú
16	Arcoverde (IPA)	-8.4336	-37.0556	Convencional	Moxotó
17	Bom Conselho (IPA)	-9.1725	-36.6928	Convencional	GI-1
18	Pesqueira	-8.3531	-36.6972	Convencional	Ipanema
19	Garanhuns	-8.8833	-36.4878	Convencional	Mundaú
20	Belo Jardim	-8.3367	-36.4253	Convencional	Ipojuca
21	São Bento do Una (IPA)	-8.5272	-36.4594	Convencional	Una
22	Correntes	-9.1286	-36.3283	Convencional	Mundaú
23	Lajedo	-8.6600	-36.3269	Convencional	Una
24	Caruaru (IPA)	-8.2383	-35.9158	Convencional	Ipojuca
25	Palmares	-8.6783	-35.5797	Convencional	Una
26	Vitória de Santo Antão (IPA)	-8.1283	-35.3028	Convencional	Capibaribe
27	Itambé (IPA)	-7.4075	-35.1786	Convencional	Goiana
28	Goiana (Itapirema - IPA)	-7.6442	-34.9489	Convencional	GL-1
29	Ipojuca (Porto de Galinhas - IPA)	-8.5136	-35.0061	Convencional	GL-3
30	Recife (Várzea)	-8.0500	-34.9167	Convencional	Capibaribe
31	Lagoa Grande	-8.9833	-40.2833	Convencional	Pontal
32	Floresta (CHESF)	-8.6167	-38.5667	Convencional	Pajeú
33	Inajá (CHESF)	-8.9014	-37.8167	Convencional	Moxotó

Lista completa no link: [ANEXO A ESTACOES PLU APAC.xlsx](#)

ANEXO B – Script Python para preparação de arquivos de chuva diária

```

import pandas as pd
from datetime import date
import calendar
import os, fnmatch
from os import listdir
from os.path import isfile, join
import glob

def pegar_lista_arquivos(path):
    files = [ file for file in listdir(path) if (isfile(join(path, file))
and file.endswith('.csv'))]
    return files

pasta_entrada= 'entradas/' #nome da pasta previamente criada onde estão os
csv's de entrada

pasta_saida = 'saidas/' #nome da pasta previamente criada onde serão salvas
as saídas (pasta salva no mesmo diretório onde se encontra o código)

postos_localizacao = pd.read_csv('postos.csv', delimiter=',',
decimal='.',index_col='CODIGO', encoding = 'UTF-8')#se tiver em formato
brasil -> delimiter=';', decimal = ','

nLinhas = postos_localizacao.shape[0]

latitude_dict = postos_localizacao['LATITUDE'].to_dict()
longitude_dict = postos_localizacao['LONGITUDE'].to_dict()

lista_arquivos = pegar_lista_arquivos(pasta_entrada)

for arquivo in lista_arquivos:
    arquivo_path = os.path.join(pasta_entrada, arquivo)

    df = pd.read_csv(arquivo_path, delimiter=',',
decimal=',',index_col=False, encoding = 'UTF-8')#se tiver em formato brasil
-> delimiter=';'

    df['DATA'] = pd.to_datetime(df['DATA'], format = '%m/%d/%Y')#se tiver em
formato brasil -> format = '%d/%m/%Y'(conferir no csv)

    meses = df["DATA"].map(lambda t: t ).unique()
    df['LATITUDE']=df['Codigo'].map(latitude_dict)
    df['LONGITUDE']=df['Codigo'].map(longitude_dict)

    for mes in meses:
        year = mes.astype('datetime64[Y]').astype(int) + 1970
        month = mes.astype('datetime64[M]').astype(int) % 12 + 1
        df_mes = df.loc[df['DATA'] == mes ]
        weekday , monthsize = calendar.monthrange(year, month)

        for dia in range(1, monthsize+1):
            df_dia = df_mes[['Posto', 'Codigo','LONGITUDE', 'LATITUDE',
str(dia)]]

            df_dia.columns = ['Posto', 'Codigo', 'LONGITUDE',
'LATITUDE', 'Chuva']
            nome_arquivo = 'Apac_1d'+str(year)+'_'+str(month)+'_'+str(dia)
            df_dia.to_csv(pasta_saida+nome_arquivo+'.csv', index=False)

