

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

LUIZA SOUZA DE PAULA

INCERTEZAS NA ESTIMATIVA DE VARIÁVEIS HIDROLÓGICAS POR
SENSORIAMENTO REMOTO EM BACIAS HIDROGRÁFICAS

PORTO ALEGRE
2020

LUIZA SOUZA DE PAULA

INCERTEZAS NA ESTIMATIVA DE VARIÁVEIS HIDROLÓGICAS POR
SENSORIAMENTO REMOTO EM BACIAS HIDROGRÁFICAS

Dissertação de Mestrado apresentada ao
Programa de Pós-Graduação em Sensoriamento
Remoto e Geoprocessamento para obtenção do
Título de Mestre em Sensoriamento Remoto e
Geoprocessamento.

Área de Concentração: Sensoriamento Remoto
Aplicado.

Orientador: Dr. Guilherme Garcia de Oliveira

PORTO ALEGRE
2020

CIP - Catalogação na Publicação

Souza de Paula, Luiza

INCERTEZAS NA ESTIMATIVA DE VARIÁVEIS HIDROLÓGICAS
POR SENSORIAMENTO REMOTO EM BACIAS HIDROGRÁFICAS / Luiza Souza de Paula. --
2020.

129 f.

Orientador: Guilherme Garcia de Oliveira.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Centro Estadual de Pesquisas em
Sensoriamento Remoto e Meteorologia, Programa de
Pós-Graduação em Sensoriamento Remoto, Porto Alegre, BR-RS, 2020.

1. sensoriamento remoto. 2. balanço hídrico. 3. ciclo hidrológico. 4.
armazenamento de água. 5. incertezas. I. Garcia de Oliveira, Guilherme,
orient. II. Título.

AGRADECIMENTOS

Inicialmente agradeço aos meus pais, Eliane e Sérgio, que sempre me incentivaram a estudar e fizeram com que fosse possível a realização deste curso através de um suporte financeiro e emocional.

Ao meu namorado, Raphael, o qual foi o incentivador principal deste desafio, me acompanhando e apoiando desde o processo de seleção, sendo uma das bases fundamentais para que eu permanecesse dando o melhor e chegasse até o meu objetivo final.

Ao meu orientador, Professor Dr. Guilherme Garcia de Oliveira, que foi extremamente atencioso durante todo o desenvolvimento deste trabalho. Apesar da distância e períodos conturbados, sempre respondendo prontamente e agregando muito conhecimento tanto a este trabalho como à minha carreira profissional. Sem dúvidas, levarei como exemplo de pessoa e de excelente profissional.

A todos os colegas de mestrado que fizeram parte do meu crescimento nesta fase. Além de compartilharem este processo comigo com muito companheirismo, me transmitiram conhecimento distintos, cada um trazendo parte de sua realidade, costumes e vivência.

A todos os meus professores que contribuíram com os seus conhecimentos para que hoje eu pudesse realizar mais esta etapa da minha vida.

À Universidade Federal do Rio Grande do Sul (UFRGS) que me deu esta oportunidade, a qual trouxe um ganho incalculável para meu amadurecimento pessoal e profissional.

Meu muito obrigada!

RESUMO

A quantificação dos recursos hídricos disponíveis é fundamental para o seu gerenciamento adequado e para sustentação da qualidade de vida. Convencionalmente, as variáveis hidrológicas são estabelecidas por medições *in situ*, no entanto pode se tornar um desafio obter tais medidas em regiões com baixa densidade de estações de medição. Neste contexto, o sensoriamento remoto na obtenção de dados hidrológicos é uma alternativa atraente, porém existe uma série de incertezas a respeito de sua precisão. O objetivo geral deste trabalho foi analisar as incertezas associadas à estimativa do balanço hídrico a partir de técnicas de sensoriamento remoto, assim como, identificar as diferenças e concordâncias entre dados medidos *in situ* e dados estimados via sensoriamento remoto dos componentes do ciclo hidrológico em bacias hidrográficas com diferentes escalas espaciais e temporais. Para isso, selecionou-se 10 bacias hidrográficas no estado do Rio Grande do Sul com dados observacionais disponíveis. Coletou-se dados de campo e dados de sensoriamento remoto de precipitação (P), evapotranspiração (ET), vazão (Q) e armazenamento de água terrestre (S), devidamente processados e organizados. Calculou-se o balanço hídrico a partir de dados *in situ* e dados de sensoriamento remoto mesclando ambas as fontes para identificação das principais causas de incerteza. Investigou-se os efeitos de escala espacial e temporal na precisão das estimativas das variáveis hidrológicas, tanto individualmente quanto na equação do balanço. Os produtos de sensoriamento remoto utilizados foram: *Tropical Rainfall Measuring Mission* (TRMM), *MODIS global terrestrial evapotranspiration algorithm* (MOD16), *Global Land Data Assimilation System* (GLDAS); *Global Amsterdam Evaporation Land Model* (GLEAM) e *Gravity Recovery and Climate Experiment* (GRACE). Obteve-se resultados satisfatórios na estimativa de P e ET por sensoriamento remoto. Os dados de satélite de armazenamento de água terrestre não obtiveram uma boa concordância com os valores calculados por dados de campo. No entanto, as estimativas de S calculadas por fontes mistas de dados demonstraram resultados excelentes. No cálculo de Q pela equação simples constatou-se que a utilização de ET via sensoriamento remoto é uma alternativa viável quando há escassez de dados de campo. O uso de dados de sensoriamento remoto de S no cálculo da quantificação das vazões para um período histórico reduz significativamente os erros, principalmente em bacias maiores. Concluiu-se que é possível estimar o balanço hídrico em bacias hidrográficas a partir de dados obtidos por sensoriamento remoto, no entanto a precisão destas estimativas é resultado de diversos fatores: localização, tamanho da bacia, época do ano e escala temporal de análise.

Palavras-chave: precipitação, evapotranspiração, armazenamento de água, balanço hídrico, ciclo hidrológico.

ABSTRACT

Quantification of available hydric resources is essential to its proper management and sustained quality of life. Usually, hydrological variables are determined by in situ measurements; however, that could be a challenge in low-density gauging station areas. That makes utilizing remote sensing a good alternative in order to obtain hydrological data. The aforementioned technique has uncertainties related to its accuracy, though. The objective of the present study is both to analyze uncertainties related to water balance estimates through remote sensing and to identify the differences and agreements between observed and estimated remotely sensed data of hydrological variables in watersheds. Therefore, ten watersheds in the Rio Grande do Sul state with available field data were selected. Observed and remotely sensed data of precipitation (P), evapotranspiration (ET), runoff (Q), and water storage (S) were collected, processed, and organized. Hence, water balance was calculated from in situ and remotely sensed data merging both sources of data to identify the main causes of uncertainties. Furthermore, the effects of spatial and temporal scale on the accuracy of hydrological variables estimates were investigated, both individually and the balance equation. The remote sensing products used were: *Tropical Rainfall Measuring Mission (TRMM)*, *MODIS global terrestrial evapotranspiration algorithm (MOD16)*, *Global Land Data Assimilation System (GLDAS)*; *Global Amsterdam Evaporation Land Model (GLEAM)* and *Gravity Recovery and Climate Experiment (GRACE)*. A satisfactory result was obtained in the estimates of P and ET through remote sensing. The terrestrial water storage satellite data did not show good agreement with calculated values from field data. However, the S estimates calculated from mixed data sources showed excellent results. The Q calculation from the simplified equation found that the use of ET remotely sensed data is a viable alternative when there is field data scarcity. It was also evidenced that the use of remotely sensed data for S in the runoff quantification for a historical period lowers errors significantly, especially in larger basins. This work concluded that it is possible to estimate the water balance in hydrographic basins from remotely sensed data; nonetheless, the estimates' accuracy is dependant on various factors such as localization, drainage area, season, temporal scale of analysis.

Keywords: precipitation, evapotranspiration, water storage, water balance, hydrological cycle.

LISTA DE ILUSTRAÇÕES

Figura 01. Relações usadas por diferentes métodos de sensoriamento remoto aplicados ao estudo de nuvens.....	7
Figura 02. Função de densidade da probabilidade do erro percentual médio absoluto da estimativa de precipitação por sensoriamento remoto.....	11
Figura 03. Função de densidade da probabilidade do erro percentual médio absoluto da estimativa de evapotranspiração por sensoriamento remoto.	15
Figura 04. Incertezas das estimativas de massa do GRACE, em mm de espessura da água. ..	21
Figura 05. Fluxograma de processos - Artigo 1.	22
Figura 06. Fluxograma de processos - Artigo 2.	23
Figura 07. Bacias de estudo com diferentes áreas de drenagem. Fonte: Autor.....	29
Figura 08. Precipitação anual estimada por sensoriamento remoto e observada para cada bacia de estudo. A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.....	36
Figura 09. Precipitação média anual observada e estimada por satélite.....	37
Figura 10. Médias trimestrais e anuais para o período de 2000 a 2018 a partir de dados interpolados e dados TRMM e mapa diferença.....	38
Figura 11. Gráfico de dispersão da precipitação anual para cada bacia de estudo, no período entre 2000 e 2018. A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.	39
Figura 12. Gráfico de dispersão da precipitação mensal para cada bacia de estudo, no período entre 2000 e 2018. A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.	41
Figura 13. Evapotranspiração anual estimada por sensoriamento remoto e observada para cada bacia de estudo. A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.....	46
Figura 14. Gráfico de dispersão da evapotranspiração mensal para cada bacia de estudo (MOD16). A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.....	48
Figura 15. Gráfico de dispersão da evapotranspiração mensal para cada bacia de estudo (GLDAS). A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.....	49

Figura 16. Gráfico de dispersão da evapotranspiração mensal para cada bacia de estudo (GLEAM). A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.....	50
Figura 17. Erro absoluto médio dos produtos de estimativa de evapotranspiração.	54
Figura 18. Coeficiente de correlação e índice de concordância mensal dos produtos de estimativa de evapotranspiração.....	55
Figura 19. Normal para o período de análise dos dados <i>in situ</i> de 2000 a 2018 – Evapotranspiração.	56
Figura 20. Armazenamento de água terrestre anual estimado por sensoriamento remoto e observado para cada bacia de estudo. A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.	57
Figura 21. Normal do período de análise dos dados <i>in situ</i> de 2000 a 2018 – Armazenamento de água.....	60
Figura 22. Bacias de estudo com suas estações fluviométricas e áreas de drenagem. Fonte: Autor.....	72
Figura 23. Estações utilizadas para extração de dados <i>in situ</i> . Fonte: Autor.	75
Figura 24. Gráficos de dispersão – vazão calculada pela equação simples X vazão observada. A) Q0; B) Q1; C) Q2; D) Q3.....	80
Figura 25. Coeficiente de correlação e índice de concordância para as vazões calculadas pela equação simples.....	82
Figura 26. Erro Absoluto médio para as vazões calculadas pela equação simples.	83
Figura 27. Diferença do volume total para as vazões calculadas pela equação simples.	83
Figura 28. Normais mensais de 2000 a 2018 das vazões calculadas pela equação simples.....	84
Figura 29. Gráficos de dispersão – vazão calculada pela equação completa X vazão observada. A) Q4; B) Q5; C) Q6; D) Q7; E) Q8; F) Q9; G) Q10.	85
Figura 30. Coeficiente de correlação para as vazões calculadas pela equação completa.....	88
Figura 31. Índice de concordância para as vazões calculadas pela equação completa.	89
Figura 32. Coeficiente Nash-Sutcliffe para as vazões calculadas pela equação completa.....	90
Figura 33. Diferença do volume total para as vazões calculadas pela equação completa.....	91
Figura 34. Normais mensais de 2000 a 2018 das vazões calculadas pela equação completa.	92
Figura 35. Gráfico de dispersão – armazenamentos de água terrestre calculados X armazenamento de água terrestre observada. A)S1; B)S2; C)S3.....	93
Figura 36. Coeficiente de correlação dos armazenamentos de água terrestre calculados por bacia de estudo.....	95

Figura 37. Índice de concordância dos armazenamentos de água terrestre calculados por bacia de estudo.....	95
Figura 38. Erros absolutos médios dos armazenamentos de água terrestre calculados por bacia de estudo.....	96
Figura 39. Diferença do volume total dos armazenamentos de água terrestre calculados por bacia de estudo para o ano de 2000 a 2018.	97
Figura 40. Volume total do período histórico de 2000 a 2018 dos armazenamentos de água terrestre calculados por bacia de estudo.	97
Figura 41. Normais mensais de 2000 a 2018 do armazenamento de água terrestre calculado.	98

LISTA DE TABELAS

Tabela 01. Satélites meteorológicos de órbita polar e geoestacionária.	8
Tabela 02. Principais métodos de estimativa de chuva baseadas em satélite regionais e globais existentes.	10
Tabela 03. Comparações de métodos de estimativa de ET a partir de sensoriamento remoto.	14
Tabela 04. Resumo de algoritmos de estimativa de vazão.	18
Tabela 05. Estações fluviométricas selecionadas para análise dos produtos de sensoriamento remoto.	28
Tabela 06. Quantidade de estações pluviométricas por bacia de estudo.	30

LISTA DE QUADROS

Quadro 01. Metodologia aplicada para extração de bacias hidrográficas.	29
Quadro 02. Estações das quais foram obtidos os dados de evapotranspiração.	31
Quadro 03. Normais mensais de 2000 a 2018 observada e estimada para as bacias hidrográficas.	42
Quadro 04. Análise estatística da precipitação estimada por sensoriamento remoto.	43
Quadro 05. Erro absoluto médio por mês da estimativa de precipitação.	45
Quadro 06. Análise estatística da evapotranspiração estimada por sensoriamento remoto – MOD 16.	51
Quadro 07. Análise estatística da evapotranspiração estimada por sensoriamento remoto – GLDAS.	51
Quadro 08. Análise estatística da evapotranspiração estimada por sensoriamento remoto – GLEAM.	52
Quadro 09. Erro absoluto médio por mês da estimativa de evapotranspiração pelo GLEAM.	56
Quadro 10. Análise estatística do armazenamento de água terrestre estimado por sensoriamento remoto.	58
Quadro 11. Erro absoluto médio por mês da estimativa de armazenamento de água no período entre 2000 e 2018.	60
Quadro 12. Fonte dos dados utilizados para o cálculo das vazões a partir da Equação 15.	77
Quadro 13. Fonte dos dados utilizados para o cálculo das vazões a partir da Equação 16.	77
Quadro 14. Fonte dos dados utilizados para o cálculo dos armazenamentos de água terrestre a partir da equação 17.	78
Quadro 15. Análise estatística das vazões calculadas pela equação simples ($Q = P - ET$).	81
Quadro 16. Análise estatística das vazões calculadas pela equação completa.	87
Quadro 17. Análise estatística dos armazenamentos de água calculados.	94

LISTA DE ABREVIATURAS E SIGLAS

- $\neq V_t$ - diferença do volume total
- 1DD - Um grau por dia
- ALEXI - *The Atmosphere-Land Exchange Inverse*
- AMSR - *Advanced Microwave Scanning Radiometer*
- AMSR-E - *Advanced Microwave Sounding Radiometer-Earth*
- AMSU - *Advanced Microwave Sounding Unit*
- ANA - Agência Nacional de Águas
- ASTER - *Advanced Space borne Thermal Emission and Reflection Radiometer*
- AVHRR - *Advanced Very High Resolution Radiometer*
- BDMEP - Banco de Dados Meteorológicos para Ensino e Pesquisa
- CBERS - *China-Brazil Earth Resources Satellite*
- CERES - Sensor de energia radiante da superfície terrestre e das nuvens
- CMAP - *CPC Merged Analysis of Precipitation*
- CMORPH - *Climate Prediction Center Morphing Method*
- CPC - *Climate Prediction Center*
- d - Índice de concordância
- DLR - *Deutsche Forschungsanstalt für Luft und Raumfahrt*
- DMSP - *Defense Meteorological Satellite Program*
- dTs - Diferença de temperatura superficial de duas vezes pela manhã
- E - Coeficiente Nash – Sutcliffe
- EA - Erro Absoluto Médio
- ERM - Erro Relativo Médio
- ESA - *European Space Agency*
- ET - Evapotranspiração
- EVI - Índice de Vegetação Melhorada
- Fr - Fração de cobertura vegetal
- G - Densidade do fluxo de calor no solo
- GLDAS - *Global Land Data Assimilation System*
- GLEAM - *Global Amsterdam Evaporation Land Model*
- GMAO - *Global Modeling and Assimilation Office*
- GOES - *Geostationary Operational Environmental Satellite*
- GPCP - *Global Precipitation Climatology Project*

GPM - *Global Precipitation Measurement*
GPS - *Global Positioning System*
GRACE - *Gravity Recovery and Climate Experiment*
GRDC - *Global Runoff Data Centre*
GSMaP - *Global Satellite Mapping of Precipitation*
HCMM - *Heat Capacity Mapping Mission*
HIRS - *High-resolution Infrared Radiation Sounder*
hpbl - *Altura da camada limite planetária*
IAF - *Índice de Área Foliar*
INMET - *Instituto Nacional de Meteorologia*
IR - *Infravermelho*
JAXA - *Japan Aerospace Exploration Agency*
LIDAR - *Light Detection And Ranging*
LIS - *Sensor de imageamento de relâmpagos*
MDE - *Modelo Digital de Elevação*
MERIS - *Medium Resolution Imaging Spectrometer*
METRIC - *Mapping EvapoTranspiration at high Resolution with Internalized Calibration*
MOD16 - *MODIS global terrestrial evapotranspiration algorithm*
MODIS - *Moderate Resolution Imaging Spectrometer*
MPE - *Multi-Sensor Precipitation Estimate*
MW - *Microondas*
NASA - *National Aeronautics and Space Administration*
NDVI - *Índice de Vegetação por Diferença Normalizada*
NOAA - *National Oceanic and Atmospheric Administration*
P - *Precipitação*
PERSIANN - *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks*
PR - *Radar de precipitação*
Q - *Escoamento superficial*
r - *coeficiente de correlação*
R² - *coeficiente de determinação*
RADAR - *Radio Detection and Ranging*
REQM - *Raiz do Erro Quadrático Médio*

RFE - *Rainfall estimation algorithm*
RH - Regiões hidrográficas
Rn - Saldo de Radiação
RS - Rio Grande do Sul
S - Armazenamento de água terrestre
SAR - *Synthetic Aperture Radar*
SEBAL - *Surface Energy Balance Algorithms for Land*
SEBI - *Surface Energy Balance Index*
SEBS - *Surface Energy Balance System*
SEMA - Secretaria do Meio Ambiente e Infraestrutura
SRTM - *Shuttle Radar Topography Mission*
S-SEBI - *Simplified-SEBI*
SSM/I - *Special Sensor Microwave/Imager*
SWOT - *Surface Water e Topography Ocean*
Ta - Temperatura do ar medida a uma altura de referência
TAMSAT - *Tropical Applications of Meteorology using Satellite data*
Tc - Temperatura do dossel de vegetação
TCI - *TRMM Combined Instrument*
TIROS-1 - *Television Infrared Observation Satellite*
TMI - Imageador de microondas
TMPA - *TRMM Multisatellite Precipitation Analysis*
TOVS - *TIROS Operational Vertical Sounder*
Tpbl - Temperatura média da camada limite planetária
TRMM - *Tropical Rainfall Measuring Mission*
Ts - Temperatura da Superfície
TSEB - *Two-source Energy Budget*
u - Velocidade do Vento
VIIRS - *Visible Infrared Imager Radiometer Suite*
VIS - Visível
VRS - Radiômetro no visível e no infravermelho
za - Altura de medição da velocidade do vento e temperatura do ar
 α_s - Albedo de ondas curtas de superfície
 ΔS - Variação do armazenamento de água terrestre

SUMÁRIO

CAPÍTULO 1. INTRODUÇÃO	1
1.1 CONTEXTUALIZAÇÃO E JUSTIFICATIVA.....	1
1.2 OBJETIVOS E HIPÓTESES	3
CAPÍTULO 2. REFERENCIAL TEÓRICO METODOLÓGICO	5
2.1 ESTIMATIVA DE VARIÁVEIS HIDROLÓGICAS POR SENSORIAMENTO REMOTO	5
2.1.1 Precipitação.....	5
2.1.2 Evapotranspiração.....	11
2.1.3 Escoamento superficial.....	16
2.1.4 Armazenamento de água terrestre	19
CAPÍTULO 3. ESTRUTURA DO TRABALHO E FLUXOGRAMA DE PROCESSOS	22
CAPÍTULO 4. ESTIMATIVA DE VARIÁVEIS HIDROLÓGICAS EM BACIAS HIDROGRÁFICAS: COMPARAÇÃO ENTRE DADOS OBSERVADOS E OBTIDOS POR SENSORIAMENTO REMOTO	24
4.1 INTRODUÇÃO	25
4.2 MATERIAIS E MÉTODOS.....	28
4.2.1 Área de estudo	28
4.2.2 Coleta de dados.....	29
4.2.3 Análise estatística	33
4.3 RESULTADOS E DISCUSSÃO	35
4.3.1 Precipitação.....	35
4.3.2 Evapotranspiração.....	45
4.3.3 Armazenamento de água terrestre	56
4.4 CONCLUSÕES	60
4.5 REFERÊNCIAS BIBLIOGRÁFICAS	62
CAPÍTULO 5. INCERTEZAS ASSOCIADAS AO USO DO SENSORIAMENTO REMOTO NA ESTIMATIVA DO BALANÇO HÍDRICO	68
5.1 INTRODUÇÃO	69
5.2 MATERIAIS E MÉTODOS.....	71
5.2.1 Área de estudo	71
5.2.2 Coleta de dados.....	73
5.2.3 Balanço Hídrico	76
5.2.4 Análise estatística	78

5.3	RESULTADOS E DISCUSSÃO	79
5.3.1	Vazões calculadas	79
5.3.2	Armazenamentos de água calculados	92
5.4	CONCLUSÕES	98
5.5	REFERÊNCIAS BIBLIOGRÁFICAS	100
5.6	APÊNDICES	102
	CAPÍTULO 6. CONSIDERAÇÕES FINAIS.....	107
	REFERÊNCIAS	108

CAPÍTULO 1. INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO E JUSTIFICATIVA

A água é um bem natural essencial à produção agrícola, à estabilidade econômica e à saúde ambiental do mundo, principalmente em áreas com escassez deste recurso e com grandes demandas. A quantificação dos recursos hídricos disponíveis é fundamental para o seu gerenciamento adequado, para sustentação da qualidade de vida, tanto ecológica quanto humana, das gerações presentes e futuras. A falta de conhecimento das mudanças no armazenamento de água dificulta a nossa capacidade de gerenciar as necessidades atuais e futuras de água e de nos adaptarmos a déficits em regiões de escassez de água (BROOKFIELD *et al.*, 2018).

Desta maneira, o balanço hídrico surgiu da necessidade de se contabilizar a chuva e a evapotranspiração de um ecossistema, com o objetivo principal de avaliar a disponibilidade de água para as plantas, ao longo do ano (D'ANGIOLELLA, VASCONCELLOS e ROSA, 2005).

Um dos componentes mais importantes do balanço hídrico é a precipitação, pois esta interfere em vários setores da sociedade como a agricultura, a pesca, a navegação, o abastecimento d'água, o controle e proteção contra inundações e a conservação dos ecossistemas. Assim, identificar e quantificar os padrões de ocorrência das chuvas fornece subsídios para o planejamento e operação destes setores (SOARES *et al.*, 2014).

Existem diversos bancos de dados de órgãos públicos que fornecem séries históricas de dados de precipitação de todo o território nacional. Estes dados provêm de estações meteorológicas automáticas e convencionais, as quais coletam, sistematicamente, as informações meteorológicas (temperatura, umidade, pressão atmosférica, precipitação, direção e velocidade dos ventos e radiação solar) do ponto onde está localizada (INMET, 2011).

No que tange a medição da evapotranspiração (ET) em campo, seus métodos de quantificação são trabalhosos e de grande custo. Além disso, monitoram a ET apenas para áreas específicas de no máximo alguns quilômetros quadrados (DEBRUIN, 2009). Os principais métodos para medir a ET em campo incluem lisímetros, razão de Bowen, sistemas de covariância de vórtices turbulentos, cintilômetros e balanceamento de água no solo (RANA e KATERJI, 2000). Apesar da alta acurácia das técnicas *in situ*, elas não são muito práticas em escalas regionais, em razão do alto número de locais de medição necessários e a despesa operacional de uma rede tão densa (IRMAK *et al.*, 2011).

Em consequência, a quantificação do armazenamento de água terrestre (S) se torna uma tarefa difícil, em razão da necessidade de observações fundamentais limitadas como água subterrânea, umidade do solo, precipitação, evapotranspiração, água equivalente da neve e outras (CHEN *et al.*, 2009). As alterações no S refletem a precipitação acumulada, a evapotranspiração e o escoamento superficial e subsuperficial em uma determinada área ou bacia hidrográfica. Estes dados fornecem uma boa medida das condições climáticas anormais do S, como a seca, sendo assim, valiosa para a agricultura.

Apesar de sua importância, as medições de superfície do S são essencialmente inexistentes em grandes áreas. Os métodos típicos para estimar o S nas escalas das bacias hidrográficas incluem observações *in situ*, modelagem hidrológica, balanço hídrico atmosférico e terrestre acoplado e sensoriamento remoto (TROCH *et al.*, 2007). Outra técnica é inferir mudanças no S como a diferença entre P, ET e Q, embora aparentemente simples, esta abordagem é complexa devido à ausência de dados, portanto, as medições *in situ* por si só não são suficientes (TANG *et al.*, 2010).

Desta forma, variações sazonais e interanuais nos volumes de armazenamento de águas superficiais, bem como seu impacto na precipitação, evaporação, infiltração e escoamento superficial, não são bem conhecidas. Apesar dos modelos globais de sistema terrestre estarem avançando, as representações do balanço hídrico superficial ainda estão em grande parte imprecisas devido à ausência de uma base de dados coerente para quantificar a vazão de rios e o armazenamento de águas superficiais (ALSDORF, RODRÍGUEZ e LETTENMAIER, 2007).

Algumas questões permanecem abertas e sem uma resposta definitiva a respeito do armazenamento da água terrestre, tais como: Qual é a variabilidade espacial e temporal do armazenamento de água terrestre do mundo? Quais as consequências das mudanças climáticas na disponibilidade de água? Existem ciclos de escassez e abundância de água durante o período histórico?

Com estes aspectos levantados a respeito da importância do conhecimento da disponibilidade de água terrestre, assim como a dificuldade de sua quantificação e espacialização, o sensoriamento remoto apresenta-se com uma alternativa muito atraente. O sensoriamento remoto por satélite é um elemento-chave para obtenção de registros consistentes do ciclo da água, pois oferece cobertura e resolução espacial sem precedentes, especialmente, para regiões onde as medições *in situ* são escassas ou inexistentes. Existem diversas fontes de obtenção de dados de todos os componentes do ciclo da água terrestre, fornecendo um grande potencial para obtenção de observações globais contínuas do ciclo da água terrestre em tempo real. Existe uma série de produtos de missões de satélite recentes e em andamento que

quantificam esses componentes, individualmente ou como um agregado, em várias escalas de tempo e espaço (ALSDORF e LETTENMAIER, 2003).

Portanto, este trabalho vem com o intuito de fazer uma análise das incertezas da estimativa de variáveis hidrológicas por meio de sensoriamento remoto, tanto individualmente, quanto quando aplicadas em cálculos de balanço hídrico, identificando a concordância com os dados observados e quais os pontos e períodos mais divergentes.

1.2 OBJETIVOS E HIPÓTESES

Apesar das diversas tecnologias desenvolvidas para estimativa de variáveis hidrológicas por sensoriamento remoto, ainda existe uma série de dúvidas a respeito de sua precisão, visto que estas podem variar de acordo com a sua localização no planeta Terra, o intervalo de tempo de análise, tamanho da área de estudo, características da área, entre outras. Portanto levanta-se as seguintes questões:

Qual o nível de imprecisão ao se agregar estimativas de sensoriamento remoto e de dados *in situ* em equações de balanço hídrico para bacias hidrográficas? Quais as fontes de dados com maior similaridade de resposta nesta equação? Quais variáveis do ciclo hidrológico agregam maiores discordâncias na quantificação do armazenamento de água? Que fatores influenciam para o aumento ou redução das concordâncias entre dados de sensoriamento remoto e dados *in situ*? Em que casos o uso de estimativa por sensoriamento remoto é uma opção mais atraente do que estimativas de dados *in situ*?

Desta forma, este trabalho investiga a hipótese de que é possível estimar o balanço hídrico em bacias hidrográficas em múltiplas escalas temporais e espaciais a partir de dados obtidos por sensoriamento remoto, obtendo-se uma satisfatória precisão na quantificação dos fluxos de água.

Nesse sentido, o objetivo geral foi analisar as incertezas associadas à estimativa do balanço hídrico a partir de técnicas de sensoriamento remoto, assim como, identificar as diferenças e concordâncias entre dados estimados a partir de medições *in situ* e dados via sensoriamento remoto dos componentes do ciclo hidrológico em bacias hidrográficas com diferentes escalas espaciais e temporais. Para que o objetivo geral fosse alcançado, os seguintes objetivos específicos foram desenvolvidos:

- Calcular o balanço hídrico a partir de ambas as fontes em diferentes escalas temporais;

- Quantificar e identificar as incertezas associadas ao cálculo do balanço hídrico com incorporação de dados de sensoriamento remoto por meio da comparação com os dados de campo.

CAPÍTULO 2. REFERENCIAL TEÓRICO METODOLÓGICO

Neste tópico é apresentada uma revisão bibliográfica a respeito das práticas aplicadas para a estimativa de variáveis hidrológicas por sensoriamento remoto, assim como as incertezas já identificadas por estudos anteriores na sua quantificação.

2.1 ESTIMATIVA DE VARIÁVEIS HIDROLÓGICAS POR SENSORIAMENTO REMOTO

Para melhor compreensão e detalhamento, este tema foi estruturado considerando os quatro componentes do balanço hídrico: precipitação, evapotranspiração, escoamento superficial e armazenamento de água terrestre.

2.1.1 Precipitação

A estimativa de precipitação por satélite apresenta inúmeras vantagens sobre as medições baseadas em pluviômetros. A mais notória é a cobertura espacial, especialmente sobre os oceanos, onde as medições de precipitação são escassas, como também, a capacidade de amostragem temporal para grandes áreas, permitindo aplicações em tempo real ou quase em tempo real. Além disso, estes dados são mais homogêneos do que os dados provenientes de pluviômetro (TAPIADOR *et al.*, 2004). O uso de dados provenientes de satélites permite observar mudanças na estrutura da precipitação ao longo do ciclo de vida de uma tempestade, mesmo em locais em que os dados convencionais são esparsos (NASA, 2017).

Oposto às observações de precipitação na superfície terrestre, as quais envolvem medidas de queda de chuva, as estimativas de precipitação baseadas em satélite dependem mais das características das próprias nuvens. Para tal, três faixas de radiação eletromagnética têm grande relevância: visível (VIS), infravermelho (IR) termal e microondas (MW) (BARRETT, 1993).

Na década de 1950 foi estabelecida a relação entre a radiação refletida na parte do VIS e a estimativa de precipitação através de observações de aeronaves, a partir da observação de que nuvens que possuíam albedos maiores eram mais espessas e, portanto, mais propensas a precipitar do que nuvens de menor brilho. Contudo, há uma série de fatores que afetam o brilho das nuvens. Técnicas que utilizam o IR baseiam-se em que as temperaturas registradas no topo da nuvem são indicativas do desenvolvimento vertical da nuvem, nuvens com maior

desenvolvimento vertical são conhecidas por produzirem chuva significativa, enquanto nuvens de menor desenvolvimento vertical produzem pouca chuva (KIDD, 2001).

Nos anos 1970 foi estabelecido que as imagens de MW passivas poderiam fornecer uma avaliação útil sobre o conteúdo de água líquida da atmosfera, a água precipitável e a intensidade da chuva. Essa capacidade ocorre devido as MW penetrarem nas nuvens, sendo as partículas de precipitação a principal fonte de atenuação em frequências de MW passivas (KIDD, 2001).

Porém, as estimativas de precipitação por satélite são limitadas, principalmente, por dois fatores: as baseadas em MW apresentam resolução espacial e temporal grosseira, porém determinam a precipitação de forma mais direta, por meio da atenuação do MW pelas nuvens; as baseadas em IR fornecem melhor resolução temporal e espacial, mas determinam a precipitação indiretamente por inferência a partir da temperatura no topo das nuvens (TAPIADOR *et al.*, 2004).

Segundo Sorooshian *et al.* (2011), os sensores de MW fornecem informações de precipitação mais precisas, mas possuem dados pouco frequentes (aproximadamente duas observações por dia para qualquer local), por outro lado, os de IR/VIS fornecem informações de precipitação mais frequentes (frequência temporal aproximadamente entre 15 e 30 minutos), embora com maior incerteza. Destarte, estudos sugerem que a combinação de informações de MW e IV por satélite permite melhores estimativas de precipitação, especialmente de padrões diurnos, combinando as qualidades de ambos os sensores (JOYCE *et al.*, 2004).

Dado que a natureza inerente das interações entre nuvens/precipitação e radiação eletromagnética varia de acordo com a região espectral, se pode esperar que o conteúdo da informação nestas observações também varie de acordo com o espectro em que elas são feitas (STEPHENS e KUMMEROW, 2007). Segundo os mesmos autores há três diferentes interações que são utilizadas como bases de modelos avançados de estimativa por satélite das propriedades de nuvens e precipitação:

- a) Medições de transmissão onde a atenuação de uma fonte de radiação definida é usada para determinar alguma propriedade das nuvens;
- b) Métodos baseados em informações extraídas da emissão de radiação infravermelha e / ou microondas;
- c) Métodos que utilizam a radiação espalhada pelas nuvens e precipitação.

A Figura 01 ilustra estas interações entre a radiação eletromagnética e as nuvens.




Figura 01. Relações usadas por diferentes métodos de sensoriamento remoto aplicados ao estudo de nuvens.
Fonte: Adaptado de Stephens e Kummerow (2007).

Há uma classe especial de abordagem que emprega sistemas ativos, como sistemas de Radio Detection and Ranging (RADAR) e *Light Detection And Ranging* (LIDAR), para sondar nuvens e precipitação (STEPHENS e KUMMEROW, 2007). As medidas por radares espaciais da intensidade da chuva são possíveis devido ao sensor radar de precipitação (PR) a bordo do *Tropical Rainfall Measuring Mission* (TRMM) e *Global Precipitation Measurement* (GPM) da NASA. Essas medidas avaliam a atenuação do sinal de radar causado pela chuva. Estas estimativas, geralmente, avaliam a refletividade do radar de chuva através de um fator empírico de uma base da região, ou seja, os sistemas de radar de chuva precisam de calibração para estimativas adequadas de precipitação (KARIMI e BASTIAANSEN, 2015).

Os satélites em órbita polar utilizam sensores de microondas passivos ou radares (ativos) e são capazes de inferir com relativa precisão as propriedades das nuvens e suas taxas de precipitação por meio de modelos de transferência radioativa. Os satélites geoestacionários monitoram a temperatura do topo das nuvens através de bandas do VIS e IR fornecendo estimativas com menor precisão, mas com resoluções espaciais e temporais de 5 km e 15 minutos, respectivamente.

O primeiro *Television Infrared Observation Satellite* (TIROS-1) foi lançado em abril de 1960, com o objetivo de observar os padrões climáticos da Terra, sendo a primeira série de satélites meteorológicos lançados pelos Estados Unidos (NASA, 2014). A partir de seu lançamento, houve um avanço no desenvolvimento de sistemas de satélites, em que sensores de satélites de órbita polar se tornaram uma das principais fontes de observações meteorológicas

(KIDD, 2001). As séries de satélites *National Oceanic and Atmospheric Administration* (NOAA) são descendentes diretos do satélite TIROS-1, caracterizadas por recobrirem o globo duas vezes por dia com uma resolução espacial de 1 km (KIDD, 2001). O Sistema Mundial de Cobertura de Satélites Meteorológicos compreende três satélites geoestacionários, destes, dois são da série *Geostationary Operational Environmental Satellite* (GOES), operados pela NOAA e um METEOSAT da *European Space Agency* (ESA) (CONTI, 2002).

O conjunto de sensores desenvolvido para detecção da radiação de MW, o *Defense Meteorological Satellite Program* (DMSP), iniciado em 1960, com radiômetros de varredura registram informações que auxiliam na determinação do tipo e da altura das nuvens, da temperatura da superfície da água e da terra, das correntes de água, das características da superfície do oceano, do gelo e da neve (KIDD, 2001; NOAA, 2018). O TRMM foi lançado em 1997, como satélite experimental conjunto da NASA e da *Japan Aerospace Exploration Agency* (JAXA), percorre 16 órbitas por dia com instrumentos de bordo que possibilitam o monitoramento de nuvens, precipitações, fluxo de calor, raios e outros aspectos do ciclo da água. Seu instrumento mais significativo é o PR de MW ativo capaz de fornecer informações sobre distribuição horizontal e vertical de precipitação em resolução espacial de 4 km e 250 m, respectivamente (KIDD, 2001; PASSOW, 2010).

Existem outros satélites meteorológicos, tais como os citados na Tabela 01.

Tabela 01. Satélites meteorológicos de órbita polar e geoestacionária.

Satélite	País de origem	Sensor	Cobertura
NOAA	USA	VIS/IR	90°N – 90°S
Meteor	Rússia	VIS/IR	90°N – 90°S
FY-1	China	VIS/IR	90°N – 90°S
TRMM	USA/ Japão	VIS/IR/MW/radar	40°N – 40°S
DMSP	USA	VIS/IR/MW	89°N – 89°S
Meteosat -7	Europa	VIS/IR	0°
Meteosat -5	Europa	VIS/IR	63°E
GOMS- 1	Rússia	VIS/IR	76°E
INSAT- 1D	Índia	VIS/IR	74°E
INSAT- 2E	Índia	VIS/IR	83°E
FY- 2A,B	China	VIS/IR	105°E
GMS – 5	Japão	VIS/IR	140°E
GOES – 10	USA	VIS/IR	IR 135°W
GOES – 8	USA	VIS/IR	75°W

Fonte: Adaptado de Kidd (2001).

Diversos métodos de estimativas de precipitação por satélite têm sido desenvolvidos nos últimos anos, tais como: *Climate Prediction Center Morphing Method* (CMORPH) com estimativas de precipitação derivadas do MW passivo dos satélites NOAA, DMSP e TRMM (JOYCE *et al.*, 2004); *TRMM Multisatellite Precipitation Analysis* (TMPA) em que dados de MW passivo são coletados do TRMM, DMSP, Aqua, e NOAA e dados de IR coletados pela constelação internacional de satélites geossíncronos de órbita terrestre (GEO) (HUFFMAN *et al.*, 2007); *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks* (PERSIANN) projetada para extrair e combinar informações de dados de vários tipos, incluindo imagens de satélite IR e MW, pluviômetros e dados de radar baseados em informações topográficas da superfície do solo (HSU *et al.*, 1997); *The Global Precipitation Climatology Project* (GPCP) que fornece uma análise mensal, em uma grade global de 2,5° de latitude por 2,5° de longitude, com dados a partir do ano de 1979 (ADLER *et al.*, 2003).

Karimi e Bastiaanssen (2015) compilaram uma série de metodologias utilizadas para estimativa de precipitação por sensoriamento remoto, conforme Tabela 02.

No entanto, conjuntos de dados de satélite estão sujeitos a diversas incertezas. Estimativas de chuvas através de sensores MW apresentam muitas vantagens sobre as técnicas baseadas em IR, mas desvantagens como a baixa resolução temporal e espacial devem ser consideradas. As abordagens de fusão de dados são capazes de mitigar essas desvantagens sem remover a discriminação baseada em precipitação física que elas proporcionam (TAPIADOR *et al.*, 2004).

Segundo Stephens e Kummerow (2007), vários fatores contribuem para as incertezas das estimativas de precipitação derivadas dos métodos de emissão de microondas, tais como:

- a) Distinguir a precipitação de cenas nubladas de cenas não-precipitantes. Como o problema de identificação com nuvem / sem nuvens, a discriminação da nuvem a partir de cenas nubladas contendo precipitação é um primeiro passo importante em qualquer método de recuperação de precipitação. A classificação errônea de tais cenas é uma fonte de viés de recuperação;
- b) A natureza do modelo atmosférico. Os modelos variam consideravelmente em complexidade e em número e tipos de parâmetros que os definem;
- c) Aproximações à transferência radiativa e microfísica da chuva. Incertezas no estado atmosférico formam uma parte do total de erro do modelo avançado. Outras fontes de erro de modelo derivam do próprio modelo de transferência radiativa, nas aproximações às propriedades de absorção e dispersão de nuvens e precipitações. Incertezas associadas a suposições sobre as propriedades microfísicas da chuva, incluindo o derretimento de partículas, sustentam grande parte do ruído geofísico no sistema.

Tabela 02. Principais métodos de estimativa de chuva baseadas em satélite regionais e globais existentes.

Produto	Principais dados de entrada	Resolução espacial	Cobertura	Resolução mínima temporal
MPE	Meteosat 7,8,9,10	3km	Oceano Índico	15 min
CMORPH	MW (DMSP F-13,14 e 15, NOAA-15, 16, 17 e 18, AMSR-E, e TRMM).	8 km	50° N–50° S	30 min
PERSIANN	MW (DMSP F-13, 14, e 15, NOAA-15, 16, 17, e TRMM).	0.25°	60° N–60° S	1h
GSMaP	MW (DMSP F-13, 14 e 15, AMSR, AMSR-E, e TRMM).	0.1°	60° N–60° S	1h
NRL-blended	MW (DMSP F-13, 14 e 15, F-16)	0.25°	60° N–60° S	3h
TCI (3G68)	MW (TRMM) e PR	0.5°	37° N–37° S	1h
TOVS	HIRS, AMSU	1°	Global	Diário
Hydro estimator	IR GOES	4 km	Global	15 min
TRMM 3B42	MW (TRMM, SSM/I, AMSR e AMSU), IR de satélites geostacionários	0.25°	50° N–50° S	3h
CPC-RFE 2.0	MW (SSM/I,e AMSU-B), IR (METEOSAT)	0.1°	20° W–55° E 40° N–40° S	Diário
GPCP 1DD	IR de satélites geostacionários, TOVS	1°	50° N–50° S	Diário
CMAP	MW (SSM/I), GOES IR	2.5°	Global	5 dias
TAMSAT	Meteosat termal – IR	3 km	África	10 dias
TRMM 3B42	MW (TRMM, SSM-I, AMSR e AMSU), IR de satélites geostacionários	0.25°	40° N–40° S	Mensal
GPCP_V2	MW (SSM/I), IR, TOVS	2.5°	Global	Mensal

Fonte: Adaptado de Karimi e Bastiaanssen (2015).

Karimi e Bastiaanssen (2015) analisaram 24 artigos que descrevem a precisão das estimativas de precipitação sazonal e anual por satélites, contabilizando 68 pontos de dados reconstruídos. Obtiveram a seguinte distribuição da função de densidade da probabilidade do erro percentual médio absoluto relatado (Figura 02).




Figura 02. Função de densidade da probabilidade do erro percentual médio absoluto da estimativa de precipitação por sensoriamento remoto.
Fonte: Adaptado de Karimi e Bastiaanssen (2015)

O erro percentual médio absoluto varia entre 0 e 65%, dos produtos globais, as estimativas do TRMM foram as mais precisas. Vários estudos mostram que a calibração local melhora significativamente a precisão de estimativas de precipitação por satélite, mas erros relevantes foram encontrados para todos os algoritmos de precipitação. A incompatibilidade de escala de pixel é uma das principais fontes deste problema (KARIMI e BASTIAANSEN, 2015).

Asadullah, McIntyre e Kigobe (2008) avaliaram cinco produtos de satélite de estimativa de precipitação: CMORPH, PERSIANN, RFE 2.0, TRMM 3B42 e TAMSAT. Os produtos CMORPH, TRMM 3B42, TAMSAT e o RFE subestimaram a precipitação em 2, 8, 12 e 19%, respectivamente, enquanto PERSIANN superestimou 8%. Os produtos TRMM 3B42 e TAMSAT apresentaram maior similaridade com os dados *in situ*. No entanto, o CMORPH possui maior similaridade com dados históricos na progressão sazonal da precipitação do que com padrões espaciais de precipitação, quando comparado com os outros produtos. O RFE 2.0 apresentou maior capacidade espacial do que temporal e o sistema PERSIANN é vantajoso em termos de padrões sazonais de precipitação nas regiões com menor elevação, porém, estima quantidades de precipitação muito diferentes dos outros produtos.

2.1.2 Evapotranspiração

A necessidade de quantificar ET em escala regional/global, em paralelo com os avanços atuais das tecnologias de satélite, levou à aplicação generalizada de sensoriamento remoto na modelagem da ET (BHATTARAI *et al.*, 2016). Esta tecnologia apresenta vantagens marcantes em relação às medições convencionais: 1) cobertura espacial ampla e contínua em poucos minutos; 2) menor custo; 3) maior praticidade para áreas não habitadas, onde medidas feitas

pelo homem são de difícil condução, ou até mesmo, indisponíveis (ENGMAN *et al.*, 1991; RANGO, 1994).

A capacidade de usar tecnologia de sensoriamento remoto para avaliar ET com a ajuda de termômetros portáteis ganhou destaque a partir de 1970, mas somente após 1978 com o lançamento da missão *Heat Capacity Mapping Mission* (HCMM) e satélites meteorológicos de órbita polar – TIROS-N (terceira geração de satélites meteorológicos da NOAA) – que os dados se tornaram disponíveis para estudos de fluxo de superfície a partir de naves espaciais (PRICE, 1980).

Os métodos variam em complexidade, desde regressões empíricas simplificadas a modelos de equilíbrio de energia superficial, métodos de triângulo/trapézio de temperatura da superfície e técnicas de assimilação de dados, estas, em geral, acopladas a algum modelo numérico que agrega todas as fontes de informação disponíveis para identificar o fluxo de transferência de calor e água através da interação solo-vegetação-atmosfera (KUSTAS e NORMAN, 1996).

Para a estimativa da ET por sensoriamento remoto, são utilizadas as seguintes abordagens básicas: índices de vegetação baseados em dados de Índice de Área Foliar (IAF) ou Índice de Vegetação por Diferença Normalizada (NDVI), albedo de superfície a partir de bandas do visível e infravermelho próximo, emissividade e temperatura de superfície radiométrica a partir de bandas infravermelhas térmicas (LI *et al.*, 2009). O IAF e o NDVI, provenientes do sensoriamento remoto, são usados juntamente com a resistência de superfície na equação de Penman-Monteith para fornecer estimativas globais de ET, e a Temperatura da Superfície Terrestre, detectada remotamente, é utilizada em diversos algoritmos, incluindo os modelos de variabilidade espacial como o *Surface Energy Balance Algorithms for Land* (SEBAL) (LONG, LONGUEVERGNE e SCALON, 2014).

As principais metodologias de base física para estimativas de ET por sensoriamento remoto podem ser divididas em: modelos residuais de balanço de energia e modelos baseados em equações (Penman-Monteith e Priestley-Taylor). Também são utilizados, conforme a escala da aplicação, dados meteorológicos auxiliares oriundos de estações meteorológicas ou de reanálise (PAIVA e RUHOFF, 2017).

A temperatura da superfície é a principal variável de entrada nos algoritmos ET, medida rotineiramente por radiômetros espaciais como o *Advanced Very High Resolution Radiometer* (AVHRR), *Moderate Resolution Imaging Spectrometer* (MODIS), *Visible Infrared Imager Radiometer Suite* (VIIRS), Landsat, *Advanced Space borne Thermal Emission and Reflection Radiometer* (ASTER), *China-Brazil Earth Resources Satellite* (CBERS), e por satélites

chineses como o HJ e o Feng Yung (KARIMI E BASTIAANSEN, 2015). No entanto, nenhum deles é capaz de medir o conteúdo de vapor próximo da superfície ou o fluxo de vapor. Portanto, a ET é determinada pela aplicação de um balanço de energia na superfície, em que a energia consumida pelo processo ET é calculada como um resíduo da equação de energia superficial (01) (ALLEN *et al.*, 2011).

$$LE = R_n - G - H \quad (01)$$

Em que: LE é a energia latente consumida por ET; R_n é radiação líquida (soma de toda radiação de onda curta e onda longa de entrada e saída na superfície); G é densidade do fluxo de calor no solo e H é o fluxo de calor sensível.

Nessa perspectiva, diversos algoritmos de estimativa de evapotranspiração foram desenvolvidos: *Surface Energy Balance Index* (SEBI) (MENENTI e CHOUDHURY, 1993), junto com seus derivados como SEBAL (BASTIAANSEN *et al.*, 1998), *Simplified-SEBI* (S-SEBI) (ROERINK e MENENTI, 2000), *Surface Energy Balance System* (SEBS) (SU, 2002; JIA *et al.*, 2003), *Mapping EvapoTranspiration at high Resolution with Internalized Calibration* (METRIC) (ALLEN *et al.*, 2007); e outros como *The Atmosphere-Land Exchange Inverse* (ALEXI) (ANDERSON *et al.*, 1997), ETWatch (WU *et al.*, 2012), *Two-source Energy Budget* (TSEB) (NORMAN, KUSTAS e HUMES, 1995).

Uma classe diferente de algoritmos de ET, baseados em sensoriamento remoto, é construída em torno da derivação de um valor relativo de ET usando métodos trapezoidais/triangulares. Construídos a partir de uma população de valores de pixel de temperatura da superfície e de índice de vegetação, usados para inferir o valor relativo de ET. Assumem que a temperatura mais baixa em uma determinada faixa de índice de vegetação representa a ET potencial (KARIMI e BASTIAANSEN, 2015).

A Tabela 03 apresenta alguns métodos de estimativa de ET por sensoriamento remoto e suas respectivas vantagens e desvantagens.

Tabela 03. Comparações de métodos de estimativa de ET a partir de sensoriamento remoto.

Métodos	Entradas Principais	Vantagens	Desvantagens
SEBI	$T_{pbi}, h_{pbi}, u, T_s,$ R_n, G	Relaciona diretamente os efeitos de T_s e r_a em LE.	Medições baseadas em terra são necessárias.
SEBAL	$u, z_a, T_s, IV,$ R_n, G	1) Medições mínimas do solo; 2) Calibração interna automática; 3) Correções atmosféricas precisas não são necessárias.	1) Aplicado sobre superfícies planas; 2) Incerteza na determinação de pixels âncora.
S-SEBI	T_s, α_s, R_n, G	Nenhuma medição terrestre é necessária.	Temperaturas extremas têm que ser específicas da localização.
SEBS	$T_a, z_a, u, T_s,$ R_n, G	1) Incerteza de T_s e variáveis meteorológicas podem ser limitadas e reduzidas; 2) Computa explicitamente a altura da rugosidade para transferência de calor em vez de usar valores fixos.	1) São necessários muitos parâmetros 2) A solução dos fluxos de calor turbulentos é relativamente complexa.
METRIC	$u, z_a, T_s, IV,$ R_n, G	O mesmo que o SEBAL, mas a inclinação e o aspecto da superfície podem ser considerados.	Incerteza na determinação de pixels âncora.
ALEXI	u, z_a, dT_s, F_r ou IAL, R_n, G .	Erros devido a correções atmosféricas e especificação de emissividade de superfície são significativamente reduzidos.	A determinação de um par ótimo de tempos de observação térmica para o aumento linear no aquecimento sensível é necessária.
TSEB	$u, z_a, T_a, T_s, T_c,$ F_r ou IAL, R_n, G	1) Os efeitos da geometria da vista são levados em conta; 2) Correções empíricas para o "excesso de resistência" não são necessárias.	1) Muitas medições de solo são necessárias; 2) Temperaturas dos componentes solo e vegetação são necessários.
Triângulo	R_n, G, T_s, IV	Nenhuma medição terrestre é necessária	1) Difícil de determinar as bordas secas e molhadas; 2) A forma triangular do IV- T_s não é facilmente reconhecida com dados de resolução espacial grosseira.
Trapézio	$T_a, u, T_s, IV,$ R_n, G	Toda a gama de IV e umidade do solo na cena de interesse não é necessária.	1) Incerteza na determinação de bordas secas e molhadas; 2) Muitas medições baseadas em terra são necessárias.

Fonte: Adaptado de LI *et al.* (2009).

A ciência de estimativa de ET apresentou avanços significativos nas últimas décadas. No entanto, segundo Fisher *et al.* (2017), ainda existem desafios que necessitam de soluções científicas como:

- Aumento da acurácia das estimativas em diferentes condições de uso da terra e condições climáticas;
- Aumento da resolução espacial, para detectar variações em superfícies heterogêneas;
- Aumento da resolução temporal, a partir da combinação de imagens multi-sensor;
- Ampliação do domínio espacial dos modelos, correspondendo a um aumento da área de abrangência;
- Monitoramento de longo prazo, para detectar a resposta da vegetação e dos processos hidrológicos às mudanças climáticas.

Um ponto importante das críticas comumente feitas à utilização de dados de sensoriamento remoto é a falta de precisão. Karimi e Bastiaanssen (2015) analisaram 31 publicações de estimativas de ET por sensoriamento remoto, incluindo métodos como SEBAL, METRIC, SEBS, TSEB, ALEXI, ETWatch e SatDAET, totalizando 46 pontos, para análise da acurácia. A distribuição de probabilidade do erro percentual absoluto médio em estimativas de ET por sensoriamento remoto é apresentada na Figura 03.