```

ANEXO C – Relação de estações fluviométricas Hidroweb em Pernambuco

Código Hidroweb	Bacia hidrográfica	Nome	Longitude	Latitude	Área de drenagem, (km²)
39084200	Botafofo	Eng. Itapirema de Baixo	-7,6833	-34,8833	198
48400000	Brígida	Parnamirim	-8,0922	-39,5881	3060
48420000	Brígida	Riacho Gravatá	-7,9528	-39,9042	2610
48430000	Brígida	Poço Do Fumo	-8,1786	-39,7311	3650
48440000	Brígida	Matias	-8,1717	-40,05	3360
48460000	Brígida	Jacaré	-8,2681	-39,8508	5220
39575000	Canhoto	Canhotinho	-8,8825	-36,2186	808
39100000	Capibaribe	Santa Cruz Do Capibaribe	-7,9619	-36,2022	1560
39130000	Capibaribe	Toritama	-8,0128	-36,0578	2450
39140000	Capibaribe	Salgadinho	-7,9428	-35,6342	4910
39145000	Capibaribe	Limoeiro	-7,8789	-35,4519	5580
39145550	Capibaribe	Limoeiro Jusante	-7,8969	-35,3339	0
39150000	Capibaribe	Paudalho	-7,8942	-35,1733	6190
39154000	Capibaribe	Engenho Canavieira	-7,9719	-35,2067	311
39170000	Capibaribe	Vitória De Santo Antão	-8,1136	-35,2839	264
39187800	Capibaribe	São Lourenço Da Mata II	-7,9986	-35,0392	7290
48340000	Garças	Fazenda Badajó	-8,7536	-39,8539	3900
39081250	Goiana	Timbaúba	-7,5128	-35,3269	276
39082000	Goiana	Engenho Volta	-7,5219	-35,2883	329
39082800	Goiana	Vicência	-7,6506	-35,3206	192
39083000	Goiana	Engenho Retiro	-7,5578	-35,1175	472
39084000	Goiana	Caricé	-7,5428	-35,0686	1320
39084010	Goiana	Nazaré Da Mata	-7,7542	-35,2331	692
39084020	Goiana	Engenho Itapissirica	-7,6131	-35,0647	1230
39715000	Inhumas	Palmeirina	-9,0019	-36,3264	128
49380000	Ipanema	Horizonte Alegre	-8,4981	-36,8603	567
49480000	Ipanema	Águas Belas	-9,0933	-37,1617	3910
39310000	Ipojuca	Sanharó	-8,3656	-36,5603	672
39340000	Ipojuca	Caruaru	-8,3028	-36,0108	2000
39345000	Ipojuca	Gravatá	-8,2128	-35,6042	2650
39360000	Ipojuca	Engenho Tabocas	-8,2819	-35,3647	2960
39370100	Ipojuca	Engenho Maranhão	-8,3697	-35,1422	3310
39189550	Jaboatão	Moreno	-8,1167	-35,1	92
39190000	Jaboatão	Destilaria JB	-8,225	-35,285	48
39190800	Jaboatão	Destilaria JB-II	-8,2233	-35,285	48
39191000	Jaboatão	Ponte PE-35	-8,2425	-35,2647	67
39192000	Jaboatão	Cachoeira Tapada	-8,2636	-35,2597	90
39195000	Jaboatão	Destilaria Inexport	-8,2822	-35,1567	235
39200000	Jaboatão	Pirapama	-8,2792	-35,0628	372
39220000	Jaboatão	Destilaria Bom Jesus	-8,2511	-35,0131	149
49100000	Moxotó	Caroalina	-8,2806	-37,5706	1740
49130000	Moxotó	Samambaia	-8,3272	-37,7236	331
49160000	Moxotó	Inajá	-8,9178	-37,8269	8250
39689000	Mundaú	Correntes II	-9,1242	-36,3392	479
39690000	Mundaú	Correntes	-9,1322	-36,3231	624
48820000	Pajeú	Afogados da Ingazeira	-7,7431	-37,6422	3540
48830000	Pajeú	Flores	-7,8683	-37,9728	4970
48840000	Pajeú	Serra Talhada	-8,0006	-38,2447	5910
48841000	Pajeú	Bom Nome	-8,0061	-38,6033	1300
48860000	Pajeú	Floresta	-8,6089	-38,5767	12300
48880000	Pajeú	Ilha Grande	-8,5275	-38,1664	2260
39800000	Paraíba	Brejão	-9,0394	-36,5983	326
39431000	Sirinhaém	Amaragi	-8,3803	-35,4553	139