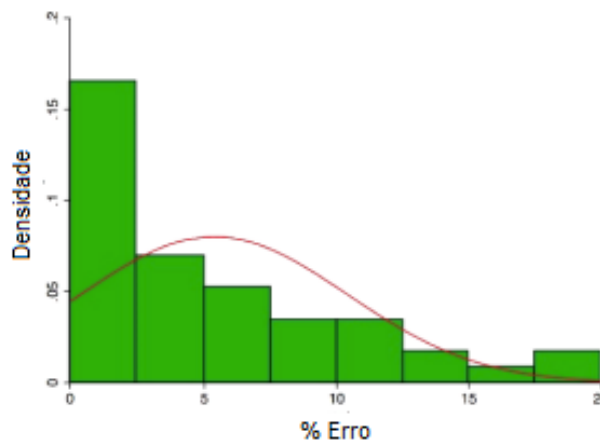


Figura 03. Função de densidade da probabilidade do erro percentual médio absoluto da estimativa de evapotranspiração por sensoriamento remoto.
Fonte: Adaptado de Karimi e Bastiaanssen (2015)

Os resultados demonstraram que o erro absoluto da ET anual ou sazonal varia entre 0 e 20%. Alguns artigos obtiveram uma porcentagem absoluta de erro médio de 1% para terra cultivada, baseados no algoritmo SEBAL e METRIC. Eles concluem que não há um modelo ET único preferido, a sua seleção depende da aplicação, da resolução espacial requerida, do

período para o qual os fluxos de ETs devem ser estimados, do tamanho da área de estudo, das classes de uso da terra presentes, etc. O mais importante é distinguir modelos de escala global e modelos de escala local.

Bhattarai *et al.* (2016) compararam cinco modelos de estimativa de evapotranspiração em um clima subtropical úmido: SEBAL, METRIC, S-SEBI, SEBS, SSEB. Entre os cinco modelos o SEBS apresentou as melhores coberturas de terra, o S-SEBI teve um desempenho ligeiramente melhor do que o METRIC e ligeiramente inferior ao do SEBAL. Quatro dos cinco modelos (METRIC, SEBAL, SEBS e S-SEBI) previram ET diária com boas precisões, enquanto o modelo SSEB obteve erros relativamente grandes. Os autores observaram que a maioria dos modelos SEB funcionam melhor quando a vegetação não está em condições de limitação hídrica e também relataram que estes modelos superestimam a ET da vegetação em condições secas, em razão da maior estimativa de H, em que a maioria dos modelos não considera a influência da umidade do solo.

2.1.3 Escoamento superficial

A detecção remota por satélite do escoamento superficial iniciou a partir de meados de 1990. Os métodos utilizados têm diferentes variantes, no entanto uma abordagem comum é simplesmente correlacionar uma variável hidráulica obtida por sensoriamento remoto, em locais com uma estação de medição, ou perto de uma, com os dados terrestres simultâneos. Semelhante ao método tradicional, porém uma medição é derivada de satélite, normalmente, a área ou largura do fluxo (SMITH e PAVELSKY, 2008).

Métodos para a estimativa de vazão de rios por sensoriamento remoto podem ser classificados em dois tipos: (1) aqueles que utilizam variáveis hidráulicas (largura do canal, elevação da superfície, declive e área transversal) por meio de uma relação de lei de fluxo; e (2) aqueles que acoplam dados de satélite a um modelo hidráulico. Nenhum sensor existente é capaz de medir todas as variáveis hidráulicas desejadas, o que leva a dificuldades em estabelecer uma relação direta entre as variáveis hidráulicas e a vazão do rio, ou a construir um modelo hidráulico do sistema fluvial (YOON *et al.*, 2016).

Segundo Birkinshaw *et al.* (2014), as seguintes variáveis hidráulicas podem ser obtidas por imagens de satélite:

- O nível da água: obtido por medições altimétricas via satélite, proporciona medições temporais discretas do nível da água durante o ciclo de repetição do trajeto do satélite, por exemplo, TOPEX / Poseidon e Jason de 10 dias e ERS2 e

ENVISAT de 35 dias. A missão de satélites *Surface Water e Topography Ocean* (SWOT), projetada para ser lançada em 2021, irá para fazer o primeiro levantamento global das águas superficiais da Terra, melhorando conseqüentemente a cobertura espacial e temporal destas medições;

- A extensão de água superficial e a largura do canal do rio: podem ser obtidas do *Synthetic Aperture Radar* (SAR) ou imagens do visível, como do Landsat, do MODIS a bordo dos satélites Terra e Aqua da NASA e do *Medium Resolution Imaging Spectrometer* (MERIS) a bordo do ENVISAT. Esses dados geralmente possuem uma resolução espacial de 10 a 30 m;
- Declividade longitudinal do canal: obtido a partir da *Shuttle Radar Topography Mission* (SRTM), medidas de satélites de altimetria e futuramente, a partir da missão SWOT.

Vale ressaltar que ao calibrar de forma cruzada dados de diferentes sensores, podem ser alcançados amostragem temporal frequente e estimativa de vazão com maior precisão (BRAKENRIDGE *et al.*, 2005).

A missão SWOT teve como objetivo fazer o primeiro levantamento global das águas superficiais da Terra, observar os detalhes da topografia da superfície do oceano e medir como as massas de água mudam ao longo do tempo em alta resolução espacial. Esta missão está sendo desenvolvido em conjunto pela NASA e pelo *Centre National D'Etudes Spatiales* (CNES) com auxílio da *Canadian Space Agency* (CSA) e da *United Kingdom Space Agency*. O lançamento está previsto para setembro de 2021 (JPL, 2020). O potencial de técnicas espaciais e aerotransportadas para a obtenção de estimativas de vazões de rios tem sido desenvolvido em diversos estudos, usando observações do tipo SWOT de dados atuais de satélite.

A Tabela 04 resume cinco algoritmos propostos utilizando a missão SWOT. Durand *et al.* (2016), ao comparar os cinco algoritmos propostos de estimativa de vazão, obteve que 14 de 16 rios não-trançados obtiveram a Raiz do Erro Quadrático Relativo de 35% do fluxo verdadeiro. Os resultados indicaram que melhorias do algoritmo são necessárias para que um produto robusto de vazão global seja fornecido pela SWOT, visto que nenhum algoritmo único ou sua mediana de conjunto foram executados com resultados consistentemente precisos.

Tabela 04. Resumo de algoritmos de estimativa de vazão.

Algoritmo	Referência	Base teórica	Variáveis Aplicadas de observação	Variáveis estimadas	Método de estimativa da variável
AMHG	Gleason e Smith (2014)	Variáveis geométricas hidráulica de várias estações	Largura da superfície da água	a, b (parâmetros empíricos)	a e b são otimizados para preservar a continuidade entre as estações utilizando um algoritmo genético
GaMo	Garambois e Monnier (2015)	Equação de Manning	Mudança na área de seção transversal do fluxo calculada a partir da largura média e alteração na altura da superfície da água, inclinação da superfície da água para vários pontos	Resistência de fluxo (n) e área de seção transversal do canal no fluxo zero (A_0)	A_0 e n são otimizados para preservar a continuidade entre os alcances observados usando uma otimização não linear de maior inclinação.
MetroMan	Durand <i>et al.</i> , (2014)	Equação de Manning	Mudança na área de seção transversal do fluxo calculada a partir da largura média e alteração na altura da superfície da água, inclinação da superfície da água para vários pontos	Resistência de fluxo (n) e área de seção transversal do canal no fluxo zero (A_0)	A_0 e n são otimizados para preservar a continuidade entre os alcances observados (devem ser três ou mais) usando o algoritmo Metropolis
MFG	Durand, <i>et al.</i> (2016)	Equação de Manning Adaptada	Largura, declive e altura da superfície da água para o ponto	Resistência ao fluxo (n) e altura do fluxo zero (B)	n é estimado a partir de uma relação empírica entre o seu valor médio e a inclinação, e então ajustado com base em uma relação empírica entre a mudança na seção transversal do rio. B é calibrado para uma estimativa do fluxo médio anual para a série temporal
MFCR	Durand, <i>et al.</i> (2016)	Equação de Manning	Largura, declive e altura da superfície da água para o ponto	Área de seção transversal do canal no fluxo zero (A_0)	A resistência ao fluxo é assumida constante em 0,03, uma estimativa da vazão média anual é usada para calibrar A_0 para a série temporal

Fonte: Adaptado de Durand *et al.* (2016).

Cada técnica tem vantagens e limitações. Medições de nível *in situ* podem ser contínuas e precisas, visto que, ao longo de alguns trechos a variação do fluxo no canal ocorre com pouca mudança, e o monitoramento em campo do nível d'água é a melhor abordagem. Em contraste, o sensoriamento remoto é aplicável aos trechos do rio onde as mudanças na área de fluxo são significativas e consistentes ao longo do tempo (BRAKENRIDGE *et al.*, 2007).

A principal dificuldade do uso de dados de satélite para estimar a vazão de rios a partir de sensoriamento remoto é a profundidade batimétrica desconhecida do canal (BIRKINSHAW *et al.*, 2014). Muitos métodos de estimativa de vazão dependem das curvas-chaves empíricas que relacionam medições ocasionais em campo de vazão para outra variável que pode ser monitorada mais facilmente (SMITH e PAVELSKY, 2008). Como as curvas-chaves são específicas do local, elas não podem ser aplicadas em outro lugar, ao longo do mesmo rio ou em outros rios de forma semelhante (BJERKLIE *et al.*, 2003).

Outra possível limitação do uso de sensoriamento remoto na estimativa de vazão é a escala espacial relativamente pequena da largura do rio, ao se usar a área da superfície da água (BJERKLIE *et al.*, 2003). Mudanças significativas na vazão do canal podem produzir mudanças na largura do rio de apenas alguns metros e, os sensores de alta resolução temporal normalmente não fornecem a resolução espacial necessária para medir essas alterações (BRAKENRIDGE *et al.*, 2007). Além disso, problemas com sensores da banda do VIS incluem cobertura de nuvens, e os sensores ópticos também não conseguem obter resposta da superfície da água sob a vegetação em áreas úmidas. Estimativas baseadas na SAR da extensão da água superficial são confusas devido a rugosidade da superfície da água para os comprimentos de onda usados pela maioria dos sensores existentes (ALSDORF, RODRÍGUEZ e LETTENMAIER, 2007).

2.1.4 Armazenamento de água terrestre

O *Gravity Recovery and Climate Experiment* (GRACE) é a primeira missão dedicada a obtenção da gravidade por satélite, patrocinada conjuntamente pela NASA e pelo *Deutsche Forschungsanstalt für Luft und Raumfahrt* (DLR) da Alemanha. O GRACE consiste em duas espaçonaves idênticas que voam a cerca de 220 km entre si de distância em uma órbita polar a 500 km da Terra. O GRACE mapeia o campo gravitacional da Terra fazendo medições precisas da distância entre os dois satélites, usando *Global Positioning System* (GPS) e um sistema de alcance de microondas (NASA, 2012). Mudanças nos campos de gravidade alteram a distância entre as duas naves espaciais, obtendo a medida desta distância, pode-se quantificar anomalias

temporais de S, que consistem na soma das águas superficiais, subterrâneas, umidade do solo, neve/gelo e umidade armazenada na vegetação (RODELL, 2012).

Sua extensão vertical é medida em centímetros de espessura de água equivalente, obtido pelo campo de gravidade da Terra mensal subtraído de uma linha de base média de tempo, assim se obtém a mudança de massa na superfície, em que esta é convertida em espessura de água equivalente, seu método básico é explicado em Wahr, Molenaar e Bryan (1998) (JPL, 2019).

As observações do GRACE foram usadas para inferir a vazão de água doce terrestre, a evapotranspiração, o balanço de massa de mantas de gelo, o balanço hídrico de lagos, além de dados de águas subterrâneas e neve que foram isolados do GRACE usando informações auxiliares. As mudanças de armazenamento baseadas no GRACE estão em concordância com as obtidas de simulações de modelo de superfície terrestre e observações *in situ*. Embora o GRACE tenha apoiado muitos avanços na ciência do ciclo da água, a frequência de produção mensal e a resolução espacial grosseira (~150.000 km²) limitam a utilização de suas observações para a maioria das aplicações que requerem entrada em tempo quase real de dados e uma resolução muito mais fina (HOUBORG *et al.*, 2012). De modo mais recente, os dados do GRACE foram redimensionados para resoluções mais altas por meio de assimilação em modelos de superfície terrestre (ZAITCHIK, RODELL e REICHLE, 2008).

Como o único sistema de sensoriamento remoto capaz de medir mudanças de armazenamento de água em todos os níveis e abaixo da superfície da terra, o GRACE representa um grande avanço na quantificação, compreensão e simulação da variabilidade do S. No entanto, o fato do GRACE medir a água em todas as profundidades simultaneamente é também um desafio, e, como já mencionado, suas resoluções espaciais e temporais são grosseiras para qualquer padrão de dados da ciência da Terra. Por conseguinte, a assimilação de dados mostrou-se muito promissora para uma desagregação vertical, horizontal e temporal efetiva das observações mensais da coluna de água e, portanto, agrega valor a essas observações exclusivas para pesquisa e aplicações (ZAITCHIK, RODELL e REICHLE, 2008).

Wahr, Swenson e Velicogna (2006) analisaram a precisão das estimativas de massa do GRACE, a Figura 04 representa as incertezas ao longo do globo em mm de espessura de água. Os autores observaram que os erros obtidos são quase independentes de longitude, e são menores nos polos (8 mm) do que em baixas latitudes (25-27 mm), em razão, provavelmente, de uma cobertura de terra mais densa perto dos polos. A média global ponderada por área é de 21 mm. Além disso, os erros variam de um mês para outro e de acordo com o tamanho da região de estudo.




Figura 04. Incertezas das estimativas de massa do GRACE, em mm de espessura da água.
Fonte: Adaptado de Wahr, Swenson e Velicogna (2006).

CAPÍTULO 3. ESTRUTURA DO TRABALHO E FLUXOGRAMA DE PROCESSOS

O presente trabalho foi estruturado na forma de artigos científicos. Foram desenvolvidos dois artigos, ambos constituídos pelos seguintes tópicos: introdução, materiais e métodos, resultados e discussão, conclusão e referências bibliográficas.

O primeiro artigo denominado “Estimativa de variáveis hidrológicas em bacias hidrográficas: comparação entre dados observados e obtidos por sensoriamento remoto”, compõe o Capítulo 4. O fluxograma de processos do artigo 1 está expresso na Figura 05, em que foi realizada a coleta de dados *in situ* e de dados de sensoriamento remoto para as bacias hidrográficas de estudo com a finalidade de analisar as similaridades e discrepâncias no comportamento e na quantificação dos conjuntos de dados de cada variável do balanço hídrico a partir de uma análise estatística.

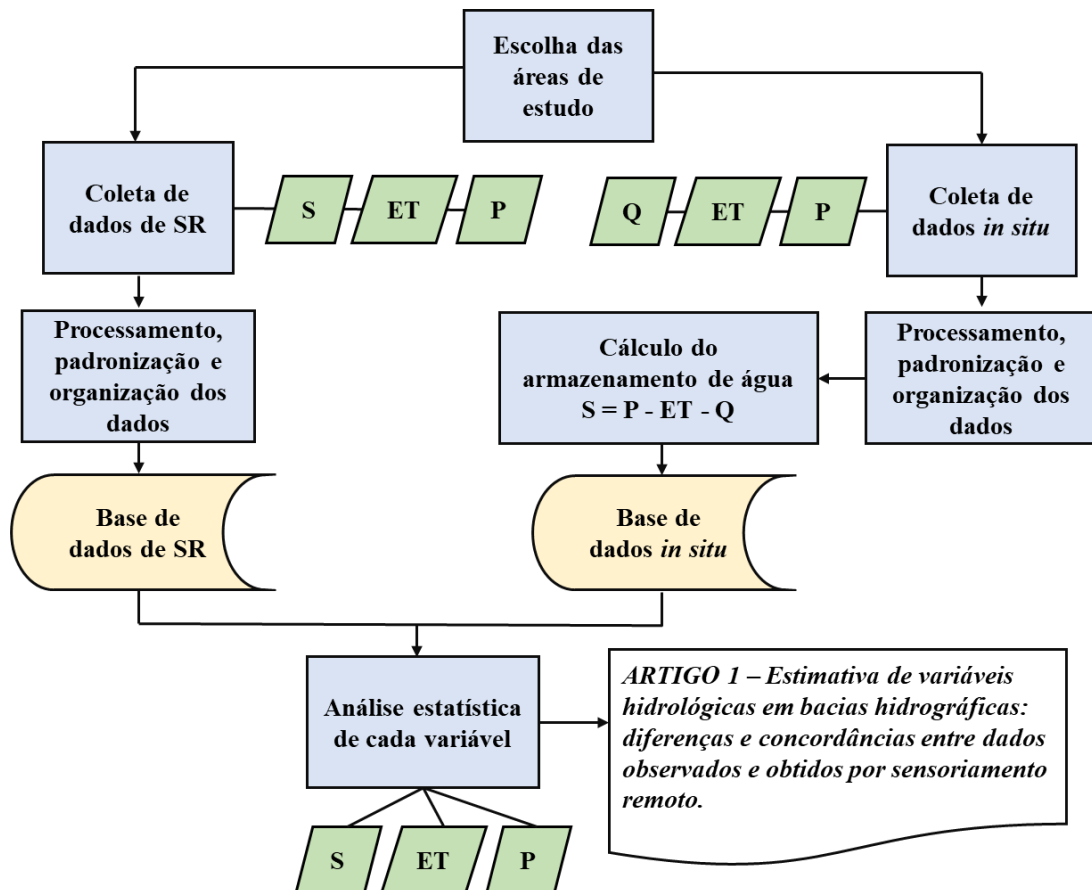


Figura 05. Fluxograma de processos - Artigo 1.

O Capítulo 5 apresenta o artigo 2, intitulado: “Incertezas associadas ao uso do sensoriamento remoto na estimativa do balanço hídrico”. A Figura 06 demonstra os processos realizados no seu desenvolvimento. Realizou-se o cálculo do balanço hídrico mesclando dados

provenientes de sensoriamento remoto e dados *in situ*, a fim de identificar as principais fontes de incertezas e os fatores associados à sua potencialização ou minimização.

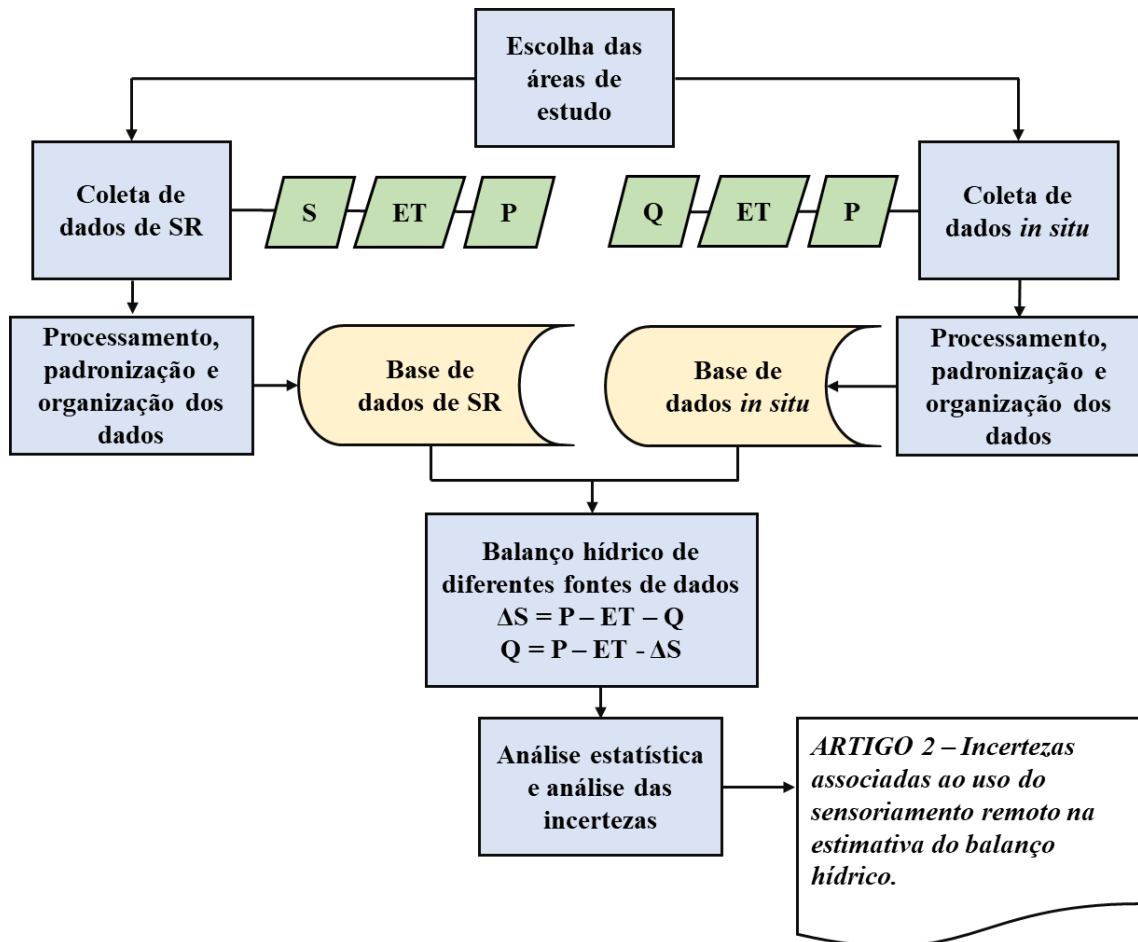


Figura 06. Fluxograma de processos - Artigo 2.

CAPÍTULO 4. ESTIMATIVA DE VARIÁVEIS HIDROLÓGICAS EM BACIAS HIDROGRÁFICAS: COMPARAÇÃO ENTRE DADOS OBSERVADOS E OBTIDOS POR SENSORIAMENTO REMOTO

Pesquisas em Geociências

Data de submissão: 17 de fevereiro de 2020

Autores: Luiza Souza de Paula, Guilherme Garcia de Oliveira

Resumo

O ciclo da água terrestre tem impactos diretos na vida humana. Convencionalmente, as variáveis hidrológicas são estabelecidas por meio de medições *in situ*, no entanto pode se tornar um desafio em regiões do globo com baixa densidade de estações de medição, tornando os dados de sensoriamento remoto uma alternativa atraente. Estes dados estão sujeitos a incertezas e limites que são, por muitas vezes, não quantificados. Desta forma, o objetivo deste trabalho foi identificar as diferenças e concordâncias entre os dados observados e os estimados por sensoriamento remoto das variáveis hidrológicas em bacias hidrográficas. Para isso, selecionou-se dez áreas de estudo com dados de campo disponíveis, em seguida, coletou-se os dados *in situ* e os de sensoriamento remoto, os quais foram processados e organizados. Assim, calculou-se o armazenamento de água terrestre com dados observacionais e, posteriormente, realizou-se a análise estatística de cada variável hidrológica (P, ET e S) através da comparação entre os conjuntos de dados. Para a precipitação, o produto TRMM representou de forma bem verídica o comportamento das chuvas, tanto espacialmente como temporalmente. A respeito dos produtos de evapotranspiração, o MOD16 apresentou pior performance, já o GLDAS e o GLEAM tiveram um desempenho superior e semelhante entre si. Na análise do produto GRACE, os valores não apresentaram uma boa concordância, o que se atribui à escala de tamanho das bacias de estudo. Logo, este trabalho permitiu a detecção das semelhanças e diferenças entre os dados observados e os estimados via sensoriamento remoto, em que se destacou a influência da escala espacial e temporal dos produtos.

Palavras-chave: precipitação, evapotranspiração, armazenamento de água, balanço hídrico, ciclo hidrológico.

Abstract

The water cycle directly affects the human life. Usually hydrological variables are determined by in situ measurements; however that could be a challenge in low density gauging station areas making remote sensing data an interesting alternative. This kind of data are bound to uncertainties and boundaries that commonly non-quantified. The present work aims to identify the differences and agreements between observed and estimated remotely sensed data of hydrological variables in hydrographic basins. Therefore, ten study areas with available field data were selected and their data were collected along with corresponding remote sensing data which were processed and organized. Then, terrestrial water storage data were calculated with observational data and the statistical analysis of each hydrological variable (P, ET, and S) was carried through data set comparison. With regards to precipitation, the TRMM product described with high fidelity the rainfall behavior, both spatially and temporally. As for evapotranspiration products, MOD16 presented the worst performance whilst GLDAS and GLEAM showed better results with similarities between each other. Regarding the GRACE product analysis, results did not show good agreement with in situ data, attributed to the size scale of the studied basins. Hence, the present work allowed the detection of similarities and differences between observed and estimated data via remote sensing, in which highlighted the influence of the product's spatial and temporal scale.

Keywords: Precipitation, evapotranspiration, water storage. water balance, hydrologic cycle.

4.1 INTRODUÇÃO

O ciclo da água terrestre tem impactos diretos na vida humana, visto que ocasiona eventos de inundação e seca, influencia na produtividade agrícola, nos recursos hídricos e na saúde dos ecossistemas. O total de água terrestre consiste em quatro termos principais: a precipitação (P), a evapotranspiração (ET), o escoamento (Q), e o armazenamento de água terrestre (S) (PAN *et al.*, 2012).

A precipitação é provavelmente o parâmetro meteorológico mais desafiador a ser quantificado em virtude da sua variabilidade espacial e temporal. No domínio espacial, ela pode variar ao longo de distâncias muito curtas, tornando os medidores existentes não representativos das áreas circundantes (KIDD, 2001). A ET representa o maior fluxo de saída de água do ciclo hidrológico em escala global, sendo um determinante primário de disponibilidade de água, juntamente com a precipitação (LONG, LONGUEVERGNE e SCALON, 2014). Porém, sua interação complexa com diversos fatores ambientais e climáticos torna a sua quantificação uma

tarefa desafiadora, visto que é uma variável muito dinâmica no espaço e no tempo (IRMAK *et al.*, 2011; BHATTARAI *et al.*, 2016). Medidas de escoamento fluvial são necessárias no gerenciamento de inundação, planejamento de recursos hídricos, estudos de clima e ecologia e cumprimento de acordos de águas transfronteiriços, no entanto, o seu conhecimento é extremamente pobre (VOROSMARTY *et al.*, 2000).

Quantificar os ciclos globais de água e energia terrestre é essencial para melhorar nossa compreensão do sistema climático, incluindo a caracterização das memórias e *feedbacks* entre os principais componentes de água e energia, aperfeiçoando, assim, previsões de tempo e clima em grande escala. É necessário um registro consistente do ciclo da água e suas mudanças ao longo do tempo para melhores estimativas da disponibilidade de recursos hídricos (SAHOO *et al.*, 2011).

Convencionalmente, as variáveis hidrológicas são estabelecidas por meio de medições *in situ*, no entanto pode se tornar um desafio ao analisar regiões do globo com baixa densidade de estações de medição (WANG *et al.*, 2014). Além disso, tais medidas são geralmente pontuais e disponíveis apenas em alguns locais (TANG *et al.*, 2010). Ao mesmo tempo em que há uma baixa densidade de rede de estações de campo hidrometeorológicas, há ausência de conjuntos adequados de dados, os quais apresentam descontinuidades e falhas. A escassez de dados é ainda mais grave em áreas transfronteiriças onde, para além da coleta, a acessibilidade dos dados é prejudicada por questões políticas (AWULACHEW, 2012).