Código Hidroweb	Bacia hidrográfica	Nome	Longitude	Latitude	Área de drenagem, (km ²)
39433000	Sirinhaém	José Mariano	-8,4675	-35,4014	295
39450000	Sirinhaém	Engenho Bento	-8,4972	-35,4978	537
39480000	Sirinhaém	Engenho Mato Grosso	-8,6375	-35,3056	1310
39530000	Una	Cachoeirinha	-8,4839	-36,2331	1210
39535000	Una	Sítio Da Chata	-8,5769	-36,0661	588
39540000	Una	Capivara	-8,4975	-35,9153	2610
39540750	Una	São Benedito Do Sul	-8,8161	-35,9339	434
39541000	Una	Belém De Maria	-8,6247	-35,8414	388
39550000	Una	Catende	-8,6786	-35,7233	718
39560000	Una	Palmares	-8,6794	-35,5769	4910
39570000	Una	Engenho Florescente	-8,7478	-35,4897	181
39571000	Una	Sítio Cachoeira	-8,8967	-35,7678	352
39590000	Una	Barreiros	-8,7992	-35,205	6550
39580000	Una	Jacuípe	-8,837392	-35,4463	--

ANEXO D – Relação de barragens inseridas no modelo hidrológico HEC-HMS

Bacia	Reservatório	Longitude	Latitude	Volume, (hm ³)
Capibaribe	Cursaí	-35.1753	-7.8782	12.8
Capibaribe	Eng. Gercino Pontes	-36.1405	-8.0247	13.6
Capibaribe	Goitá	-35.1156	-7.9695	52.9
Capibaribe	Jucazinho	-35.7423	-7.9663	208.0
Capibaribe	Lagoa do Carro	-35.3376	-7.8939	255.0
Capibaribe	Machado	-36.27	-7.9996	14.6
Capibaribe	Poço Fundo	-36.3498	-7.9616	27.8
Capibaribe	Tapacurá	-35.1624	-8.0371	104.9
Capibaribe	Várzea do Una	-35.1223	-8.0292	11.6
GL-2	Pirapama	-35.0717	-8.2879	58.4
Goiana	Guararema	-35.1661	-7.4889	20.7
Goiana	Pedra Fina	-35.5234	-7.7491	6.5
Goiana	Siriji	-35.4121	-7.6717	17.3
Goiana	Tiúma	-35.3453	-7.5118	6.1
Ipojuca	Pão de Açúcar	-36.7005	-8.2721	34.2
Ipojuca	Pedro Moura Jr.	-36.3748	-8.3456	37.4
Moxotó	Poço da Cruz	-37.7049	-8.5083	504.0
Mundaú	Inhumas I	-36.3843	-8.9899	7.9
Pajeú	Barra do Juá	-38.0741	-8.4483	71.4
Pajeú	Brotas	-37.6215	-7.7444	19.6
Pajeú	Jazigo	-38.2416	-7.9996	15.5
Pajeú	Rosário	-37.4721	-7.777	35.0
Pajeú	Serrinha	-38.5332	-8.2085	311.1
Una	Gurjão	-36.5798	-8.6428	3.8
Una	Pau Ferro	-36.12	-8.8382	12.2
Una	Prata	-35.8371	-8.5254	39.5
Una	Serro Azul	-35.67	-8.5873	303.0

ANEXO E1 – Vazões médias observadas e simuladas no modelo HEC-HMS para a bacia do rio Goiana.


— Q_{obs} — Q_{calc} - - $Q_{MLT,calc}$ - - $Q_{MLT,obs}$ ▲ $Q_{máx,obs}$ ● $Q_{máx,calc}$ ◆ $Q_{mín,obs}$ ■ $Q_{mín,calc}$




ANEXO E2 – Vazões médias observadas e simuladas no modelo HEC-HMS para a bacia do rio Capibaribe.

— Q_{obs} — Q_{calc} - - $Q_{MLT,calc}$ - - $Q_{MLT,obs}$ ▲ $Q_{m\acute{a}x,obs}$ ● $Q_{m\acute{a}x,calc}$ ◆ $Q_{m\acute{i}n,obs}$ ■ $Q_{m\acute{i}n,calc}$


Santa Cruz do Capibaribe




Toritama



Salgadinho




Limoeiro




ANEXO E2 – Vazões médias observadas e simuladas no modelo HEC-HMS para a bacia do rio Capibaribe.