Neste contexto, a utilização de sensoriamento remoto para obtenção de dados hidrológicos é uma alternativa atraente quando comparada aos métodos convencionais de coleta de dados *in situ* (ENGMAN *et al.*, 1991; BASTIAANSEN, MOLDEN e MAKIN, 2000; WAGNER *et al.*, 2009; NEALE e COSH, 2012). Satélites permitem inferir a distribuição espacial das variáveis hidrológicas indiretamente, com alta frequência temporal. Séries temporais de diversas variáveis hidrológicas, como precipitação, evapotranspiração, cobertura de neve, umidade do solo, armazenamento de água de aquíferos podem ser obtidas de bases de dados provenientes de satélites de domínio público (KARIMI e BASTIAANSEN, 2015).

Dados de precipitação podem ser obtidos por meio de métodos que utilizam a faixa do espectro do visível (VIS) e infravermelho (IR) (KAMARIANAKIS *et al.*, 2006), dados de evapotranspiração podem ser categorizados de acordo com a metodologia, os que são estimados a partir da equação do balanço de energia, da equação do balanço hídrico ou de índices de vegetação (AGHAKOUCHAK *et al.*, 2015). Com o lançamento da missão GRACE é possível a medição da variação do armazenamento total de água terrestre derivada da medição de gravidade terrestre (SHEFFIELD *et al.*, 2009).

No entanto, conjuntos de dados de satélite estão sujeitos a incertezas e limites, por muitas vezes não quantificados (PINKER *et al.*, 2009; DORIGO *et al.*, 2010; MEHRAN e AGHAKOUCHAK, 2014). O entendimento das incertezas dos dados de entrada é essencial para avaliação da acurácia de modelos de simulações baseados em informações obtidas por sensoriamento remoto. A falta de informações sobre estes modelos pode impedir a integração de dados de satélite em decisões e aplicações operacionais, sendo necessário dar maior ênfase à caracterização adequada dos pontos fortes e limitações das ferramentas e produtos de sensoriamento remoto, fornecendo os resultados aos responsáveis por tomadas de decisões. Isso vai significar a melhora da usabilidade e aceitabilidade das observações de satélite dentro da comunidade de hidrologia, pois permitirá estabelecer orientações sobre os horários e locais mais apropriados para uso dos dados (AGHAKOUCHAK *et al.*, 2015).

É importante destacar que as medições *in situ* também possuem seus próprios erros e incertezas que devem ser levados em consideração quando usados na verificação da precisão das estimativas baseadas em satélite (KARIMI e BASTIAANSSEN, 2015).

Na quantificação dos erros atrelados aos métodos de estimativa de evapotranspiração faz-se referência aos seguintes estudos: King *et al.* (2011); Kim *et al.* (2012); Wu *et al.* (2012); Long, Longuevergne e Scanlon (2014); Bhattarai, *et al.* (2016); Yang *et al.* (2017); Aguilar *et al.* (2018); Khan *et al.* (2018); Schirmbeck, Fontana e Roberti (2018) e Jamshidi, *et al.* (2019). No que diz respeito à avaliação de produtos de estimativa de precipitação por sensoriamento remoto cita-se: Dinku *et al.* (2007); Asadullah, Mcintyre e Kigobe (2008); Voisin, Wood e Lettenmaier (2008); Stisen e Sanholt (2010); Bitew e Gebremichael (2011); Getirana *et al.* (2011); Nogueira, Moreira e Volpato (2018); Omranian e Sharif (2018); Wu *et al.* (2018); Zeng *et al.* (2018) e Sultana e Nasrollahi (2018). Há também estudos relacionados as incertezas e limitações das estimativas de armazenamento de água terrestre: Strassberg, Scanlon e Chambers (2009); Tang *et al.* (2010); Sahoo *et al.* (2011); Landerer e Swenson (2012); Thomas *et al.* (2014); Paiva e Ruhoff (2017); Brookfield *et al.* (2018) e Tangdamrongsub *et al.* (2018).

Este trabalho traz uma proposta diferente dos demais artigos acima citados por analisar os componentes do ciclo hidrológico de forma espacial, em que se teve como objeto de estudo bacias hidrográficas, ao invés de uma avaliação pontual como comumente é empregada. Desta forma, o objetivo deste trabalho foi identificar as diferenças e concordâncias, entre estimativa de dados observados por estações meteorológicas para bacias hidrográficas e os dados estimados via sensoriamento remoto; no ciclo hidrológico para áreas de diferentes tamanhos, com destaque às suas vantagens, limitações e tendências.

4.2 MATERIAIS E MÉTODOS

4.2.1 Área de estudo

O presente trabalho foi realizado em dez bacias distribuídas nas três regiões hidrográficas (RH) do Rio Grande do Sul. Para seleção das áreas de estudo, primeiramente, analisou-se a disponibilidade de dados de escoamento *in situ* (séries de vazões observadas), visto que estes são os que apresentam maiores problemas de falhas hidrológicas, com muitas lacunas nos registros. Considerou-se também a área de drenagem de cada estação fluviométrica e sua localização, com o objetivo de selecionar pontos bem distribuídos no estado. A Tabela 05 apresenta a lista de estações fluviométricas utilizadas, com código, nome e área de drenagem, obtidas junto ao sistema *Hidroweb* da Agência Nacional de Águas.

Tabela 05. Estações fluviométricas selecionadas para análise dos produtos de sensoriamento remoto.

Código	Nome	Sigla	Área de drenagem (km ²)
88750000	Passo Dos Carros	PDC	131
74460000	Ponte Do Rio Turvo	PRT	502
88575000	Cerro Chato	CCH	1.050
86500000	Passo Carreiro	PCA	1.820
75295000	Colônia Mousquer	CMO	2.160
87170000	Barca Do Caí	BCA	3.030
75230000	Santo Ângelo	SAN	5.440
85642000	Passo São Lourenço	PSL	27.300
74100000	Iraí	IRA	61.900
74800000	Porto Lucena	PLU	95.200

Fonte: Autor

Na Figura 07 visualiza-se as bacias hidrográficas de estudo. A partir destas estações foram extraídas as bacias hidrográficas no *software* ArcGIS. Para tal procedimento, realizou-se uma série de etapas, as quais estão expostas no Quadro 01. Para o desenvolver desse procedimento foi necessário o auxílio de um *shapefile* dos pontos das estações fluviométricas selecionadas e um Modelo Digital de Elevação (MDE). O MDE foi obtido da missão *Shuttle Radar Topography Mission* (SRTM), com resolução espacial de aproximadamente 90 m (FARR *et al.*, 2007). Esta missão é liderada pela Agência Nacional de Inteligência Geoespacial e pela *National Aeronautics and Space Administration* (NASA), e teve como intuito obter uma base de dados topográfica digital de alta resolução da Terra, seus dados têm acesso gratuito e sua cobertura abrange as latitudes 60° Norte e 56° Sul.

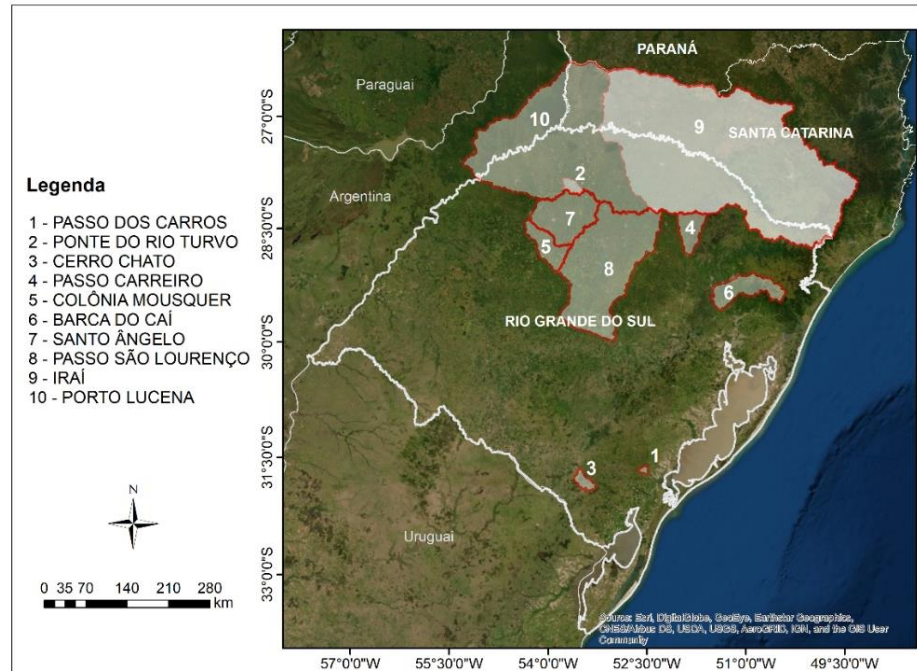


Figura 07. Bacias de estudo com diferentes áreas de drenagem. Fonte: Autor

Quadro 01. Metodologia aplicada para extração de bacias hidrográficas.

Etapas	Ferramenta	Como Funciona	Referência Bibliográfica
1	<i>Fill</i>	Preenche vales e picos em uma varredura de superfície para remover pequenas imperfeições nos dados.	Greenlee (1987); Jenson e Domingue (1988); Tarboton, Bras e Rodriguez-Iturbe (1991); Planchon e Darboux (2002).
2	<i>Flow Direction</i>	A partir de uma superfície gera uma varredura de direção do fluxo de cada célula.	
3	<i>Flow accumulation</i>	Calcula o fluxo acumulado através do peso acumulado de todas as células que fluem para uma célula descendente.	
4	<i>Snap Pour Point</i>	Aponta para a célula de maior acumulação de fluxo dentro de uma distância especificada.	
5	<i>Watershed</i>	Determina a área de contribuição acima de um conjunto de células em uma varredura.	
6	<i>Raster to polygon</i>	Converte um conjunto de dados raster em polígono.	

4.2.2 Coleta de dados

Foram obtidos dados observados de precipitação (estações pluviométricas), evapotranspiração (estações meteorológicas) e escoamento (estações fluviométricas), além de dados estimados por sensoriamento remoto de precipitação, evapotranspiração e armazenamento de água terrestre. O período de análise foi entre 2000 e 2018, em função da

maior cobertura de dados de sensoriamento remoto. As séries foram discretizadas no intervalo de tempo mensal.

As vazões observadas em cada bacia hidrográfica foram utilizadas para o cálculo do armazenamento de água terrestre a partir de dados das estações instaladas *in situ*, por meio da Equação 02, a fim de realizar a comparação com o produto sensoriamento remoto.

$$\Delta S = P - ET - Q \quad (02)$$

Em que: ΔS é a variação do armazenamento de água terrestre mensal calculada; P é a precipitação observada nas estações pluviométricas na área da bacia; ET é a evapotranspiração observada na bacia; e Q é o escoamento observado na estação fluviométrica.

4.2.2.1 Dados observados nas estações

Os dados de precipitação mensal foram obtidos do sistema *Hidroweb* para os estados do Rio Grande do Sul e Santa Catarina, das estações pluviométricas a partir do ano de 2000, num total de 450 estações. Foram organizados com o auxílio dos *softwares Microsoft Office Excel e Matlab*. Foi realizada a uma interpolação dos valores de precipitação a partir do método do inverso do quadrado da distância para uma malha de pontos distribuídos com equidistância de 20 km. Após atribuído o valor de precipitação mensal para cada ponto, foi realizada uma média dos valores dos pontos em cada bacia de estudo, para cada mês. A Tabela 06 especifica a quantidade de estações pluviométricas presentes em cada bacia. Apesar da bacia Passo dos Carros não possuir estação com dados de chuva no seu interior, a estação pluviométrica mais próxima fica situada a 12,6 km e o processo de interpolação foi realizado normalmente para os pontos da grade que interseccionavam com a área da bacia.

Tabela 06. Quantidade de estações pluviométricas por bacia de estudo.

Bacia de Estudo	Nº de estações dentro da bacia de estudo
PDC	0
PRT	1
CCH	2
PCA	5
CMO	2
BCA	4
SAN	9
PSL	14
IRA	70
PLU	97

Os dados de evapotranspiração mensal foram obtidos do sistema Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) do Instituto Nacional de Meteorologia (INMET). Devido à baixa disponibilidade destes dados, com apenas 22 estações espalhadas pelo Rio Grande do Sul e Santa Catarina, procedeu-se da seguinte forma: para as bacias com mais de uma estação dentro de sua área, realizou-se as médias dos valores; para as bacias menores sem estações em sua abrangência, utilizou-se os dados da estação mais próxima..

O Quadro 02 traz informações sobre as estações meteorológicas utilizadas para obtenção de dados de evapotranspiração *in situ*.

Quadro 02. Estações das quais foram obtidos os dados de evapotranspiração.

Bacia de Estudo	Nº de estações dentro da bacia de estudo	Distância da estação mais próxima (km)	Estações meteorológicas utilizadas
PDC	0	18,15	Pelotas
PRT	0	76,6	Cruz Alta
CCH	0	81,4	Bagé
PCA	0	47	Lagoa Vermelha
CMO	0	41,8	Cruz Alta
BCA	0	25,7	Caxias Do Sul
SAN	1	-	Cruz Alta
PSL	2	-	Santa Maria, Cruz Alta
IRA	7	-	Passo Fundo, Lagoa Vermelha, Irai, São Joaquim, Lages, Campos Novos, Chapecó.
PLU	7	-	Passo Fundo, Lagoa Vermelha, Irai, São Joaquim, Lages, Campos Novos, Chapecó.

No entanto, os dados destas estações apresentavam descontinuidades, desta forma para completar a série histórica aplicou-se o método de estimativa de evapotranspiração de Thornthwaite, o qual utiliza apenas como dado de entrada a temperatura média mensal.

O conjunto de equações desenvolvido por Thornthwaite foi baseado em balanço hídrico de bacias hidrográficas e em medidas de evapotranspiração realizadas em lisímetros. A evapotranspiração potencial média mensal padrão (ETPp, mm.mês') é obtida por meio das Equações 03, 04 e 05.

$$ETPp = 16 \left(\frac{10 Ti}{I} \right)^a \quad (03)$$

$$a = 6,75 \cdot 10^{-7} I^3 - 7,71 \cdot 10^{-5} I^2 + 1,7912 \cdot 10^{-2} I + 0,49239 \quad (04)$$

$$I = \sum_{i=1}^{12} (0,2 Ti)^{1,514} \quad (05)$$

Em que: T_i é a temperatura média mensal ($^{\circ}\text{C}$); e I é o índice de calor da região que deve ser calculado com valores normais (média climatológica); i representa o mês do ano (exemplo: para janeiro, $i = 1$).

Para aplicação de tal método, utilizou-se os dados de temperatura média mensal das estações meteorológicas, porém também havia deficiência de dados, de maneira que foi necessário empregar valores de ET de normais climatológicas oriundas do INMET nos meses faltantes.

Os dados de escoamento foram obtidos a partir do *software* Hidro 1.3 e exportados para o *Microsoft Office Excel*. A bacia Iraí possuía alguns meses sem medidas, portanto procedeu-se o preenchimento destes valores da seguinte forma: calculou-se a proporção de escoamento em relação ao escoamento médio histórico do mês de análise nas bacias vizinhas, em seguida obteve-se a média dessas proporções e aplicou-se este valor sobre a normal climatológica do mês com falha.

4.2.2.2 Dados de sensoriamento remoto

Para obtenção dos dados de precipitação por sensoriamento remoto, optou-se pelas imagens do satélite *Tropical Rainfall Measuring Mission* (TRMM). O produto utilizado foi o TRMM 3B43, uma estimativa de precipitação com resolução espacial de $0,25^{\circ} \times 0,25^{\circ}$ (cerca de 27,8 km) e resolução temporal de 1 mês (TRMM, 2011), em mm/h no seguinte endereço: <<https://disc.gsfc.nasa.gov/>>.

Os dados de armazenamento de água terrestre foram obtidos do *Gravity Recovery and Climate Experiment* (GRACE). O produto utilizado foi o “*JPL TELLUS GRACE Level-3 Monthly LAND Water-Equivalent-Thickness Surface-Mass Anomaly Release 6*”, o qual fornece as anomalias de massa de água terrestre mensais expressas como espessura de água equivalente provenientes das observações da variação de gravidade no tempo do GRACE (FELIX LANDERER, 2019). Sua resolução espacial é de $1^{\circ} \times 1^{\circ}$ com unidade de mm/h, acessíveis no site: <<https://podaac.jpl.nasa.gov/>>.

Para estimativa de evapotranspiração por sensoriamento remoto selecionou-se três produtos mensais: *MODIS global terrestrial evapotranspiration algorithm* (MOD16) (MU, ZHAO e RUNNING, 2013); *Global Land Data Assimilation System* (GLDAS) (RODELL *et al.*, 2004); e *Global Amsterdam Evaporation Land Model* (GLEAM) (MARTENS *et al.*, 2017).

O produto de evapotranspiração utilizado MOD16A2 versão 5, proveniente do instrumento *Moderate Resolution Imaging Spectroradiometer* (MODIS) a bordo dos satélites

Terra e Aqua, é disponibilizado pelo *Numerical Terradynamic Simulation Group* no seguinte endereço: <<https://www.ntsg.umt.edu/project/modis/mod16.php>> para o período de 2000 a 2014. Possuem resolução espacial de 1 km e resolução temporal de 8 dias, mensal e anual, no formato hdf para os grânulos h13v11 e h13v12.

O produto utilizado do projeto GLDAS foi o *GLDAS Noah Land Surface Model L4 monthly 0.25 x 0.25 degree Version 2.0*, o qual fornece dados meteorológicos de superfície modelados em uma grade de 0.25° x 0.25° a partir de janeiro de 2000, no site da NASA: <<https://search.earthdata.nasa.gov/search>> em formato NetCDF com valores em kg/m²/s.

O GLEAM é um conjunto de algoritmos que estimam separadamente os diferentes componentes da evaporação do solo: transpiração (Et), sublimação de neve (Es), perda por interceptação (Ei), evaporação (Eb) e sublimação em águas abertas (Ew). Fornecidos em uma grade de latitude-longitude de 0,25 ° x 0,25 ° e com uma resolução temporal diária, os quais são agregados em mensais e anuais. Disponíveis em <<https://www.gleam.eu/>> e organizados em arquivos NetCDF.

O produto utilizado foi o GLEAM v3.3a: conjunto de dados global que abrange o período de 39 anos 1980–2018. O valor extraído foi Evapotranspiração real (E) em mm/mês que corresponde a Equação 06.

$$E = Et + Eb + Ew + Ei + Es \quad (06)$$

Estes produtos mensais de sensoriamento remoto passaram por uma série de processamentos, extraída a média dos valores dos pixels para cada área de estudo para cada mês no *software* ArcGIS e transformados em mm/mês no *Microsoft Office Excel*.

4.2.3 Análise estatística

Para analisar a capacidade dos produtos de sensoriamento remoto de replicarem a variabilidade e a quantificação mensal e anual das variáveis do ciclo hidrológico, realizou-se uma análise estatística dos dados, em que se calculou índices de comparação entre os conjuntos de valores estimados e os observados.

Inicialmente, obteve-se o Erro Absoluto Médio, que corresponde à diferença entre a variável estimada e a observada por mês, a Raiz do Erro Quadrático Médio que elimina a existência de números negativos e informa a precisão e a acurácia das estimativas e o Erro

Relativo Médio que é o quociente entre o erro absoluto e o valor observado, expresso em percentual. Estes indicadores são obtidos pelas Equações 07, 08 e 09.

$$EA = \frac{1}{n} \sum |X_{est} - X_{obs}| \quad (07)$$

$$REQM = \sqrt{\frac{1}{n} \sum (X_{est} - X_{obs})^2} \quad (08)$$

$$ERM = \frac{1}{n} \sum \frac{|X_{est} - X_{obs}| \cdot 100}{X_{obs}} \quad (09)$$

Em que: EA = erro absoluto médio; REQM = Raiz do Erro Quadrático Médio; n = número de meses analisados; X_{est} = variável estimada; X_{obs} = variável observada.

Obteve-se o índice de concordância (d) proposto por Wilmott para identificar o grau de concordância entre o valor observado e sua estimativa (KRAUSE *et al.*, 2005), quanto mais próximo de 1, melhor a exatidão do desempenho do modelo em prever a variável dependente (AIRES, NETO e DE MELLO, 2017) e o coeficiente de correlação linear de Pearson (r), que mede a relação entre duas variáveis quantitativas e exprime o grau de correlação por meio de valores situados entre -1 e 1. Estes índices são calculados pelas equações 10 e 11.

$$d = 1 - \left[\frac{\sum (X_{est} - X_{obs})^2}{\sum (|X_{est} - \bar{X}_{obs}| + |X_{obs} - \bar{X}_{obs}|)^2} \right] \quad (10)$$

$$r = \frac{\sum (X_{est} - \bar{X}_{est}) \cdot (X_{obs} - \bar{X}_{obs})}{\sqrt{\sum (X_{est} - \bar{X}_{est})^2 \cdot \sum (X_{obs} - \bar{X}_{obs})^2}} \quad (11)$$

Em que: \bar{X}_{obs} = média dos valores observados; \bar{X}_{est} = média dos valores estimados.

Para o armazenamento de água terrestre, calculou-se o coeficiente Nash-Sutcliffe (E), que é amplamente utilizado no setor de recursos hídricos para avaliar o desempenho de um modelo hidrológico (Equação 12) e o valor da diferença do volume total ($\neq Vt$) para quantificação do erro para todo o período de análise (Equação 13).

$$E = 1 - \left[\frac{\sum (\Delta S_{obs} - \Delta S_{est})^2}{\sum (\Delta S_{obs} - \overline{\Delta S_{obs}})^2} \right] \quad (12)$$

$$\neq Vt = \sum \Delta S_{est} - \sum \Delta S_{obs} \quad (13)$$

Em que: ΔS_{est} = armazenamento de água terrestre estimado; ΔS_{obs} = armazenamento de água terrestre observado, $\overline{\Delta S_{obs}}$ = média dos valores observados.

4.3 RESULTADOS E DISCUSSÃO

4.3.1 Precipitação

A série anual de precipitação estimada pelo satélite TRMM e a precipitação observada nas bacias a partir da interpolação de dados das estações pluviométricas, são observadas na Figura 08. Nota-se, que a estimativa por sensoriamento remoto apresenta um comportamento similar aos dados observados, no entanto na maioria dos anos há uma superestimativa dos valores de precipitação. Esta afirmativa fica evidente ao visualizarmos a Figura 09, em que a bacia Passo Carreiro ficou 12,2 % acima da média anual de precipitação e a bacia Porto Lucena 11,8%. As demais variaram entre 6% e 7%, com exceção de Passo dos Carros e Colônia Mousquer que obtiveram valores menores, de 1,3% e 3,6%, respectivamente. Não é possível identificar uma razão para essas diferenças, seja por localização, seja por escala espacial.

Asadullah, McIntyre e Kigobe (2008) ao avaliar o produto TRMM em Uganda, relataram que o mesmo não possuía viés (tendência do produto de reportar maior ou menor total de precipitação média anual) significativo para região do Lago Victoria, no entanto para a região central reportam totais de chuvas ligeiramente superiores aos medidos, cerca de 5%. Bernardi (2016) também verificou em Uruguaiana e Caxias do Sul no estado do Rio Grande do Sul uma superestimativa dos valores estimados, o primeiro em 12,3% e o segundo em 5,5% do total precipitado.

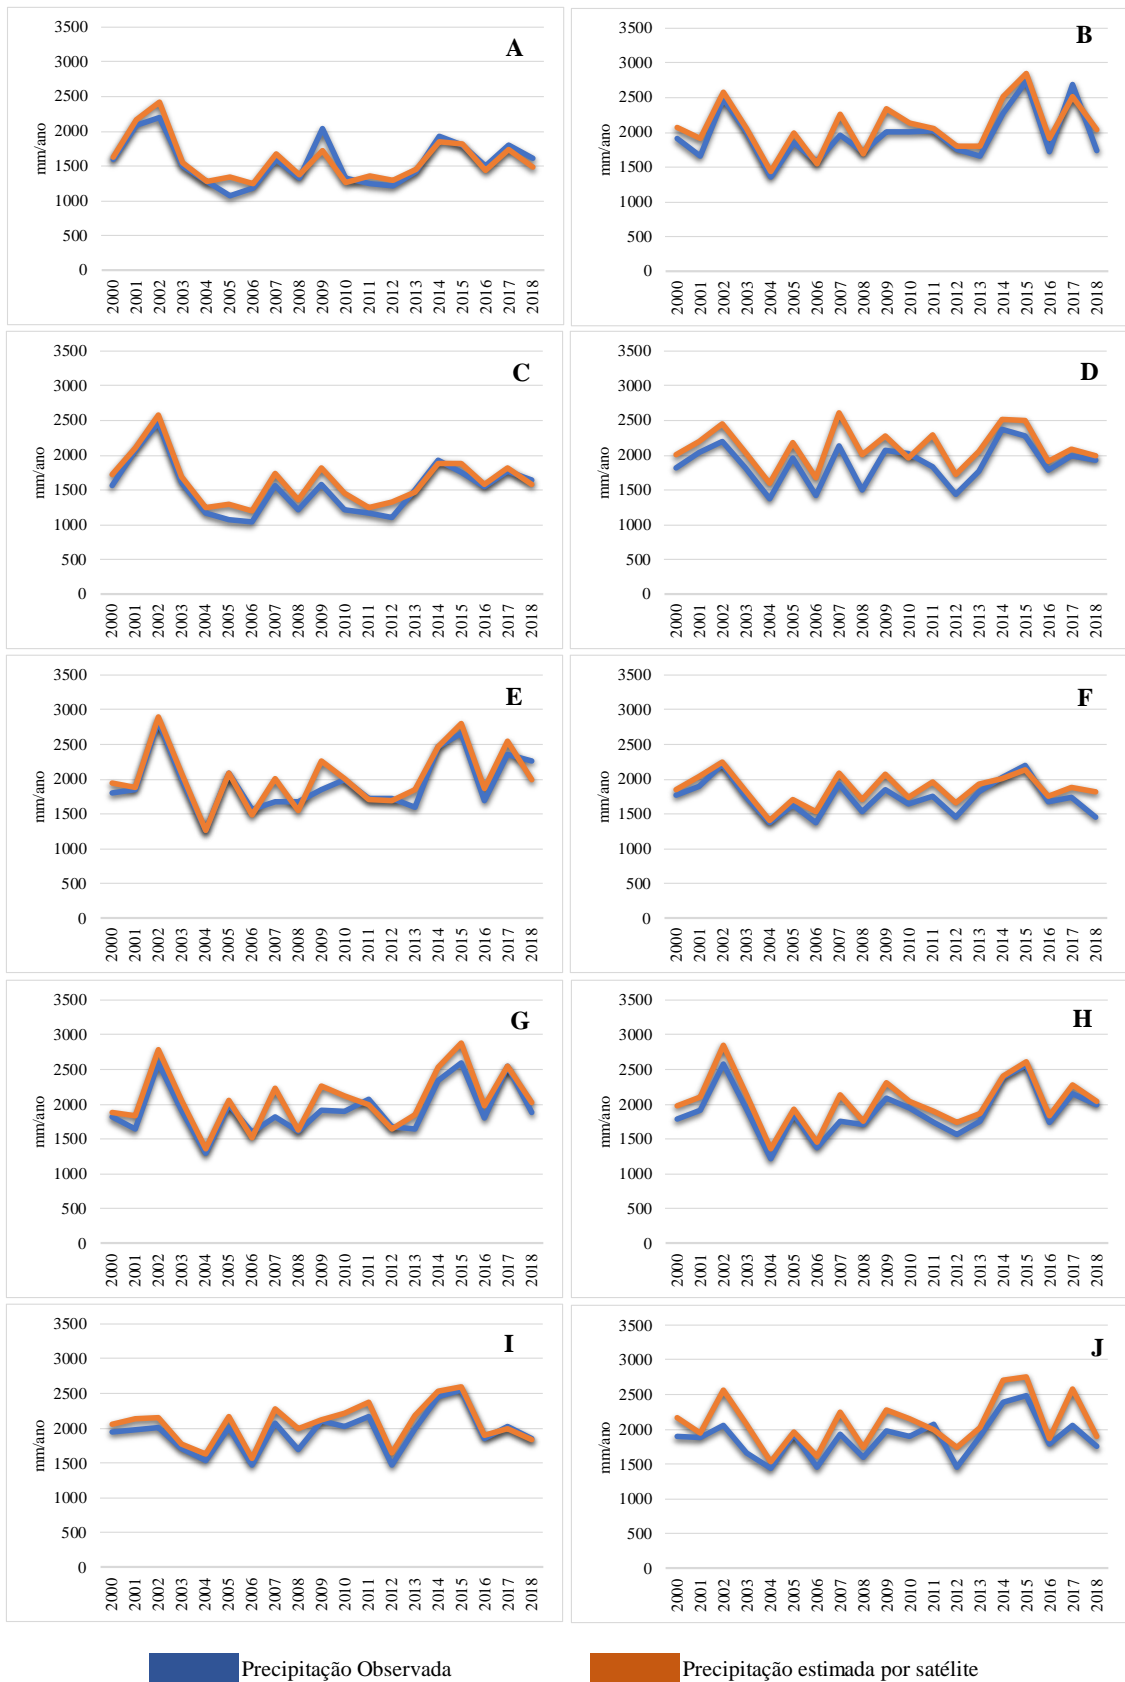


Figura 08. Precipitação anual estimada por sensoriamento remoto e observada para cada bacia de estudo. A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.




Figura 09. Precipitação média anual observada e estimada por satélite.

A Figura 10 mostra os valores de precipitação média trimestral e anual para o período entre 2000 e 2018 dos dados interpolados e dos dados do satélite TRMM, assim como o mapa diferença. Nesta, confirma-se a capacidade do satélite de replicar estes valores de forma espacial, apesar de se evidenciar uma superestimativa dos dados na maioria do estado quando analisado o mapa diferença, o comportamento das chuvas é reproduzido de forma excelente, sendo possível identificar o padrão sazonal desta variável mesmo que em intervalos maiores de tempo.

O gráfico de dispersão dos dados de precipitação anual observados e estimados por satélite para cada bacia e suas respectivas equações da reta, Figura 11, mostra a tendência de cada conjunto de valores. Vale ressaltar que quanto mais próximo da reta ideal, menor a existência de tendência nos dados, sendo que com o coeficiente angular próximo a 1 e o coeficiente linear próximo a zero melhor o desempenho da estimativa. Para todas as bacias de estudo o coeficiente angular apresenta valores de moderados a bons, porém no coeficiente linear há uma maior amplitude, com valores muito baixos de 2,39 na bacia Ponte do Rio Turvo até 369,75 na bacia Porto Lucena.

O melhor desempenho evidencia-se a bacia Passo dos Carros com uma diferença de coeficiente angular da reta ideal de apenas 0,0342 e, em segundo, a bacia Cerro Chato com 0,0443, porém seu coeficiente linear é maior. As piores performances foram identificadas nas bacias Porto Lucena e Passo Carreiro, com tendências lineares bem diferentes da reta ideal, a primeira com um problema na sua angulação e a segunda com um distanciamento da reta ideal.

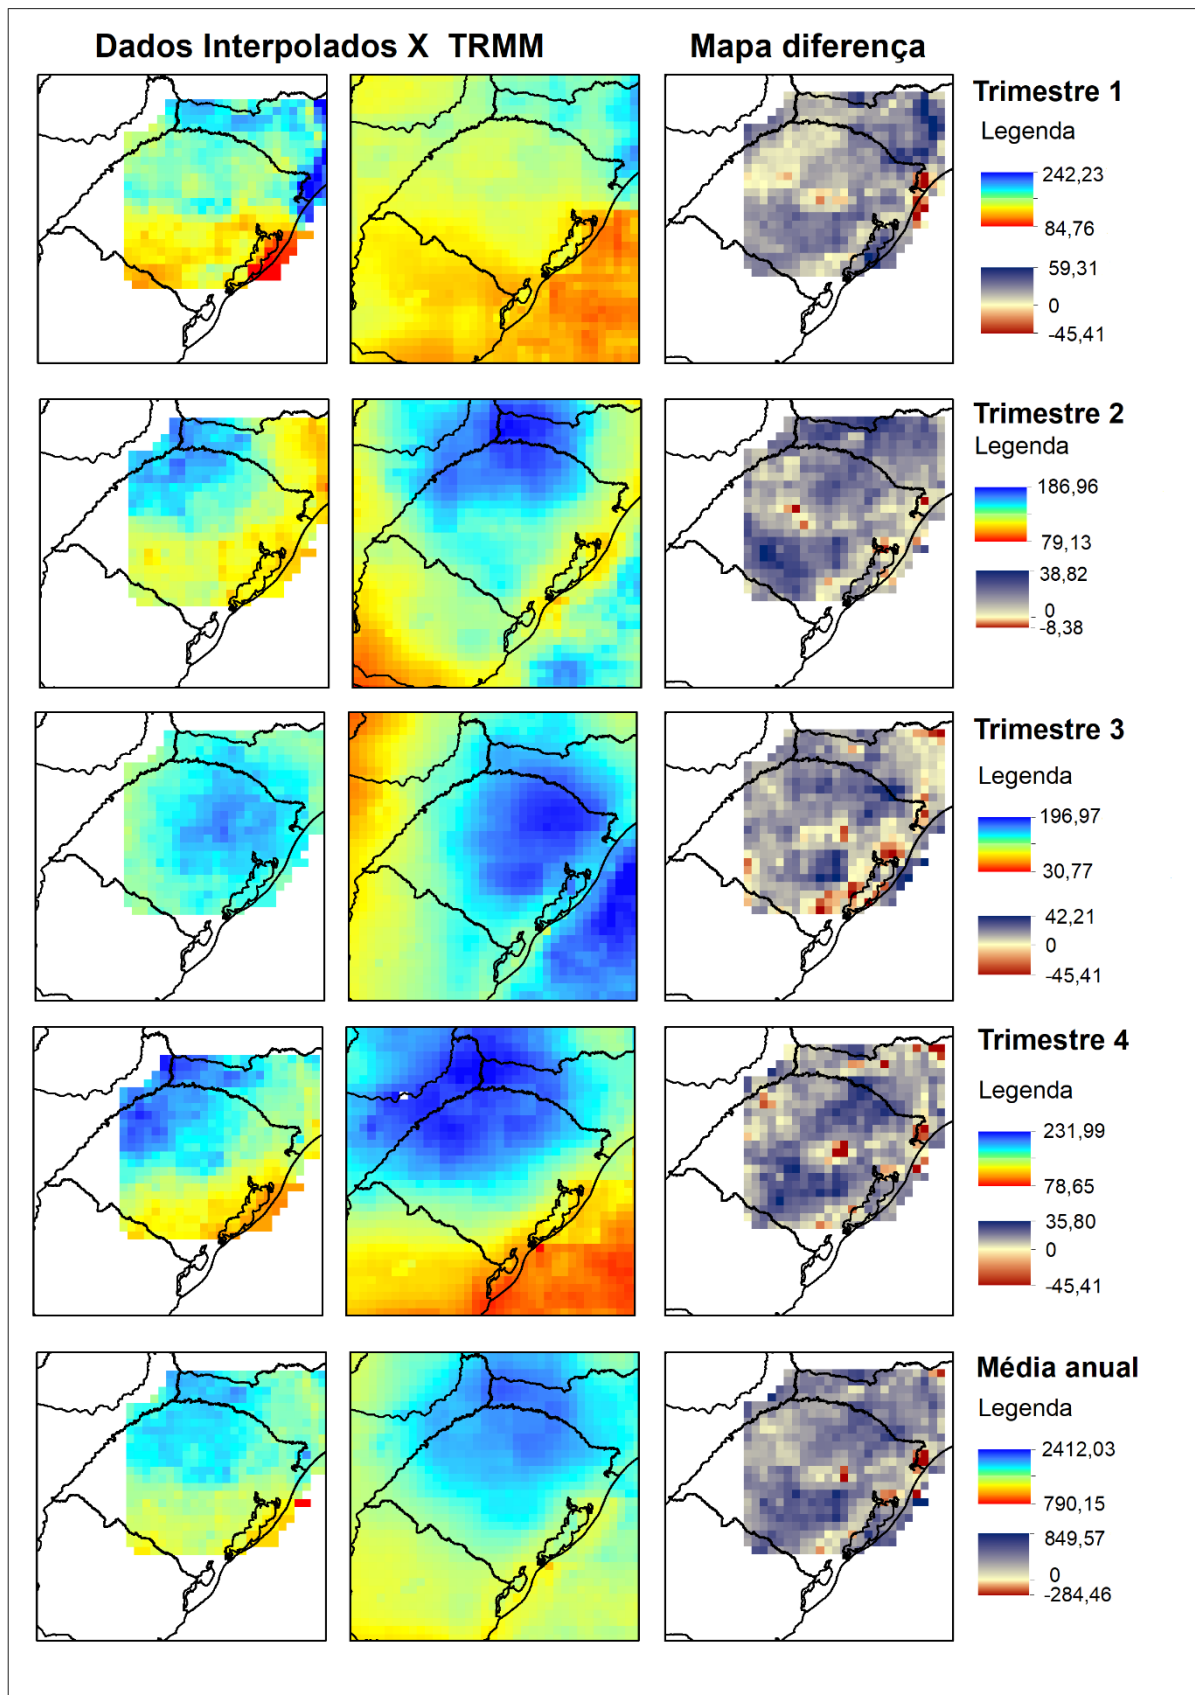


Figura 10. Médias trimestrais e anuais para o período de 2000 a 2018 a partir de dados interpolados e dados TRMM e mapa diferença.

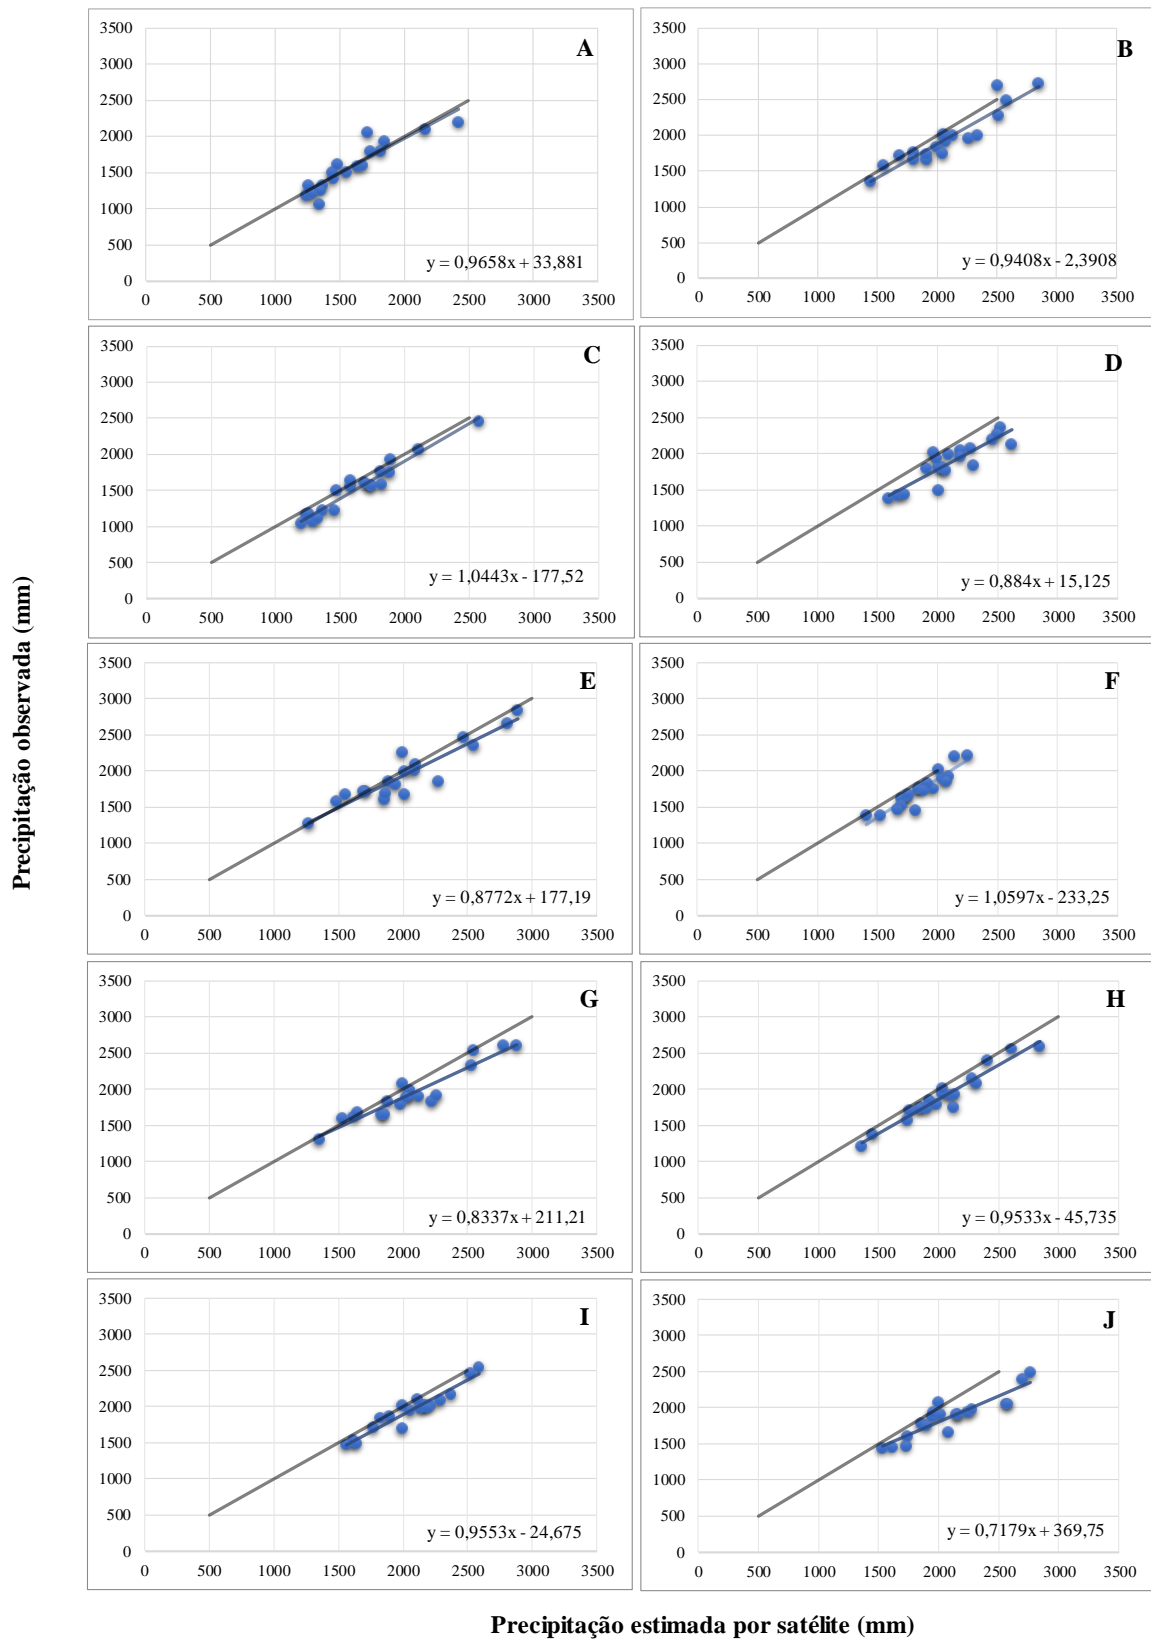


Figura 11. Gráfico de dispersão da precipitação anual para cada bacia de estudo, no período entre 2000 e 2018.

A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.

Com exceção das bacias Barca do Caí e Cerro Chato, todas apresentaram coeficientes angulares menores que 1, ou seja, para valores observados mais elevados havia maior superestimativa, dando destaque para as bacias Santo Ângelo e Porto Lucena que apresentaram as maiores tendências, visto que seus coeficientes angulares estão mais distantes de 1, com 0,83 e 0,71, respectivamente. Vale ressaltar que bacias como Cerro Chato, Barca do Caí, Passo São Lourenço e Iraí demonstram um paralelismo com a reta ideal, apresentando um viés uniforme nos dados de precipitação por satélite.

A Figura 12 demonstra o gráfico de dispersão dos dados mensais observados e estimados por satélite para cada bacia. Ao comparar com os gráficos anuais, os dados mensais demonstraram uma performance superior, em que as funções lineares estão muito próximas da reta ideal, com coeficientes lineares baixos, entre 1,14 e 26,84 e coeficientes angulares próximos a 1, entre 0,74 e 0,97. Os piores valores para ambos coeficientes foram identificados na bacia Porto Lucena.

Com maior proximidade da reta ideal destaca-se a chuva estimada por satélite para a bacia Iraí, seguido de Colônia Mousquer e Passo São Lourenço. As bacias de pior capacidade de reprodução dos dados foram Porto Lucena, Cerro Chato e Passo Carreiro. Em Cerro Chato, os dados de sensoriamento remoto apresentaram uma performance muito boa em uma análise anual, no entanto em escala mensal seu desempenho foi reduzido. Nas três piores bacias hidrográficas, notou-se maiores superestimativas das precipitações de valores mais elevados, o que concorda com Nastos, Kapsomenakis e Philandras (2016) que ao avaliar o produto TRMM 3B43 sobre o território da Grécia concluíram que o satélite tem um desempenho ruim na estimativa de totais mensais altos de precipitação sobre a região grega.

Percebe-se que o satélite TRMM replica de forma satisfatória o comportamento da precipitação, em que as normais mensais do período de análise das bacias demonstraram um padrão muito similar aos dados observados, sendo capaz de reproduzir padrões sazonais em escala mensal (Quadro 03), o que também foi verificado por Asadullah, McIntyre e Kigobe (2008) ao analisar cinco produtos de estimativa de precipitação por sensoriamento remoto.

O Quadro 04 apresenta os índices estatísticos calculados do produto TRMM se comparado com os dados *in situ* para uma escala mensal e anual. Em geral, a estimativa de precipitação por sensoriamento remoto obteve um desempenho muito satisfatório. O coeficiente de correlação, tanto em escala mensal como em escala anual, demonstrou valores altos, maiores que 0,86 e 0,88, respectivamente. No que concerne ao índice de concordância também apresentou uma performance ótima, acima de 0,92 para os dados mensais e acima de 0,81 para

os anuais. Além de baixos erros absolutos médios entre 20 e 30 mm por mês, comprovando a precisão deste produto em estimar a precipitação.

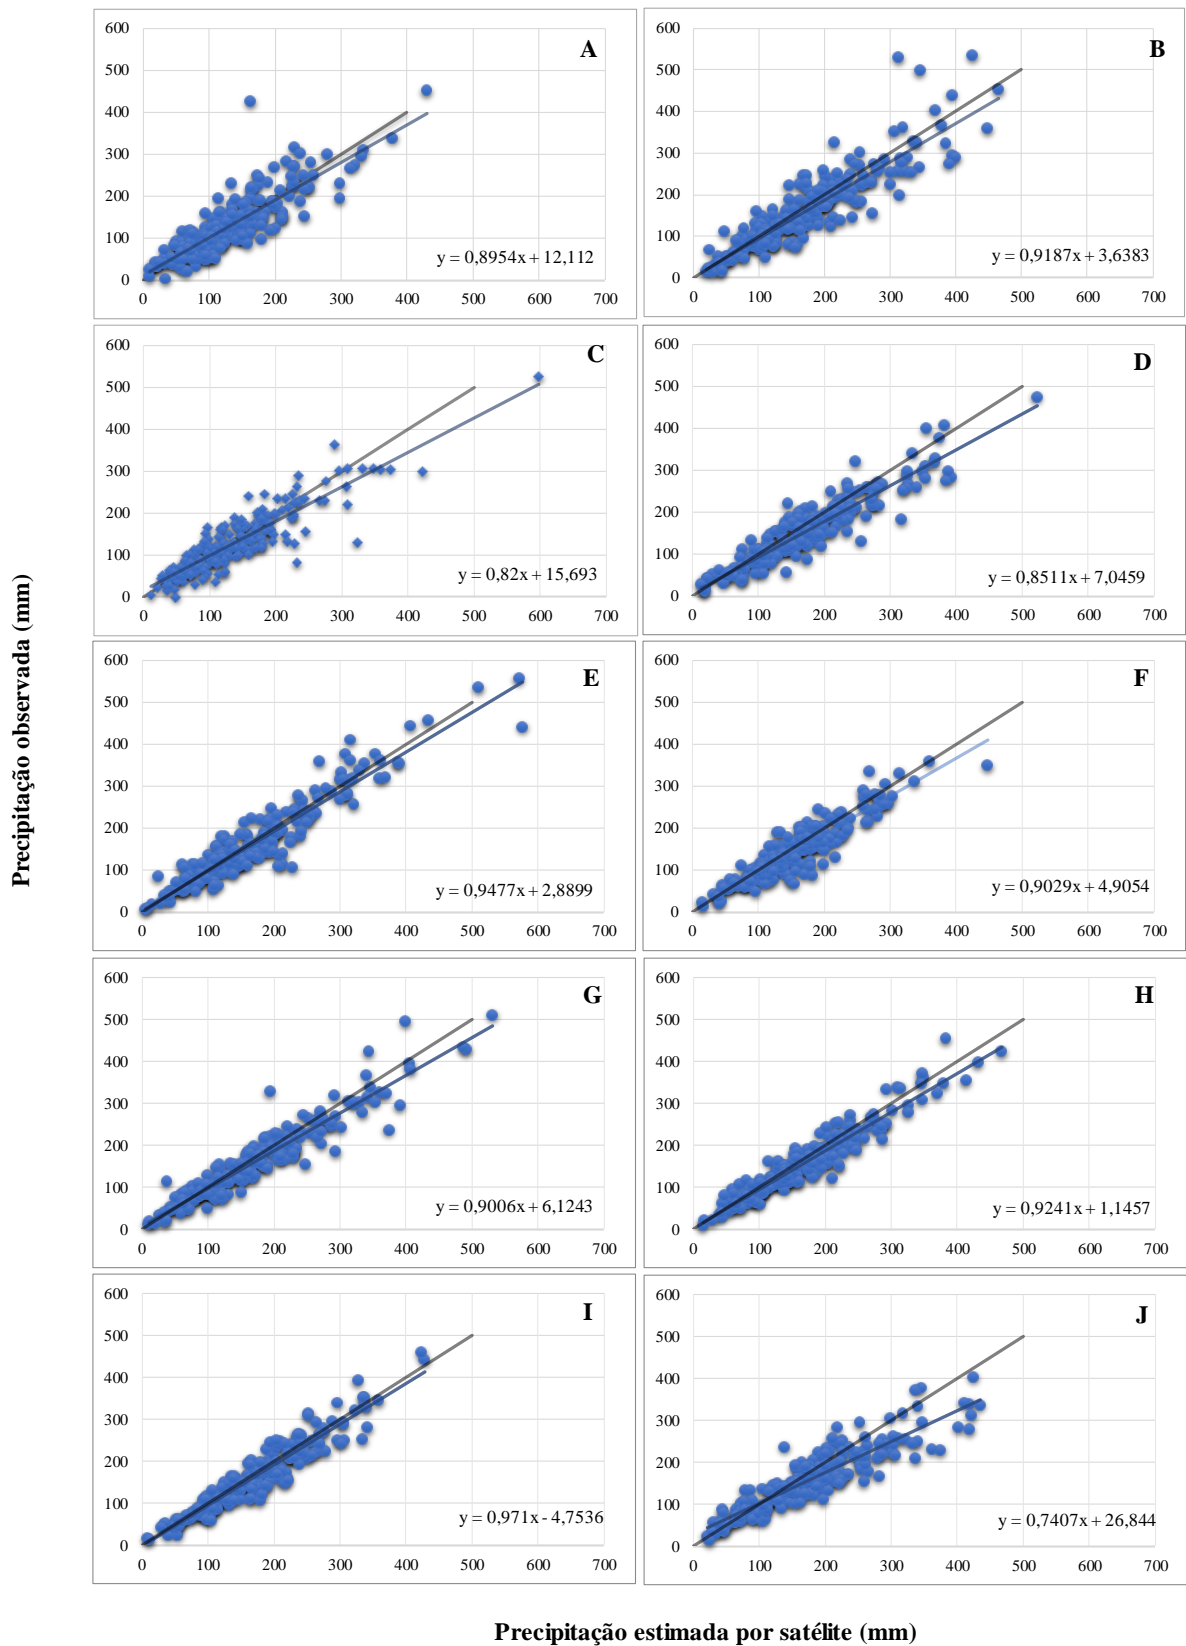


Figura 12. Gráfico de dispersão da precipitação mensal para cada bacia de estudo, no período entre 2000 e 2018. A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.

Quadro 03. Normais mensais de 2000 a 2018 observada e estimada para as bacias hidrográficas.