— Q_{obs} — Q_{calc} - - $Q_{MLT,calc}$ - - $Q_{MLT,obs}$ ▲ $Q_{m\acute{a}x,obs}$ ● $Q_{m\acute{a}x,calc}$ ◆ $Q_{m\acute{m}n,obs}$ ■ $Q_{m\acute{m}n,calc}$


Paudalho




Engenho Canaveira



Vitória de Santo Antão




São Lourenço da Mata II



ANEXO E3 – Vazões médias observadas e simuladas no modelo HEC-HMS para a bacia do rio Ipojuca.


— Q_{obs} — Q_{calc} - - $Q_{MLT,calc}$ - - $Q_{MLT,obs}$ ▲ $Q_{máx,obs}$ ● $Q_{máx,calc}$ ◆ $Q_{mín,obs}$ ■ $Q_{mín,calc}$




ANEXO E4 – Vazões médias observadas e simuladas no modelo HEC-HMS para a bacia do rio Sirinhaém.

— Q_{obs} — Q_{calc} - - $Q_{MLT,calc}$ - - $Q_{MLT,obs}$ ▲ $Q_{máx,obs}$ ● $Q_{máx,calc}$ ◆ $Q_{mín,obs}$ ■ $Q_{mín,calc}$


Amaraji




José Mariano



Engenho Bento




Engenho Mato Grosso




ANEXO E5 – Vazões médias observadas e simuladas no modelo HEC-HMS para a bacia do rio Una.

— Q_{obs} — Q_{calc} - - $Q_{MLT,calc}$ - - $Q_{MLT,obs}$ ▲ $Q_{m\acute{a}x,obs}$ ● $Q_{m\acute{a}x,calc}$ ◆ $Q_{m\acute{i}n,obs}$ ■ $Q_{m\acute{i}n,calc}$


Cachoeirinha




Capivara



Belém de Maria




Catende




ANEXO E5 – Vazões médias observadas e simuladas no modelo HEC-HMS para a bacia do rio Una.

— Q_{obs} — Q_{calc} - - $Q_{MLT,calc}$ - - $Q_{MLT,obs}$ ▲ $Q_{máx,obs}$ ● $Q_{máx,calc}$ ◆ $Q_{mín,obs}$ ■ $Q_{mín,calc}$


Palmares




Engenho Florescente



Jacuípe







Barreiros



ANEXO E6 – Vazões médias observadas e simuladas no modelo HEC-HMS para a bacia do rio Mundaú.



— Q_{obs} — Q_{calc} - - $Q_{MLT,calc}$ - - $Q_{MLT,obs}$ ▲ $Q_{m\acute{a}x,obs}$ ● $Q_{m\acute{a}x,calc}$ ◆ $Q_{m\acute{i}n,obs}$ ■ $Q_{m\acute{i}n,calc}$



ANEXO E7 – Vazões médias observadas e simuladas no modelo HEC-HMS para a bacia do rio Ipanema.

— Q_{obs} — Q_{calc} - - $Q_{MLT,calc}$ - - $Q_{MLT,obs}$ ▲ $Q_{m\acute{a}x,obs}$ ● $Q_{m\acute{a}x,calc}$ ◆ $Q_{m\acute{i}n,obs}$ ■ $Q_{m\acute{i}n,calc}$


Horizonte Alegre




ANEXO E8 – Vazões médias observadas e simuladas no modelo HEC-HMS para a bacia do rio Moxotó.

— Q_{obs} — Q_{calc} - - $Q_{MLT,calc}$ - - $Q_{MLT,obs}$ ▲ $Q_{máx,obs}$ ● $Q_{máx,calc}$ ◆ $Q_{mín,obs}$ ■ $Q_{mín,calc}$

Caroalina




Inajá




ANEXO E10 – Vazões médias observadas e simuladas no modelo HEC-HMS para a bacia do rio Pajeú.

— Q_{obs} — Q_{calc} - - $Q_{MLT,calc}$ - - $Q_{MLT,obs}$ ▲ $Q_{m\acute{a}x,obs}$ ● $Q_{m\acute{a}x,calc}$ ◆ $Q_{m\acute{i}n,obs}$ ■ $Q_{m\acute{i}n,calc}$


Afogados da Ingazeira




Flores




Serra Talhada



Floresta



Ilha Grande



ANEXO E10 – Vazões médias observadas e simuladas no modelo HEC-HMS para a bacia GL-2.

— Q_{obs} — Q_{calc} - - $Q_{MLT,calc}$ - - $Q_{MLT,obs}$ ▲ $Q_{m\acute{a}x,obs}$ ● $Q_{m\acute{a}x,calc}$ ◆ $Q_{m\acute{i}n,obs}$ ■ $Q_{m\acute{i}n,calc}$