Precipitação observada										
Mês	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
Janeiro	131,53	167,60	116,56	153,14	171,73	156,19	170,43	163,08	173,84	171,34
Fevereiro	144,73	130,16	119,95	141,31	121,48	137,26	122,93	135,53	150,21	141,02
Março	132,14	146,73	123,27	130,65	150,67	137,58	147,42	142,53	146,32	141,80
Abril	129,19	167,60	127,70	138,62	165,94	119,10	162,90	147,48	145,08	142,24
Mai	125,31	159,66	128,94	138,89	148,10	124,12	154,17	139,06	153,83	146,85
Junho	118,41	162,48	123,59	153,34	152,87	130,96	154,24	148,39	156,40	147,62
Julho	116,29	139,59	112,00	160,77	136,06	162,17	139,22	157,45	137,04	130,92
Agosto	128,99	120,17	126,54	133,56	116,58	130,23	122,07	125,24	120,51	116,43
Setembro	168,96	148,05	155,24	194,59	169,22	170,63	155,32	184,23	182,65	172,94
Outubro	143,08	254,94	153,01	227,44	255,09	192,52	247,60	230,61	237,56	229,46
Novembro	118,83	174,13	130,55	147,04	174,81	136,30	170,54	158,92	162,62	158,67
Dezembro	105,97	183,40	108,08	161,91	189,76	142,91	182,11	162,98	175,76	175,22
Precipitação estimada										
Mês	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
Janeiro	134,76	173,88	117,34	175,60	174,11	169,04	183,70	180,83	192,42	185,35
Fevereiro	167,94	144,00	149,25	158,91	136,64	163,50	136,18	148,86	181,11	154,99
Março	114,26	138,92	117,45	145,80	135,69	134,78	135,04	138,21	145,45	145,02
Abril	150,80	192,01	182,23	163,72	186,51	133,77	185,48	168,61	152,29	196,79
Mai	129,86	150,10	142,43	151,35	146,37	120,17	150,38	137,27	157,01	160,68
Junho	103,94	180,77	111,14	170,76	154,12	146,09	169,30	165,44	162,75	168,79
Julho	137,10	149,37	129,75	187,37	136,13	180,05	143,97	162,39	148,21	134,81
Agosto	107,52	120,25	120,90	133,38	122,57	132,29	124,09	128,41	125,42	106,78
Setembro	153,99	194,12	148,19	218,60	186,02	185,03	190,71	201,27	203,53	188,45
Outubro	148,51	266,32	158,18	258,70	263,23	194,01	267,35	250,29	244,67	269,19
Novembro	130,17	179,55	146,21	175,71	184,41	149,26	180,50	178,43	165,42	184,78
Dezembro	104,87	190,66	107,60	171,20	197,75	154,02	193,60	176,23	180,20	200,35




Precipitação
Mínima

Precipitação
Máxima

Quadro 04. Análise estatística da precipitação estimada por sensoriamento remoto.

ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	27,98	31,29	26,17	28,61	23,54	21,08	22,36	21,09	20,56	30,74
EA máximo	261,35	217,16	192,34	134,17	135,94	98	139,24	88,99	83,85	146,93
REQM	38,19	43,35	36,47	36,81	32,05	28,49	31,27	26,81	26,71	42,34
r	0,86	0,89	0,89	0,93	0,95	0,92	0,95	0,95	0,95	0,91
d	0,92	0,94	0,94	0,95	0,97	0,95	0,97	0,97	0,97	0,93
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	95,35	151,43	119,32	235,41	125,36	130,33	151,2	140,73	120,58	228,4
EA máximo	325,41	337,49	240,23	503,75	409,72	370,18	403,59	374,77	310,19	522,03
r	0,92	0,94	0,97	0,88	0,93	0,92	0,94	0,97	0,95	0,9
d	0,96	0,94	0,96	0,81	0,95	0,89	0,94	0,95	0,94	0,83



Wang *et al.* (2017) também obtiveram valores de r acima de 0,8 em escala anual para China e Chen e Li (2016) encontraram $r=0,96$ na China continental, indicando a alta concordância dos dados estimados com as observações do pluviômetro. Medhioub *et al.* (2019) obtiveram um valor um pouco mais baixo sobre a Tunísia, de 0,79, mas ainda assim aceitável. Os valores obtidos de erro absoluto médio em escala mensal e anual concordaram com o apurado por Wang *et al.* (2017) ao avaliarem o TRMM na região Central da China, estes verificaram um erro de 19,58 mm/mês e 132,81 mm/ano.

Bernardi (2016), para 18 estações no Rio Grande do Sul, encontraram valores de 0,82 a 0,95 em escala mensal e a média dos erros absolutos médios de 28,05 mm/mês. Moreira *et al.* (2017) observou altas correlações entre valores obtidos do TRMM e das estações meteorológicas espalhada pelo RS, com r acima de 0,81. Nogueira *et al.* (2018) compararam estimativas do modelo Eta, do TRMM e do CHIRPS com dados de precipitação das estações meteorológicas do INMET para Minas Gerais, e identificaram uma superestimativa nos três produtos, o TRMM apresentou R^2 maiores que 0,87 e o REQM variou entre 9,51 mm e 17,33 mm para um período de 16 dias.

Para os EA médios e máximos mensais identificou-se que os maiores valores correspondem as bacias com menor área de drenagem, inferiores a 2.000 km². A exceção foi a bacia Porto Lucena, apesar de possuir cerca de 95.000 km², demonstrou um erro absoluto de aproximadamente 30 mm por mês. O erro absoluto máximo foi maior em bacias de menor área,

Passo dos Carros, seguido da bacia Ponte do Rio Turvo, confirmando o padrão observado. O REQM demonstra uma tendência similar ao EA.


O fato de bacias menores obterem erros maiores pode estar relacionado tanto ao próprio dado de sensoriamento remoto, o qual possui resolução espacial grosseira, logo apenas um valor é estimado para uma grande área, o que pode prejudicar a qualidade da informação, visto que a variável chuva possui grande variabilidade espacial; quanto ao dado *in situ*, pois as bacias menores possuíam menos estações de medição no seu interior, diminuindo a precisão da interpolação nestes locais.

Contudo, em escala anual este padrão não é observado. Porto Lucena segue com valores altos de erro, entorno de 230 mm anuais, e a bacia Passo Carreiro obteve o maior EA médio, em contraponto Passo dos Carros obteve o menor valor com 95 mm. Desta forma, pode-se levantar a seguinte afirmativa: o efeito da escala espacial da bacia hidrográfica não afeta a precisão dos dados estimados pelo produto TRMM em uma análise anual, porém em intervalos menores, mensais, este parâmetro deve ser considerado. Tal fato é evidenciado devido a variabilidade da precipitação nos domínios espacial e temporal, em que em qualquer instante, as intensidades de precipitação em todo o mundo variam de zero a 125 mm/h, já as variações interanuais na América do Sul sofrem influência de padrões de grande escala e de baixa frequência tais como El Niño e La Niña (BARRETT, 1993; GUERRA, 2012). Ou seja, a variabilidade espacial da precipitação é maior para intervalos de tempo menores afetando a precisão de sua estimativa para pequenas áreas devido as limitações do satélite na sua detecção.

Ao obter o erro absoluto médio por mês (Quadro 05) não foi observado um padrão claro de ocorrência dos erros, como verificado por Wang *et al.* (2017), em que os valores mais altos ocorriam no verão e valores mais baixos no inverno, de acordo com a quantidade sazonal de precipitação. O mesmo foi apurado por Chen e Li (2016) em que o REQM acompanha um padrão muito semelhante ao das quantidades mensais de precipitação na China continental. Como o estado do Rio Grande do Sul apresenta um regime de chuvas bem distribuído ao longo do ano justifica-se esta ausência de tendência dos valores.

Quadro 05. Erro absoluto médio por mês da estimativa de precipitação.

Mês	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
Janeiro	39,25	28,56	19,71	33,03	30,86	27,18	23,10	22,59	27,66	22,61
Fevereiro	26,70	28,04	36,00	27,90	30,35	28,91	21,64	21,97	35,90	20,36
Março	32,05	27,77	16,49	28,26	21,94	14,68	22,30	16,33	14,02	20,01
Abril	30,58	32,37	56,75	31,59	29,02	19,21	25,47	22,06	17,39	56,16
Mai	22,38	27,11	17,99	20,30	11,69	17,61	17,39	11,59	21,89	22,60
Junho	25,78	28,19	21,85	21,61	14,55	21,30	17,77	22,18	13,10	25,31
Julho	32,69	21,67	20,79	30,82	17,79	22,37	12,72	12,39	16,32	13,57
Agosto	24,40	21,59	22,52	16,01	17,56	13,33	12,22	14,71	17,55	22,51
Setembro	30,83	49,15	27,21	27,22	25,66	22,57	35,87	26,16	24,07	35,48
Outubro	29,65	44,41	25,85	44,39	26,36	20,07	33,47	31,34	21,99	56,04
Novembro	22,05	25,93	25,35	31,72	24,17	21,31	21,66	24,39	15,22	36,36
Dezembro	19,44	40,66	23,54	30,51	32,53	24,39	24,70	27,42	21,58	37,91



4.3.2 Evapotranspiração

Como um todo, os dados estimados via satélite apresentam uma maior constância ao longo dos anos, ao contrário dos dados *in situ* que apresentam maior dispersão nos valores anuais. A Figura 13 traz os valores da evapotranspiração acumulada anual para cada bacia do produto MOD16, GLDAS e GLEAM, respectivamente.

O produto MOD16 subestimou os valores, em todos os anos de análise, em 4 das 10 bacias, e superestimou, durante todo o período, em 3 bacias, nas demais teve períodos com valores acima do observado e períodos com valores abaixo. Nestes casos, não foi possível associar essas tendências à localidade ou ao tamanho da área de estudo. O produto GLDAS apresentou uma superestimativa notável nas duas maiores bacias: Iraí e Porto Lucena, e nas demais bacias demonstra comportamentos distintos entre os anos. O produto GLEAM subestimou os valores na maioria das bacias de estudo, com exceção de Iraí e Porto Lucena, em que os valores estimados e observado possuem uma magnitude similar em grande parte do período.

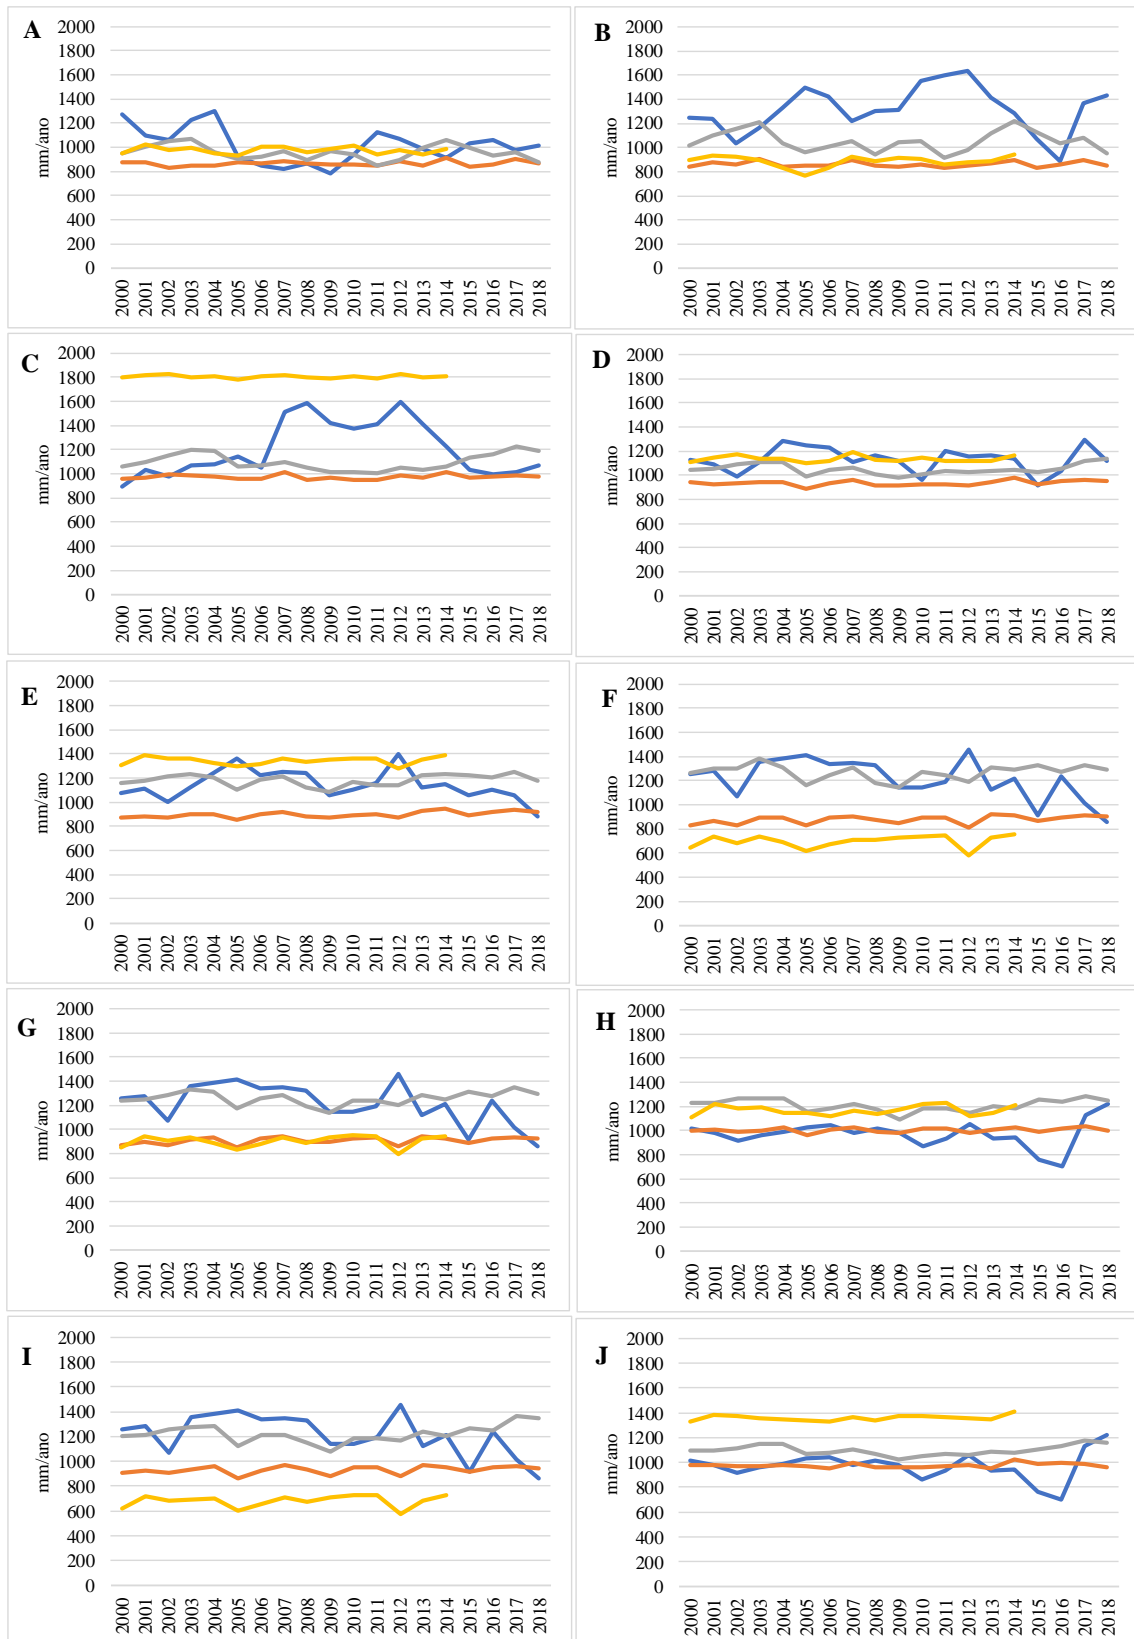


Figura 13. Evapotranspiração anual estimada por sensoriamento remoto e observada para cada bacia de estudo. A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.

A Figura 14, Figura 15 e Figura 16 exibem os gráficos de dispersão da evapotranspiração dos dados mensais observados e estimados por satélite para cada bacia dos produtos de análise, assim como suas equações da reta. O produto MOD16 demonstra uma maior dispersão dos valores, superestimando os valores maiores e subestimando os menores. A tendência linear dos dados se apresenta mais clara para os produtos GLDAS e GLEAM, tendo menor dispersão no segundo. Também, percebe-se que o produto GLEAM replica melhor valores mais altos e ambos (GLDAS e GLEAM) subestimam os valores mais baixos.

O MOD16 obteve valores de coeficiente angular menores que 0,52 em 8 das 10 áreas analisadas, ou seja, apresenta uma tendência dos dados bem acentuada na maioria das áreas, apenas as bacias Passo dos Carros e Cerro Chato exibiram valores mais altos. Para a bacia Cerro Chato ocorre um deslocamento da reta, o que pode indicar alguma incerteza na medição dos dados *in situ*. Nas demais bacias os valores menores são, em geral, subestimados, e os maiores, superestimados, no entanto há uma grande dispersão dos dados, sendo este padrão não tão evidente. Visualmente, a bacia Passo dos Carros demonstrou um desempenho muito superior as outras, em razão de sua proximidade com a reta ideal.

Para o produto GLDAS os coeficientes angulares são um pouco maiores, mas ainda assim considerados moderados, novamente com melhor atuação a bacia Passo dos Carros. A tendência de superestimativa de valores altos e subestimativas de valores mais baixos, já verificada para o produto MOD16, também ocorre para o GLDAS, porém mais notória, com menor dispersão dos dados.

O GLEAM apresenta menor dispersão dos dados que os produtos anteriores e melhores coeficientes angulares. Com melhor reprodução dos valores de ET temos Passo dos Carros, seguido de Ponte do Rio Turvo, que representam as bacias de menor dimensão. Além disso, Iraí e Porto Lucena, as maiores bacias, registram as piores performances. Logo, identifica-se um efeito de escala sobre a precisão da estimativa. Verifica-se novamente o deslocamento da reta na bacia Cerro Chato, corroborando com a probabilidade de os erros estarem associados ao conjunto de dados observados, visto que a evapotranspiração *in situ* para esta bacia foi obtida de uma estação meteorológica a cerca de 80 km, podendo haver mudanças significativas deste valor para a área de estudo. Além disso, como já destacado, sua predição é melhor para valores mais altos e tende a subestimar valores mais baixos.

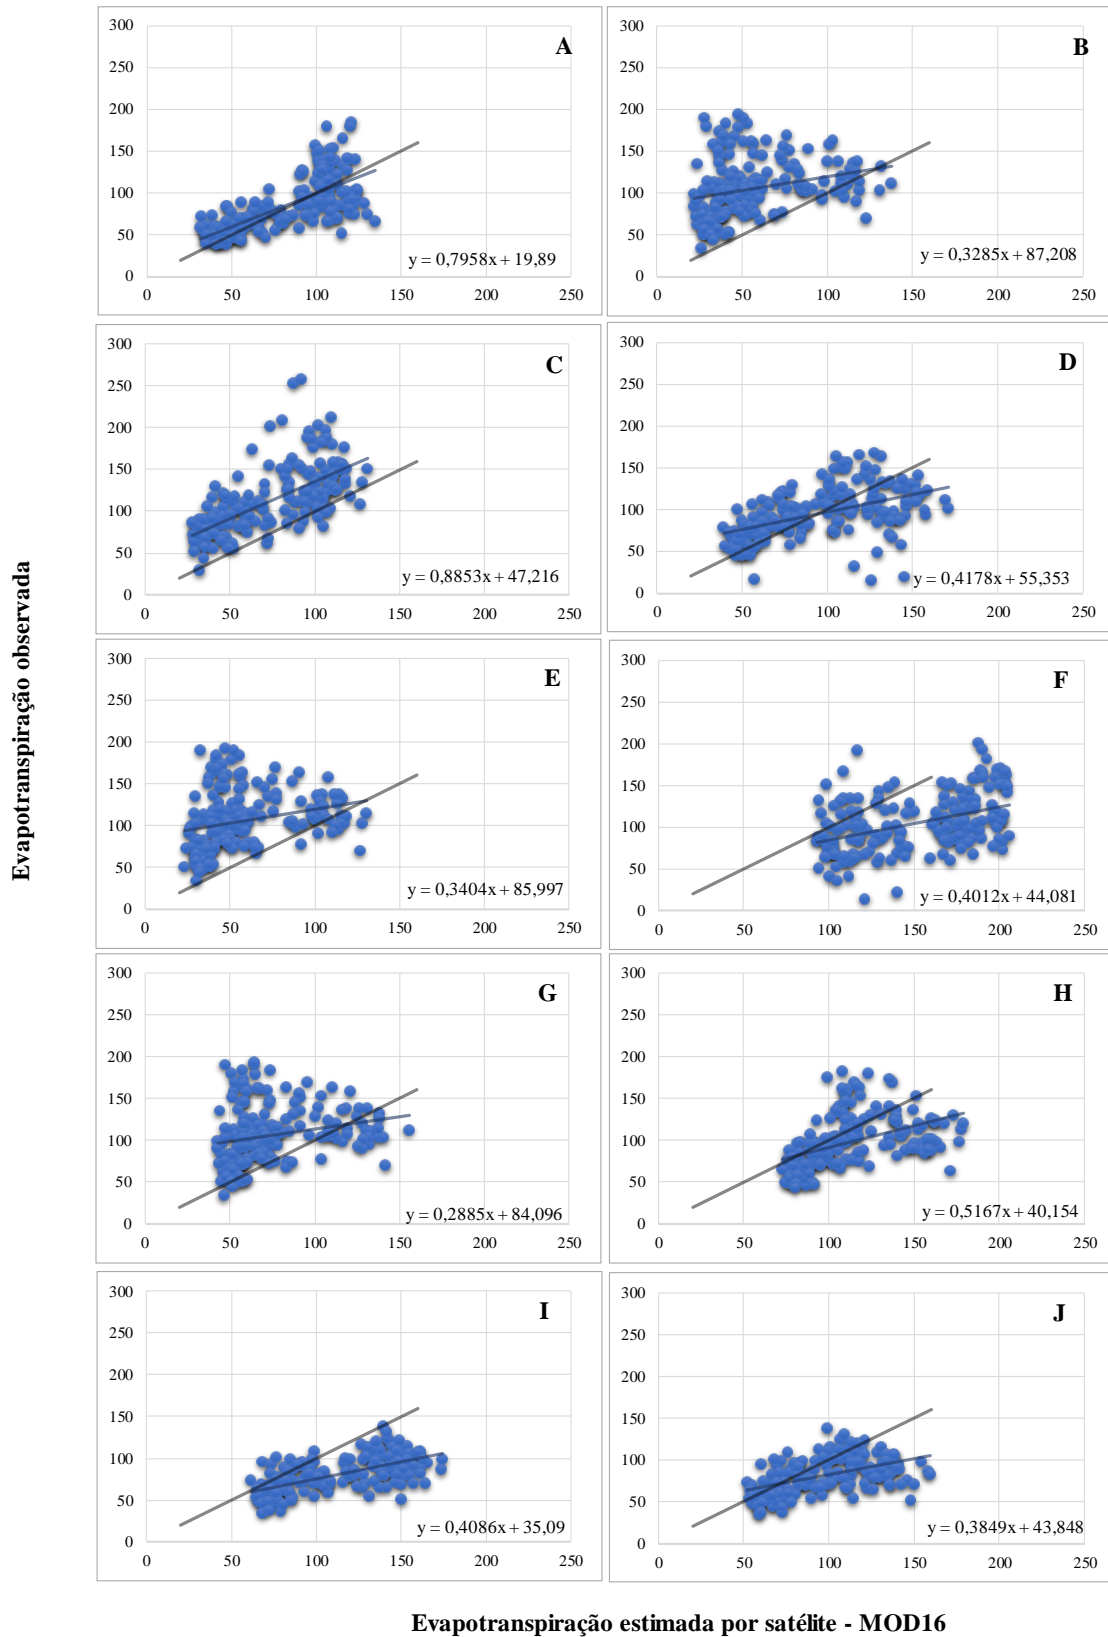


Figura 14. Gráfico de dispersão da evapotranspiração mensal para cada bacia de estudo (MOD16). A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.

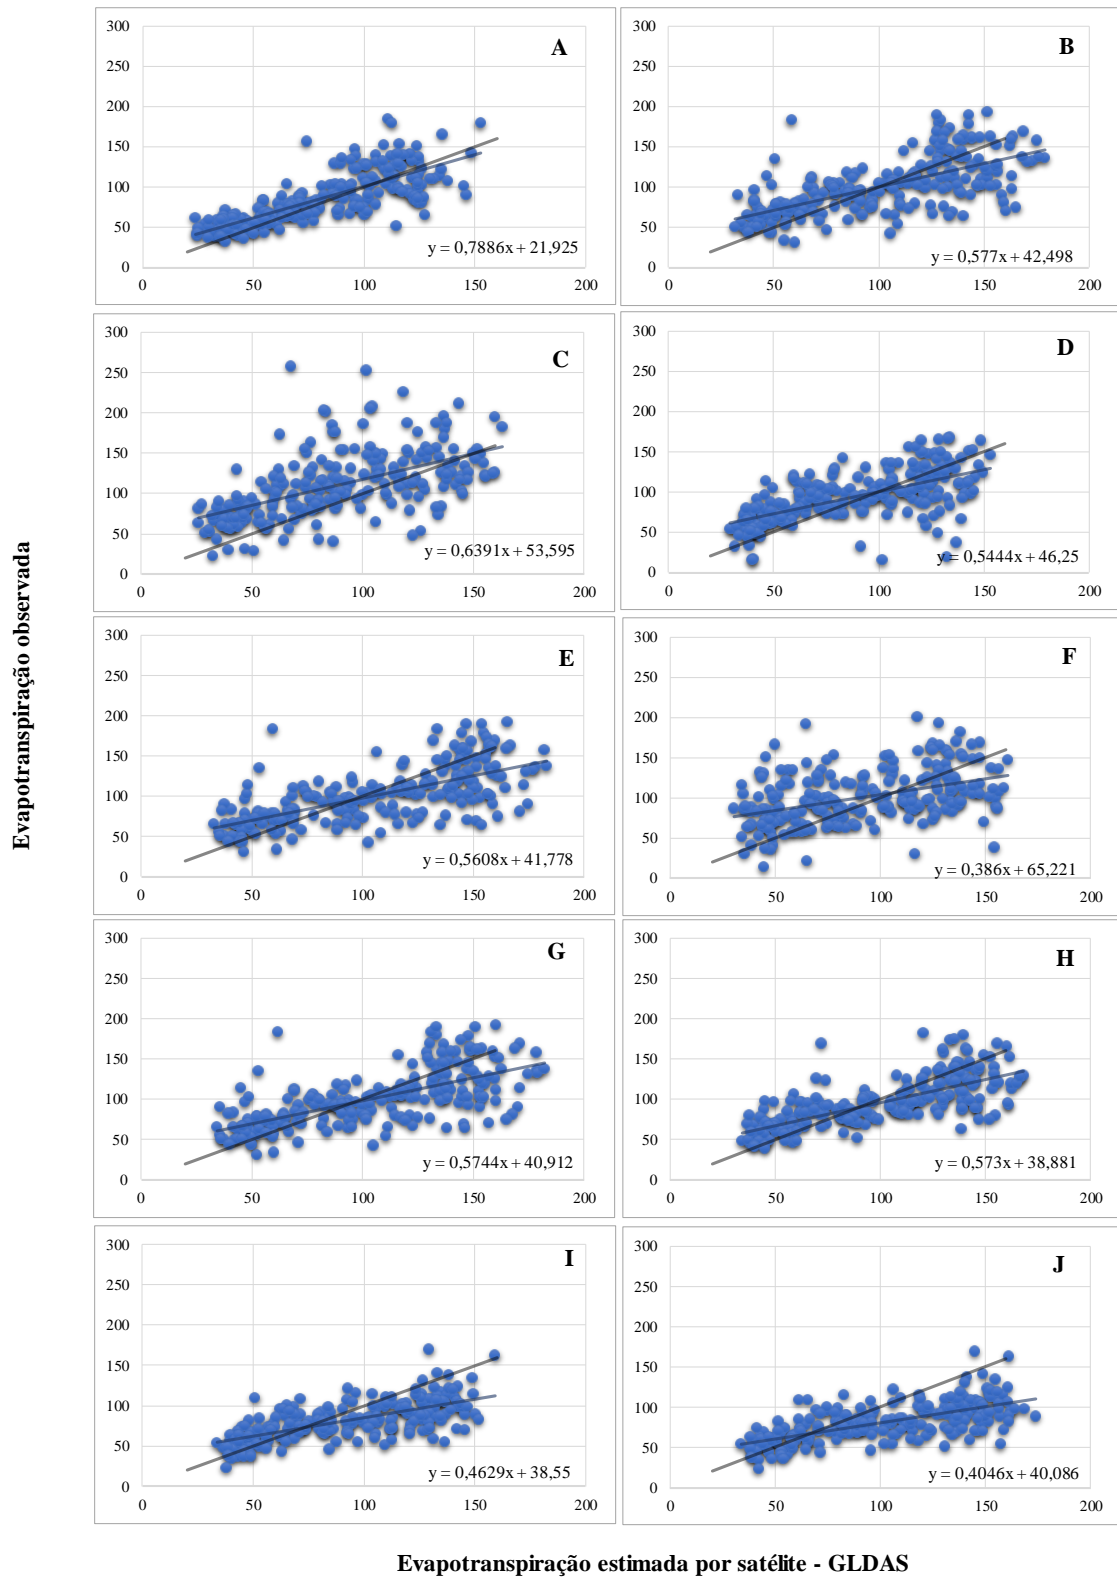


Figura 15. Gráfico de dispersão da evapotranspiração mensal para cada bacia de estudo (GLDAS). A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.

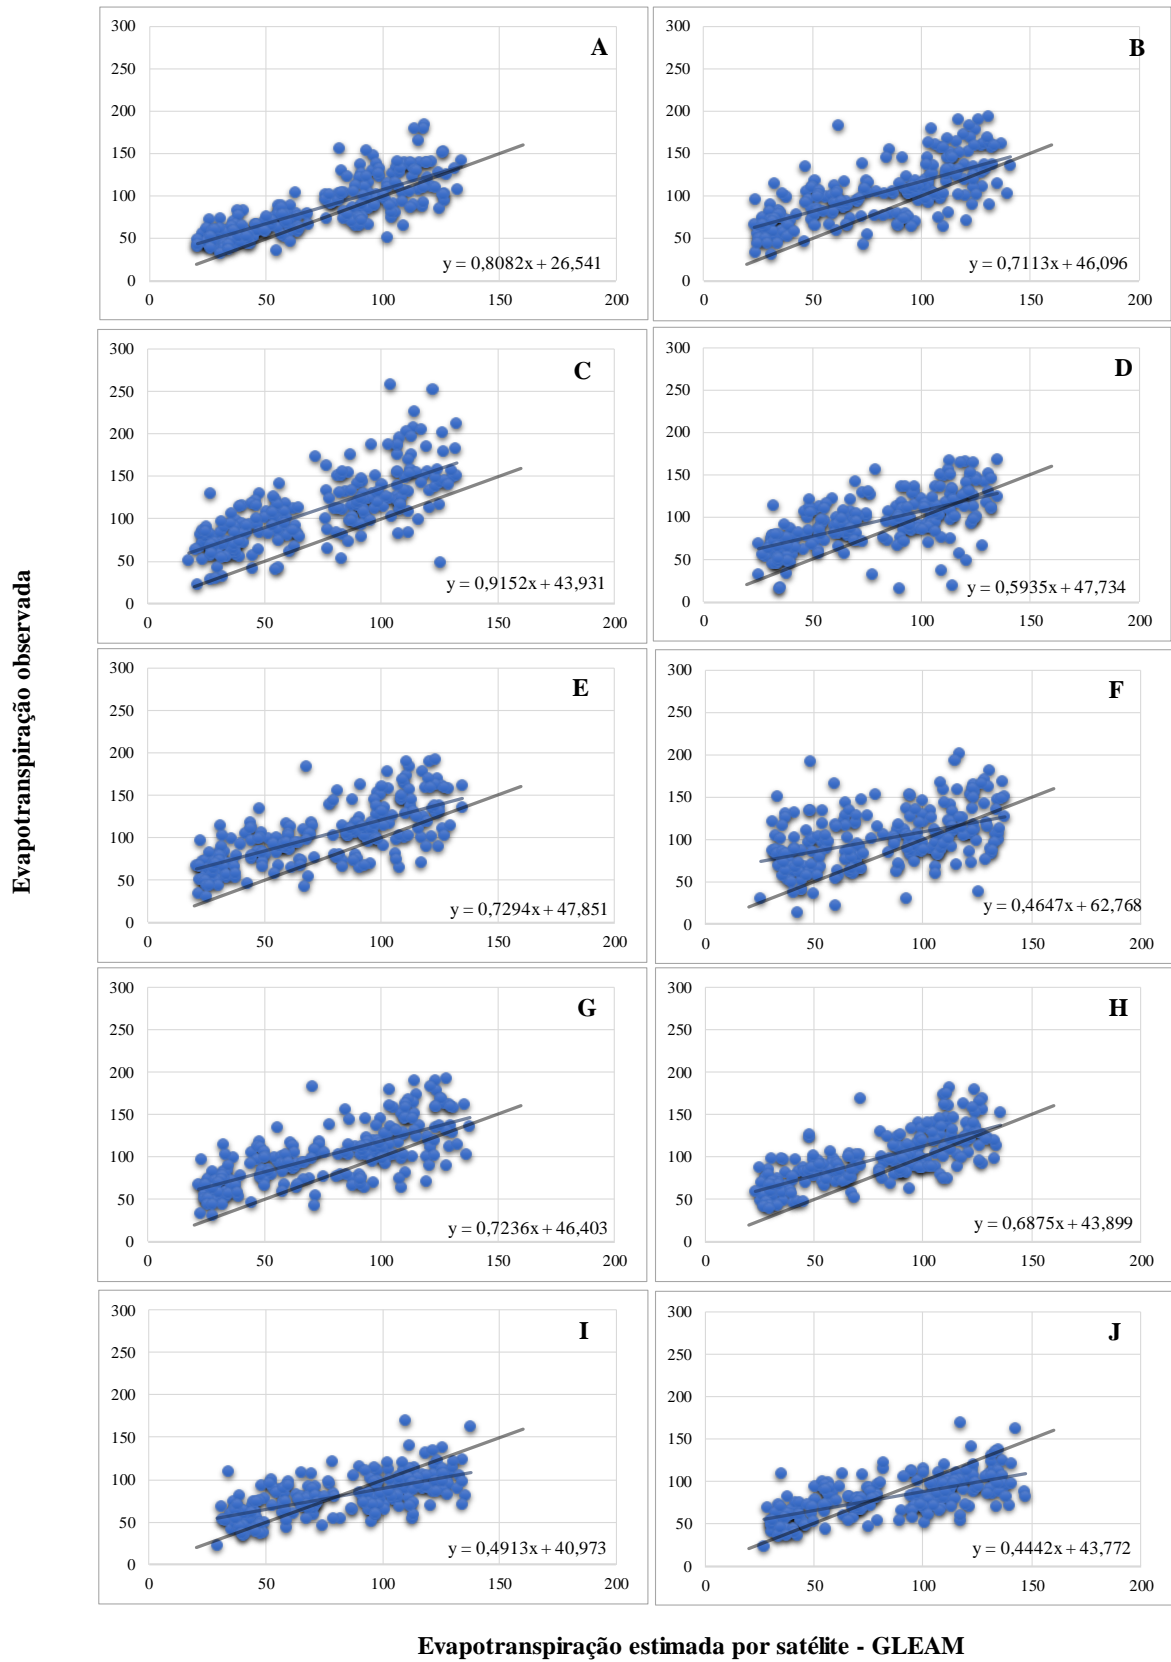



Figura 16. Gráfico de dispersão da evapotranspiração mensal para cada bacia de estudo (GLEAM). A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.

O Quadro 06, Quadro 07 e Quadro 08 permitem analisar os índices estatísticos obtidos para cada produto de estimativa de evapotranspiração.


Quadro 06. Análise estatística da evapotranspiração estimada por sensoriamento remoto – MOD 16.

MOD16										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	18,94	51,31	40,01	26,08	50,02	50,87	37,52	26,75	33,40	22,23
EA máximo	72,39	162,18	166,23	126,55	157,61	129,23	143,20	108,18	99,21	97,08
ERM	22,56	46,20	34,87	36,45	44,86	62,76	31,81	29,94	43,86	29,78
REQM	24,40	62,37	49,24	33,13	60,86	59,59	49,47	33,88	40,49	29,46
r	0,71	0,26	0,66	0,49	0,26	0,43	0,22	0,45	0,63	0,51
d	0,83	0,48	0,63	0,70	0,49	0,51	0,52	0,61	0,56	0,62
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	145,62	590,67	465,13	78,93	571,63	552,48	366,95	193,26	382,30	192,94
EA máximo	348,94	881,21	759,60	185,15	877,20	905,07	665,36	364,17	509,51	352,64
r	-0,29	-0,55	-0,51	-0,53	-0,57	0,05	-0,60	-0,65	-0,57	-0,77
d	0,23	0,23	0,32	0,02	0,24	0,39	0,30	0,34	0,17	0,22




Quadro 07. Análise estatística da evapotranspiração estimada por sensoriamento remoto – GLDAS.

GLDAS										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	16,99	23,94	33,47	23,37	24,48	30,95	23,78	20,73	21,81	27,87
EA máximo	82,07	124,62	190,29	113,35	123,58	127,20	121,51	97,03	82,56	103,03
ERM	20,52	26,43	31,47	32,58	27,10	33,45	26,21	22,79	28,20	35,78
REQM	21,94	31,17	43,23	29,71	31,97	39,02	31,39	27,08	27,63	35,40
r	0,79	0,66	0,56	0,63	0,67	0,42	0,66	0,72	0,68	0,67
d	0,88	0,81	0,70	0,78	0,81	0,66	0,81	0,83	0,77	0,69
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	122,79	155,12	302,32	109,09	146,67	240,48	140,60	119,14	133,52	240,64
EA máximo	336,84	482,85	680,86	250,02	428,16	549,50	430,75	296,19	432,99	536,41
r	0,12	-0,49	-0,52	0,17	-0,30	-0,63	-0,35	-0,31	0,17	-0,05
d	0,42	0,15	0,33	0,44	0,28	0,25	0,25	0,18	0,46	0,35



Quadro 08. Análise estatística da evapotranspiração estimada por sensoriamento remoto – GLEAM.

GLEAM										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	19,89	29,82	40,21	26,10	32,78	31,09	30,94	25,63	19,66	22,02
EA Máximo	74,61	121,20	153,93	95,21	115,35	143,49	112,58	97,80	75,03	74,11
ERM	25,03	31,29	37,39	34,21	34,12	32,58	32,45	28,67	25,66	28,63
REQM	23,89	35,41	47,57	31,83	38,28	39,72	36,31	30,58	24,03	26,60
r	0,81	0,72	0,73	0,63	0,71	0,45	0,72	0,76	0,66	0,67
d	0,86	0,75	0,68	0,74	0,72	0,64	0,74	0,78	0,79	0,78
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	168,54	293,29	454,13	193,77	341,22	239,79	312,00	250,33	82,49	89,73
EA Máximo	453,76	579,51	783,01	358,86	650,01	643,57	593,34	529,67	293,86	311,54
r	-0,31	-0,23	-0,23	0,02	-0,29	-0,07	-0,21	-0,28	-0,23	-0,08
d	0,42	0,40	0,35	0,39	0,38	0,47	0,40	0,37	0,09	0,26



Levando em consideração a correlação linear entre as séries temporais mensais dos três produtos de sensoriamento remoto e os valores observados, destaca-se o produto GLEAM, com valores entre 0,45 e 0,81, seguido do produto GLDAS, com 0,42 e 0,79. Para ambos produtos a mínima é atribuída a bacia Barca do Caí e a máxima para Passo Carreiro. Nesse aspecto, o produto com performance inferior foi o MOD16, com r entre 0,22 e 0,71.

Sobre os erros absolutos médios mensais estes variaram, para o GLDAS, entre 16,99 e 33,47, para o GLEAM, entre 19,89 e 40,21 e para o MOD16, entre 18,94 e 51,31, valores baixos e aceitáveis para a maioria das áreas de estudo. O índice de concordância mensal também teve um desempenho de moderado a bom: GLDAS (0,66 a 0,88), GLEAM (0,64 a 0,86) e MOD16 (0,48 a 0,83). O erro relativo médio mensal teve melhor atuação no produto GLDAS (20,52% a 35,78%), em segundo o GLEAM (25,03% e 37,39%).

Michel *et al.* (2016) encontraram um coeficiente de determinação (R^2) de 0,8 para o GLEAM com resolução temporal de 3 horas ao comparar com dados de torres de fluxos. Yang *et al.* (2017) obtiveram um coeficiente de correlação médio de 8 pontos de análise de 0,86 para uma escala mensal e 0,79 para escala anual para o GLEAM. Ambos estudos fizeram uma análise pontual dos dados.

Kim *et al.* (2012) ao validarem o produto MOD16 em 17 pontos da Ásia com uma resolução temporal de 8 dias, obtiveram coeficientes de correlação variando de 0,12 a 0,82. Moreira, Adamatti e Ruhoff (2018) em uma análise diária comparando nove torres de fluxo no Brasil, obtiveram um r entre -0,34 e 0,84; o presente estudo obteve a amplitude de valores em escala mensal entre 0,22 e 0,71, apresentando uma grande variação entre os pontos de análise.

Vários estudos reportam as discrepâncias entre os dados do MOD16 e os dados observados, que podem estar atreladas à erros inerentes da classificação imprecisa dos tipos de cobertura da terra, incertezas associadas aos dados de entrada e aos dados meteorológicos de reanálise do *Global Modeling and Assimilation Office* (GMAO) (MU, ZHAO, RUNNING, 2011; KIM *et al.*, 2012). Porém vale destacar que os dados observados, usados como referência neste estudo, são carregados de incertezas espaciais, uma vez que várias bacias não possuem sequer dados medidos na área, e sim apenas em locais vizinhos, podendo não estar de acordo com a realidade local.

KHAN *et al.* (2018), ao estudarem a qualidade do MOD16, GLEAM e GLDAS na extensão Sul e Leste da Ásia de 2000 a 2010, identificaram uma correlação de moderada a boa (R) com o valor médio correspondente de (0,35–0,60, 0,63–0,84 e 0,48–0,79) em comparação com nove medições de torre de fluxo, respectivamente. No entanto, na análise anual os três produtos obtiveram índices de concordância e o coeficiente de correlação insatisfatórios, em que o coeficiente de correlação apresentou valores negativos para a maioria das bacias de estudo, sendo assim, verifica-se a falta de veracidade do comportamento anual desta variável quando estimada via sensoriamento remoto para os locais de estudo.

A comparação entre os erros absolutos mensais e anuais expressos por cada produto por bacia está presente na Figura 17. Nota-se que as maiores divergências entre os produtos se apresentam na análise anual, já na mensal o GLDAS e o GLEAM demonstram uma disposição semelhante.

A bacia Cerro Chato apresentou valores de erro absoluto mensal relativamente altos nos três produtos, o que pode indicar alguma inconsistência dos dados *in situ*. Passo dos Carros apesar de possuir uma pequena área de drenagem apresentou valores baixos de erro absoluto nas três estimativas, o que pode ter relação com o fato de a estação meteorológica que fornece os dados *in situ*, apesar de não estar dentro de sua área, está bem próxima, tornando uma vantagem sua pequena dimensão pois permite a melhor representação da realidade local.

Da mesma forma que os demais produtos de sensoriamento remoto, as bacias de maiores dimensões (Passo São Lourenço, Iraí e Porto Lucena) se destacam na diminuição de seus erros, principalmente no produto GLDAS e GLEAM. De modo geral, o MOD16 foi o que apresentou

pior performance na estimativa da evapotranspiração, além dos erros altos seus coeficientes de correlação e índice de concordância foram inferiores aos demais.




Figura 17. Erro absoluto médio dos produtos de estimativa de evapotranspiração.

Os valores do coeficiente de correlação e índice de concordância mensal para cada bacia são expressos na Figura 18. É possível notar que o produto GLDAS e o GLEAM demonstram um padrão similar para os dois índices, por exemplo, ambos obtiveram um valor mais baixo para a bacia Barca do Caí. Também se percebe que o MOD16 difere totalmente nos seus valores se comparado com os outros produtos, além de apresentar uma amplitude de resultados maior. Outro ponto a destacar, é que, apesar da similaridade entre o GLDAS e o GLEAM, o segundo se apresentou levemente superior no que concerne ao coeficiente de correlação, e no índice de concordância o cenário se inverte.





Figura 18. Coeficiente de correlação e índice de concordância mensal dos produtos de estimativa de evapotranspiração.

Ao realizar o cálculo dos erros absolutos referentes as normais mensais do período de análise, para o produto MOD16 e GLDAS não foi verificado uma tendência dos dados de subestimar ou superestimar os valores em certas épocas do ano. No entanto, o produto GLEAM demonstrou um aumento dos erros entre abril e agosto (Quadro 09), o que corresponde ao período de menores valores de ET, se analisado a normal do período de análise, de 2000 a 2018 (Figura 19). Ou seja, o produto GLEAM demonstra uma queda no desempenho ao estimar a evapotranspiração em meses de baixa temperatura.

Quadro 09. Erro absoluto médio por mês da estimativa de evapotranspiração pelo GLEAM.

Mês	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
Janeiro	1,87	3,16	39,88	12,39	10,05	6,23	4,96	0,06	30,85	39,08
Fevereiro	2,14	3,48	30,13	10,31	7,02	0,17	4,73	3,28	24,78	28,33
Março	9,18	20,08	37,30	2,16	24,02	0,37	21,06	12,08	14,77	17,70
Abril	13,81	33,46	39,94	27,93	37,34	19,45	35,23	23,11	7,63	6,73
Mai	15,06	37,94	31,05	24,38	40,63	22,10	39,20	29,19	11,34	13,51
Junho	19,16	32,12	35,86	20,83	33,93	37,17	33,07	30,37	12,49	16,85
Julho	24,15	37,18	47,21	36,69	40,61	51,58	39,02	37,10	24,58	27,07
Agosto	18,70	37,79	54,03	43,71	42,26	56,08	39,82	40,30	27,73	28,06
Setembro	14,32	18,50	35,16	25,77	23,90	30,15	20,72	21,28	7,87	5,54
Outubro	6,05	7,59	22,68	9,46	13,92	10,71	10,17	10,99	10,65	16,04
Novembro	15,17	30,67	36,82	12,82	34,70	12,83	32,56	26,19	3,50	10,30
Dezembro	17,11	22,89	44,07	11,79	28,37	3,19	25,24	18,61	12,11	19,33

Figura 19. Normal para o período de análise dos dados *in situ* de 2000 a 2018 – Evapotranspiração.

4.3.3 Armazenamento de água terrestre

Na Figura 20 é possível visualizar a série temporal do armazenamento de água terrestre observado e estimado por satélite, o período de análise compreendeu 2004 a 2010 em razão da grande quantidade de ausência de dados estimados por sensoriamento remoto, desta forma os valores anuais só foram computados para anos com dados em todos os meses.




Figura 20. Armazenamento de água terrestre anual estimado por sensoriamento remoto e observado para cada bacia de estudo. A) PDC; B) PRT; C) CCH; D) PCA; E) CMO; F) BCA; G) SAN; H) PSL; I) IRA; J) PLU.

Em geral, os valores não apresentaram uma boa concordância, nem em termos de quantificação nem em termos de comportamento. Os dados estimados por satélite exibem uma tendência similar entre as bacias, com um aumento no armazenamento em 2005, 2007 e 2010 e diminuições em 2006 e 2009. Já os dados observados divergem entre as bacias e são predominantemente negativos. Deve-se levar em consideração que o valor de armazenamento de água obtido *in situ* é fruto de uma equação de balanço hídrico, na qual se inserem três variáveis medidas em campo, portanto as incertezas são amplificadas, haja vista que o erro em qualquer uma das variáveis pode afetar o seu resultado final.

O Quadro 10 apresenta os índices calculados para avaliação do produto GRACE.

Quadro 10. Análise estatística do armazenamento de água terrestre estimado por sensoriamento remoto.

ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	55,65	75,2	70,52	52,53	63,48	52,5	68,34	61,05	54,56	50,55
EA máximo	274,62	237,67	217,29	246,25	290,35	159,34	219,06	184,72	180,26	199,22
REQM	69,89	93,14	84,87	67,49	82,09	65,18	85,56	75,15	68,68	64,82
r	-0,06	0,21	0,09	0,04	0,12	0,06	0,16	0,29	0,16	0,2
d	0,33	0,46	0,38	0,37	0,42	0,37	0,44	0,49	0,42	0,48
E	-0,13	0,15	-0,58	-0,16	-0,09	-0,06	0	0,19	0,2	0,15
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	329,92	374,21	661,03	261,96	413,76	340,79	417,69	254,82	132,83	215,03
EA máximo	584,85	670,13	1092,18	449,20	755,07	582,44	719,41	398,65	386,56	351,51
r	-0,01	0,04	-0,11	0,36	-0,17	-0,50	-0,06	0,37	0,24	0,21
d	0,32	0,38	0,25	0,45	0,24	0,17	0,25	0,47	0,46	0,41
ÍNDICES	Histórico									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
Diferença do volume total	2360,2	5396,4	8281,7	3568,1	5971,1	3962,1	6149,4	2605,4	349,98	1569,2



Ao analisar os índices calculados para o produto GRACE, visualiza-se, novamente, a relação inversa entre a área de drenagem da bacia hidrográfica e os erros absolutos. Neste produto esta relação é muito mais evidente na análise anual. Em escala mensal seus erros absolutos ficaram entre 50 e 75 mm, já na anual a amplitude é bem maior, com um mínimo de 11 mm/mês em Iraí e um máximo de 55 mm/mês em Cerro Chato. Long, Longuevergne e Scanlon (2014) constataram, ao analisar três grandes bacias hidrográficas do centro-sul dos

Estados Unidos, que à medida que o tamanho da região aumenta o REQM diminui, o que condiz com o que foi encontrado na nossa análise.

A estimativa do armazenamento de água terrestre pelo GRACE só passa a apresentar coeficiente de correlação anual e coeficiente Nash-Sutcliffe positivos nas maiores bacias (Passo São Lourenço, Iraí e Porto Lucena). Mesmo assim, com valores insatisfatórios, em que a maior correlação obtida entre as séries históricas foi na bacia Passo São Lourenço com o valor de 0,37 na análise anual, isso demonstra a baixa precisão e capacidade de reprodução do comportamento da disponibilidade de água deste produto nestas análises. Esta imprecisão pode ser comprovada considerando a diferença dos volumes totais, em que os valores se apresentaram muito altos, com exceção da bacia Iraí, demonstrando uma tendência de superestimativa dos dados em todas as bacias.

Strassberg, Scanlon e Chambers (2009) evidenciaram para o aquífero High Plains, centro dos Estados Unidos, uma boa concordância entre o armazenamento de água terrestre derivado do GRACE e as medições *in situ* em escala anual, numa bacia com área de drenagem de 450.000 km².

Esta divergência de resultados pode nos indicar que o produto GRACE só é aplicável para análises de grandes áreas. Tal evidência também é enfatizada por Landerer e Swenson (2012) que afirmam que aumentar o tamanho de uma região média geralmente reduz consideravelmente seus erros e incertezas, outro ponto destacado é que os melhores resultados ocorrem em áreas com sazonalidade de precipitação bem definida. (MOREIRA e RUHOFF, 2017).

O Quadro 11 demonstra o erro absoluto médio por mês para cada bacia. Os meses de novembro e dezembro expressam um aumento deste erro. Ao analisarmos as normais climatológicas das bacias na Figura 21, gerada a partir da equação de balanço hídrico com dados *in situ* para o período de 2000 a 2018, associa-se estes aumentos nos valores dos erros aos meses de menores valores de armazenamento medidos, logo, infere-se que o produto apresentou pior performance em meses de escassez de água.

Quadro 11. Erro absoluto médio por mês da estimativa de armazenamento de água no período entre 2000 e 2018.

Mês	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
Janeiro	64,98	80,88	75,15	39,02	76,65	45,28	71,97	54,57	45,66	43,15
Fevereiro	68,38	41,34	36,89	50,73	36,07	40,25	43,87	40,45	47,59	42,39
Março	43,22	66,94	49,02	30,31	53,56	44,59	58,95	42,98	33,01	27,74
Abril	40,34	63,85	49,07	35,34	36,42	32,66	49,03	44,23	49,77	41,95
Mai	51,65	71,50	55,10	35,20	47,60	40,86	59,08	66,93	60,92	48,91
Junho	50,20	73,00	46,12	40,74	55,50	39,45	55,56	65,82	58,72	59,22
Julho	35,13	65,85	64,00	61,85	52,23	49,67	58,57	47,74	43,06	46,68
Agosto	46,74	81,28	80,66	66,19	68,47	79,13	72,38	69,98	64,96	56,75
Setembro	45,60	51,60	79,86	54,55	46,22	55,68	54,41	50,18	50,29	56,96
Outubro	62,74	47,79	86,71	62,70	54,36	52,94	52,37	49,36	56,72	41,43
Novembro	80,94	129,00	111,36	83,15	116,22	84,57	127,92	103,36	73,26	75,01
Dezembro	76,25	117,33	106,08	71,59	109,30	61,22	105,98	90,42	68,72	65,06




Figura 21. Normal do período de análise dos dados *in situ* de 2000 a 2018 – Armazenamento de água.

4.4 CONCLUSÕES

Neste estudo foi possível detectar diferenças e concordâncias entre a estimativa através de dados observados e de dados via sensoriamento remoto, em que se destaca a influência da escala espacial sobre a performance dos produtos, assim como os períodos e condições mais críticas para os modelos.

Na estimativa de precipitação por sensoriamento remoto, o produto TRMM representou de forma verídica o comportamento das chuvas, tanto espacialmente como temporalmente,

sendo capaz de reproduzir padrões sazonais. Percebeu-se uma tendência de superestimativa dos valores, principalmente para meses de grandes volumes de precipitação. Em geral, os dados mensais obtiveram uma performance superior aos dados anuais. A respeito dos erros mensais, eles se distribuem uniformemente durante o ano e apresentam valores maiores em bacias de área de drenagem menor, o mesmo não é observado no acumulado anual.

No comparativo dos produtos de evapotranspiração ao analisar os índices, o MOD16 apresentou pior performance, e os produtos GLDAS e GLEAM tiveram um desempenho semelhante entre si, e superior ao MOD16. Os três produtos replicam de forma satisfatória o comportamento desta variável em intervalos mensais, no entanto há uma tendência de superestimativa dos valores maiores e subestimativa dos menores para o MOD16 e GLDAS. Em contrapartida o GLEAM apesar de subestimar os valores menores, replica melhor valores mais altos. No entanto, na análise anual os três produtos obtiveram índices de concordância e o coeficiente de correlação insatisfatórios. As bacias de maiores dimensões exibem uma redução de seus erros, principalmente no produto GLDAS e GLEAM. A respeito da distribuição dos erros ao longo do ano, o produto MOD16 e GLDAS não apresentaram um aumento ou uma redução expressiva para certos períodos. No entanto, o produto GLEAM demonstrou um aumento dos erros entre abril e agosto, o que corresponde ao período de menores valores de ET.

Na análise do produto GRACE notou-se a relação inversa entre a área de drenagem da bacia hidrográfica e os erros absolutos, porém esta relação é muito mais evidente no intervalo anual. Os valores estimados pelo satélite não apresentaram uma boa concordância, nem em termos de quantificação nem em termos de comportamento, o que se atribui à escala de tamanho das bacias de estudo. Também se verificou que o produto apresentou pior performance em meses de escassez de água (novembro e dezembro).

Destaca-se que o presente estudo compara duas estimativas: a partir de dados observados e a partir de sensoriamento remoto, não havendo uma verdade absoluta. Portanto, as discordâncias, em certos casos, se dão devido problemas na estimativa a partir de dados observados, estes são por vezes aproximações, é realizado o preenchimento de falhas, assim como pode haver erros de medição. Para futuros estudos sugere-se analisar outras variáveis de influência sobre a concordância dos dados, como uso e ocupação do solo, variáveis climáticas, geologia e morfologia da bacia hidrográfica, cobertura vegetal, entre outras; e avaliar as incertezas associadas aos valores tomados como referências (dados *in situ*).

4.5 REFERÊNCIAS BIBLIOGRÁFICAS

AGHAKOUCHAK, A. *et al.* Remote sensing of drought: Progress, challenges and opportunities. **Reviews of Geophysics**, v. 53, n. 2, p. 452-480, 2015.

AGUILAR, Ana *et al.* Performance assessment of MOD16 in evapotranspiration evaluation in Northwestern Mexico. **Water**, v. 10, n. 7, p. 901, 2018.

AIRES, Uilson Ricardo Venâncio; NETO, José de Oliveira Melo; DE MELLO, Carlos Rogério. Estimativas de precipitação pluvial derivadas do sensor TRMM para a bacia hidrográfica do rio paraopeba. **Scientia Agraria**, v. 17, n. 2, p. 57-66, 2017.

ASADULLAH, Anita; MCINTYRE, N. E. I. L.; KIGOBE, M. A. X. Evaluation of five satellite products for estimation of rainfall over Uganda/Evaluation de cinq produits satellitaires pour l'estimation des précipitations en Ouganda. **Hydrological Sciences Journal**, v. 53, n. 6, p. 1137-1150, 2008.

AWULACHEW, Seleshi Bekele (Ed.). The Nile River Basin: water, agriculture, governance and livelihoods. Routledge, 2012.

BARRETT, E. C. Precipitation measurement by satellites: Towards community algorithms. **Advances in Space Research**, v. 13, n. 5, p. 119-136, 1993.

BASTIAANSEN, Wim GM; MOLDEN, David J.; MAKIN, Ian W. Remote sensing for irrigated agriculture: examples from research and possible applications. **Agricultural water management**, v. 46, n. 2, p. 137-155, 2000.

BERNARDI, Ewerthon Cezar Schiavo. Qualidade das estimativas de precipitação do satélite TRMM no estado do Rio Grande do Sul. **Dissertação (Mestrado em Engenharia Ambiental)** - Universidade Federal de Santa Maria, Santa Maria, 2016.

BHATTARAI, Nishan *et al.* Evaluating five remote sensing based single-source surface energy balance models for estimating daily evapotranspiration in a humid subtropical climate. **International journal of applied earth observation and geoinformation**, v. 49, p. 75-86, 2016.

BITEW, Menberu M.; GEBREMICHAEL, Mekonnen. Evaluation of satellite rainfall products through hydrologic simulation in a fully distributed hydrologic model. **Water Resources Research**, v. 47, n. 6, 2011.

BROOKFIELD, A. E. *et al.* In Situ and GRACE-Based Groundwater Observations: Similarities, Discrepancies, and Evaluation in the High Plains Aquifer in Kansas. **Water Resources Research**, v. 54, n. 10, p. 8034-8044, 2018.

CHEN, Fengrui; LI, Xi. Evaluation of IMERG and TRMM 3B43 monthly precipitation products over mainland China. **Remote Sensing**, v. 8, n. .6, p.472, 2016.

DINKU, T. *et al.* Validation of satellite rainfall products over East Africa's complex topography. **International Journal of Remote Sensing**, v. 28, n. 7, p. 1503-1526, 2007.

DORIGO, Wouter *et al.* Error characterisation of global active and passive microwave soil moisture data sets. **Hydrology and Earth System Sciences**, v.14, p. 2605-2616, 2010.

ENGMAN, Edwin T. *et al.* Remote sensing in hydrology. **London: Chapman and Hall**, 1991.

FARR, Tom G. *et al.* The shuttle radar topography mission. *Reviews of geophysics*, v. 45, n. 2, 2007.

FELIX LANDERER. 2019. JPL TELLUS GRACE-FO Level-3 Monthly Land Water-Equivalent-Thickness Surface-Mass Anomaly Release 6.0 in netCDF/ASCII/GeoTIFF Formats. Ver. 6.0. PO.DAAC, CA, USA. Disponível em: <https://doi.org/10.5067/GFLND-3AJ06>. Acesso em: Set. 2019.

GETIRANA, Augusto CV *et al.* Assessment of different precipitation datasets and their impacts on the water balance of the Negro River basin. **Journal of Hydrology**, v. 404, n. 3-4, p. 304-322, 2011.

GREENLEE, David D. Raster and vector processing for scanned linework. **Photogrammetric Engineering and Remote Sensing**, v. 53, p. 1383-1387, 1987.

GUERRA, Viviane da Silva *et al.* Climatologia da precipitação do Rio Grande Do Sul baseado em quatro esquemas convectivos do modelo climático regional REGCM3. **Dissertação (Mestrado em Meteorologia)** - Universidade Federal de Santa Maria, Santa Maria, 2012.

IRMAK, Ayse *et al.* Estimation of land surface evapotranspiration with a satellite remote sensing procedure. **Great plains research**, p. 73-88, 2011.

JAMSHIDI, Sajad *et al.* Evaluation of Evapotranspiration over a Semiarid Region Using Multiresolution Data Sources. **Journal of Hydrometeorology**, v. 20, n. 5, p. 947-964, 2019.

JENSON, Susan K.; DOMINGUE, Julia O. Extracting topographic structure from digital elevation data for geographic information system analysis. **Photogrammetric engineering and remote sensing**, v. 54, n. 11, p. 1593-1600, 1988.

KAMARIANAKIS, Yiannis *et al.* Comparing rainfall estimates derived from rain gages and satellite images at the eastern Mediterranean region. In: **Proceedings of the 9th Conference on Geographical Information Science**, Visegrad, Hungary. 2006.

KARIMI, P.; BASTIAANSEN, Wim GM. Spatial evapotranspiration, rainfall and land use data in water accounting—Part 1: Review of the accuracy of the remote sensing data. **Hydrology and Earth System Sciences**, v. 19, n. 1, p. 507-532, 2015.

KHAN, Muhammad Sarfraz *et al.* Stand-alone uncertainty characterization of GLEAM, GLDAS and MOD16 evapotranspiration products using an extended triple collocation approach. **Agricultural and forest meteorology**, v. 252, p. 256-268, 2018.

KIDD, Chris. Satellite rainfall climatology: A review. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, v. 21, n. 9, p. 1041-1066, 2001.

KIM, Hyun Woo, *et al.* Validation of MODIS 16 global terrestrial evapotranspiration products in various climates and land cover types in Asia. **KSCE Journal of Civil Engineering**, v.16, n.2, p. 229-238, 2012.

KING, E. A. *et al.* Actual Evapotranspiration Estimates for Australia. Intercomparison and Evaluation. **In: Water Information Research and Development Alliance Science Symposium, Melbourne, Australia.** p. 1-5. 2011.

KRAUSE, P.; BOYLE, D. P.; BASE, F. Comparison of different efficiency criteria for hydrological model assessment. **Advances in Geosciences**, v. 5, p. 89-97, 2005.

LANDERER, Felix W.; SWENSON, S. C. Accuracy of scaled GRACE terrestrial water storage estimates. **Water resources research**, v. 48, n. 4, 2012.

LONG, Di; LONGUEVERGNE, Laurent; SCANLON, Bridget R. Uncertainty in evapotranspiration from land surface modeling, remote sensing, and GRACE satellites. **Water Resources Research**, v. 50, n. 2, p. 1131-1151, 2014.

MARTENS, Brecht *et al.* GLEAM v3: Satellite-based land evaporation and root-zone soil moisture. **Geoscientific Model Development**, v. 10, n. 5, p. 1903-1925, 2017.

MEDHIOUB, Emna *et al.* Monthly assessment of TRMM 3B43 rainfall data with high-density gauge stations over Tunisia. **Arabian Journal of Geosciences**, v. 12, n. 2, p. 15, 2019.

MEHRAN, Ali; AGHAKOUCHAK, Amir. Capabilities of satellite precipitation datasets to estimate heavy precipitation rates at different temporal accumulations. **Hydrological Processes**, v. 28, n. 4, p. 2262-2270, 2014.

MICHEL, Dominik, *et al.* The WACMOS-ET project—Part 1: Tower-scale evaluation of four remote-sensing-based evapotranspiration algorithms. **Hydrology and Earth System Sciences**, v.20, n.2, p. 803-822, 2016.

MOREIRA, Adriana Aparecida; ADAMATTI, Daniela Santini; RUHOFF, Anderson Luis. Avaliação dos produtos de evapotranspiração baseados em sensoriamento remoto mod16 e GLEAM em nove sítios de fluxos turbulentos do programa LBA. **In: Ciência e natureza. Vol. 40, Special Edition: X Workshop Brasileiro de Micrometeorologia (2018), p. 112-118.** 2018.

MOREIRA, Adriana Aparecida; RUHOFF, Anderson Luis. Análise do balanço hídrico na América do Sul por sensoriamento remoto. **Simpósio Brasileiro de Recursos Hídricos (22.: Florianópolis, 2017). Anais [recurso eletrônico].**[Porto Alegre: ABRH, 2017], 2017.

MOREIRA, Andreise *et al.* Dados meteorológicos estimados em condições de clima subtropical e a relação com Índices de Vegetação. **Revista Brasileira de Cartografia**, v. 70, n. 4, p. 1409-1436, 2017.

MU, Qiaozhen; ZHAO, Maosheng; RUNNING, Steven W. Modis Global Terrestrial Evapotranspiration (et) Product (Nasa Mod16a2/a3). **Algorithm Theoretical Basis Document, Collection**, v. 5, 2013.

NASTOS, P. T.; KAPSOMENAKIS, J.; PHILANDRAS, K. M. Evaluation of the TRMM 3B43 gridded precipitation estimates over Greece. **Atmospheric Research**, v. 169, p. 497-514, 2016.

NEALE, Christopher MU; COSH, Michael H. (Ed.). Remote sensing and hydrology. **IAHS Press**, 2012.

NOGUEIRA, Caparoci *et al.* Evaluating precipitation estimates from Eta, TRMM and CHRIPS Data in the south-southeast region of Minas Gerais State - Brazil. **Remote Sensing**, v. 10, n. 2, p. 313, 2018.

NOGUEIRA, Sulimar; MOREIRA, Maurício; VOLPATO, Margarete. Evaluating precipitation estimates from Eta, TRMM and CHRIPS Data in the south-southeast region of Minas Gerais State—Brazil. **Remote Sensing**, v. 10, n. 2, p. 313, 2018.

OMRANIAN, Ehsan; SHARIF, Hatim O. Evaluation of the global precipitation measurement (GPM) satellite rainfall products over the lower Colorado River basin, Texas. **JAWRA Journal of the American Water Resources Association**, v. 54, n. 4, p. 882-898, 2018.

PAIVA, Rodrigo Cauduro Dias de; RUHOFF, Anderson Luis. Desafios na estimativa do ciclo hidrológico terrestre por sensoriamento remoto. **Simpósio Brasileiro de Recursos Hídricos (22.: Florianópolis, 2017). Anais [recurso eletrônico].**[Porto Alegre: ABRH, 2017], 2017.

PAN, Ming *et al.* Multisource estimation of long-term terrestrial water budget for major global river basins. **Journal of Climate**, v. 25, n. 9, p. 3191-3206, 2012.

PINKER, Rachel T. *et al.* Evaluation of satellite estimates of land surface temperature from GOES over the United States. **Journal of Applied Meteorology and Climatology**, v. 48, n. 1, p. 167-180, 2009.

PLANCHON, Olivier; DARBOUX, Frédéric. A fast, simple and versatile algorithm to fill the depressions of digital elevation models. **Catena**, v. 46, n. 2-3, p. 159-176, 2002.

RODELL, Matthew *et al.* The global land data assimilation system. **Bulletin of the American Meteorological Society**, v. 85, n. 3, p. 381-394, 2004.

SAHOO, Alok K. *et al.* Reconciling the global terrestrial water budget using satellite remote sensing. *Remote Sensing of Environment*, v. 115, n. 8, p. 1850-1865, 2011.

SCHIRMBECK, Juliano; FONTANA, Denise Cybis; ROBERTI, Débora Regina. Evaluation of OSEB and SEBAL models for energy balance of a crop area in a humid subtropical climate. *Bragantia*, n. AHEAD, 2018.

SHEFFIELD, Justin *et al.* Closing the terrestrial water budget from satellite remote sensing. *Geophysical Research Letters*, v. 36, n. 7, 2009.

STISEN, Simon; SANDHOLT, Inge. Evaluation of remote-sensing-based rainfall products through predictive capability in hydrological runoff modelling. *Hydrological Processes: An International Journal*, v. 24, n. 7, p. 879-891, 2010.

STRASSBERG, Gil; SCANLON, Bridget R.; CHAMBERS, Don. Evaluation of groundwater storage monitoring with the GRACE satellite: Case study of the High Plains aquifer, central United States. *Water Resources Research*, v. 45, n. 5, 2009.

SULTANA, Rebeka; NASROLLAHI, Nasrin. Evaluation of remote sensing precipitation estimates over Saudi Arabia. *Journal of arid environments*, v. 151, p. 90-103, 2018.

TANG, Qihong *et al.* Dynamics of terrestrial water storage change from satellite and surface observations and modeling. *Journal of Hydrometeorology*, v. 11, n. 1, p. 156-170, 2010.

TANGDAMRONGSUB, Natthachet *et al.* Evaluation of groundwater storage variations estimated from GRACE data assimilation and state-of-the-art land surface models in Australia and the North China Plain. *Remote Sensing*, v. 10, n. 3, p. 483, 2018.

TARBOTON, David G.; BRAS, Rafael L.; RODRIGUEZ-ITURBE, Ignacio. On the extraction of channel networks from digital elevation data. *Hydrological processes*, v. 5, n. 1, p. 81-100, 1991.

THOMAS, Alys C. *et al.* A GRACE-based water storage deficit approach for hydrological drought characterization. *Geophysical Research Letters*, v. 41, n. 5, p. 1537-1545, 2014.

Tropical Rainfall Measuring Mission (TRMM) (2011). TRMM (TMPA/3B43) Rainfall Estimate L3 1 month 0.25 degree x 0.25 degree V7, Greenbelt, MD, Goddard Earth Sciences Data and Information Services Center (GES DISC), Disponível em: <https://disc.gsfc.nasa.gov/datasets/TRMM_3B43_7/summary>. Acesso em: Set. 2019.

VOISIN, Nathalie; WOOD, Andrew W.; LETTENMAIER, Dennis P. Evaluation of precipitation products for global hydrological prediction. *Journal of Hydrometeorology*, v. 9, n. 3, p. 388-407, 2008.

VÖRÖSMARTY, Charles J. *et al.* Global water resources: vulnerability from climate change and population growth. *science*, v. 289, n. 5477, p. 284-288, 2000.

WAGNER, W. *et al.* Editorial 'remote sensing in hydrological sciences'. **Hydrology and Earth System Sciences**, v. 13, n. 6, p. 813-817, 2009.

WANG, Gefei *et al.* Evaluation of precipitation from CMORPH, GPCP-2, TRMM 3B43, GPCC, and ITPCAS with ground-based measurements in the Qinling-Daba Mountains, China. **PloS one**, v. 12, n. 10, p. e0185147, 2017.

WANG, Hailong *et al.* Examination of water budget using satellite products over Australia. **Journal of Hydrology**, v. 511, p. 546-554, 2014.

WU, Bingfang *et al.* Validation of ETWatch using field measurements at diverse landscapes: A case study in Hai Basin of China. **Journal of hydrology**, v. 436, p. 67-80, 2012.

WU, Zhiyong *et al.* Hydrologic evaluation of multi-source satellite precipitation products for the upper Huaihe River Basin, China. **Remote Sensing**, v. 10, n. 6, p. 840, 2018.

YANG, Xiuqin *et al.* Multi-scale validation of GLEAM evapotranspiration products over China via ChinaFLUX ET measurements. **International Journal of Remote Sensing**, v. 38, n. 20, p. 5688-5709, 2017.

ZENG, Qiaolin *et al.* Inter-comparison and evaluation of remote sensing precipitation products over China from 2005 to 2013. **Remote Sensing**, v. 10, n. 2, p. 168, 2018.

CAPÍTULO 5. INCERTEZAS ASSOCIADAS AO USO DO SENSORIAMENTO REMOTO NA ESTIMATIVA DO BALANÇO HÍDRICO

Anuário do Instituto de Geociências

Data de submissão: Em processo de submissão

Autores: Luiza Souza de Paula, Guilherme Garcia de Oliveira

Resumo: A quantificação dos recursos hídricos disponíveis é fundamental para o seu gerenciamento adequado e para sustentação da qualidade de vida. Convencionalmente, as variáveis hidrológicas são estabelecidas por medições *in situ*, no entanto há escassez desses dados, tornando o sensoriamento remoto (SR) uma alternativa atraente. O objetivo deste trabalho é obter o balanço hídrico em bacias hidrográficas a partir de fontes de dados *in situ* e dados de SR, identificar os modelos com melhores resultados, as principais fontes de incertezas e o efeito de escala espacial e temporal. Para isso, selecionou-se 10 bacias hidrográficas no estado do Rio Grande do Sul. Coletou-se dados de campo e dados de SR de precipitação (P), evapotranspiração (ET), vazão (Q) e armazenamento de água terrestre (S). Calculou-se o balanço hídrico a partir destes dados, mesclando ambas as fontes. Os produtos de SR utilizados foram: *Tropical Rainfall Measuring Mission (TRMM)*, *Global Amsterdam Evaporation Land Model (GLEAM)* e *Gravity Recovery and Climate Experiment (GRACE)*. No cálculo de Q pela equação simples constatou-se que a utilização de ET via SR é uma alternativa viável quando há escassez de dados de campo. Na equação completa de Q, o uso de dados de S via SR não foram capazes de quantificar e representar o seu comportamento. No entanto, em um período histórico o uso desse tipo de dado reduziu significativamente os erros, principalmente em bacias maiores. As estimativas de S calculadas por fontes mistas de dados demonstraram resultados excelentes. Concluiu-se que é possível estimar o balanço hídrico em bacias hidrográficas a partir de dados obtidos por SR, no entanto a precisão destas estimativas é resultado de diversos fatores: localização, tamanho da bacia, época do ano e escala temporal de análise.

Palavras-chave: armazenamento de água; balanço hídrico; sensoriamento remoto.

Abstract: Quantification of available hydric resources is essential to its proper management and sustained quality of life. Usually, hydrological variables are determined by *in situ* measurements; however, shortage of this kind of data makes utilizing remote sensing (RS) a good alternative. The scope of the present study is to obtain the water balance for different watersheds from both *in situ* data and RS data, to determine the best results models, to identify

the main sources of uncertainties and to analyze the spatial and temporal scale effects. Therefore, ten watersheds in the Rio Grande do Sul state with available field data were selected. Observed and remotely sensed data of precipitation (P), evapotranspiration (ET), runoff (Q), and water storage (S) were collected. Hence, water balance was calculated from this data merging both sources of data. The remote sensing products used were: *Tropical Rainfall Measuring Mission* (TRMM), *Global Amsterdam Evaporation Land Model* (GLEAM) and *Gravity Recovery and Climate Experiment* (GRACE). The Q calculation from the simplified equation found that the use of ET remotely sensed data is a viable alternative when there is field data scarcity. In the complete equation of Q, the use of S data from RS was not able to quantify and replicate its behavior. However, in a historical period the use of this kind of data lowered errors significantly, especially in larger basins. The S estimates calculated from mixed data sources showed excellent results. This work concluded that it is possible to estimate the water balance in hydrographic basins from RS data; nonetheless, the estimates' accuracy is dependent on various factors such as localization, drainage area, season, temporal scale of analysis.

Keywords: water storage, water balance, remote sensing.

5.1 INTRODUÇÃO

Com o cenário atual, em que a água potável está se tornando cada vez mais escassa, é de suma importância o estudo da disponibilidade hídrica. Conhecer sua distribuição espacial e temporal fornece bases científicas para a implementação de políticas de planejamento e execução do uso racional deste recurso (D'ANGIOLELLA, VASCONCELLOS e ROSA, 2005). A gestão de recursos hídricos tem por objetivo atender em níveis sustentáveis as demandas econômicas, sociais e ambientais por água, possibilitando a convivência de seus usos atuais e futuros (SOARES *et al.*, 2010). Os problemas associados à falta de gerenciamento em bacias urbanas e rurais englobam falta do recurso para o abastecimento, precariedade no saneamento, assoreamento dos cursos d'água e a contaminação por agrotóxicos e fertilizantes (PORTO e FERREIRA, 2012).

Para obtenção do total de água disponível é necessário conhecer os fluxos de precipitação (chuva, granizo e neve), evapotranspiração (evaporação da água do dossel e do solo, transpiração da planta e sublimação da neve) e escoamento superficial e subsuperficial (SHEFFIELD *et al.*, 2009). A contabilização das entradas e saídas deste sistema fornece o armazenamento de água terrestre, ou seja, a água armazenada sobre e abaixo da superfície (TANG *et al.*, 2010). Esta contabilização da água na terra é denominada de balanço hídrico, o

qual representa o somatório das quantidades de água que entraram no sistema por precipitação (P) e que saem por evapotranspiração (ET) e escoamento (Q) (SENTELHAS *et al.*, 1999).

Métodos típicos para estimar o armazenamento de água terrestre em escalas de bacia hidrográfica incluem observações *in situ*, modelagem hidrológica, balanço hídrico atmosférico e terrestre e técnicas de sensoriamento remoto (TROCH *et al.*, 2007).

As redes de medição existentes *in situ*, apesar de terem atendido bem às necessidades de desenvolvimento da água no mundo industrializado, não provêm uma base de conhecimento global adequada das mudanças no volume de água armazenada (ALSDORF, RODRÍGUEZ e LETTENMAIER, 2007). A sua determinação direta é difícil devido a dados *in situ* insuficientes para caracterizar a variabilidade espaço-temporal das reservas hidrológicas (neve, umidade do solo, águas subterrâneas) e dos fluxos envolvidos no processo (precipitação, evapotranspiração). No entanto, métodos alternativos que usam novos conjuntos de dados provenientes de sensoriamento remoto mostram um grande potencial para melhorar a estimativa da dinâmica do armazenamento de água sazonal e interanual (TROCH *et al.*, 2007).

É possível utilizar múltiplas estimativas no cálculo do balanço hídrico, por exemplo, observações *in situ*, dados de sensoriamento remoto, reanálises atmosféricas e modelos de superfície terrestre. Essa estratégia tende a compensar as limitações de cada método de estimativa individual em termos de precisão, cobertura espacial, frequência de amostragem temporal. Ao mesmo tempo, levanta novos desafios: qual a significância das discrepâncias entre diferentes fontes de dados? Qual a exatidão e a consistência de cada fonte e as incertezas à estimativa final? Além disso, em muitos casos, as estimativas de componentes do balanço hídrico a partir de diferentes fontes não fecham o armazenamento de água terrestre, ou seja, a restrição física básica do balanço de massa de água não é satisfeita (PAN *et al.*, 2012).

Nesta perspectiva, Bastiaanssen e Chandrapala (2003) estimaram a variabilidade do balanço hídrico sobre o Sri Lanka; McCabe *et al.* (2008) avaliaram a consistência hidrometeorológica da água superficial e das variáveis do ciclo de energia obtidos de dados de sensores remotos sobre o Arizona; Sheffield *et al.* (2009) computaram o armazenamento de água terrestre por sensoriamento remoto; Gao *et al.* (2010) estimaram o balanço hídrico das principais bacias hidrográficas dos EUA via sensoriamento remoto; Tang *et al.* (2010) analisaram a dinâmica da mudança de armazenamento de água terrestre; Thomas *et al.* (2014) abordaram o déficit de armazenamento de água baseado no satélite GRACE; Paiva e Ruhoff (2017) identificaram os desafios na estimativa do ciclo hidrológico terrestre por sensoriamento remoto; Moreira e Ruhoff (2017) analisaram o fechamento do balanço hídrico por meio de dados de sensoriamento remoto em 28 bacias na América do Sul; Moreira *et al.* (2018)

avaliaram os componentes do balanço hídrico mensal por meio de sensoriamento remoto, na bacia do Alto Paraguai.

Uma questão científica, já levantada por Sheffield *et al.* (2009), mas que ainda precisa ser melhor explorada, é: será que estimativas dos componentes individuais possuem precisão suficiente para fornecer o total de água terrestre e, portanto, dar informações confiáveis sobre a variação do ciclo da água na Terra? Desta forma, o objetivo geral deste trabalho é obter o balanço hídrico em bacias hidrográficas de forma integrada, a partir de fontes diversas de variáveis que compõem o ciclo hidrológico, incluindo dados observados *in situ* e dados estimados por sensoriamento remoto. Por conseguinte, identificar os modelos com melhores resultados, ressaltar as principais fontes de incertezas e analisar o efeito de escala espacial e temporal sobre a precisão da predição.

5.2 MATERIAIS E MÉTODOS

5.2.1 Área de estudo

O presente trabalho foi realizado em dez bacias distribuídas nas três regiões hidrográficas (RH) do Rio Grande do Sul. Para seleção das áreas de estudo, primeiramente, analisou-se a disponibilidade de dados de escoamento *in situ* (séries de vazões observadas). Considerou-se também a área de drenagem de cada estação fluviométrica e sua localização, com o objetivo de selecionar pontos bem distribuídos no estado. A Figura 22 apresenta a lista de estações fluviométricas utilizadas, com código, nome e área de drenagem, obtidas junto ao sistema *Hidroweb* da Agência Nacional de Águas e a localização das bacias hidrográficas de estudo.

Vale destacar que B09 e B02 se encontram no interior de B10, correspondendo a uma bacia incremental, além disso parte de sua área fica sobre território Argentino e não foi possível coleta de dados *in situ* nesta parcela.

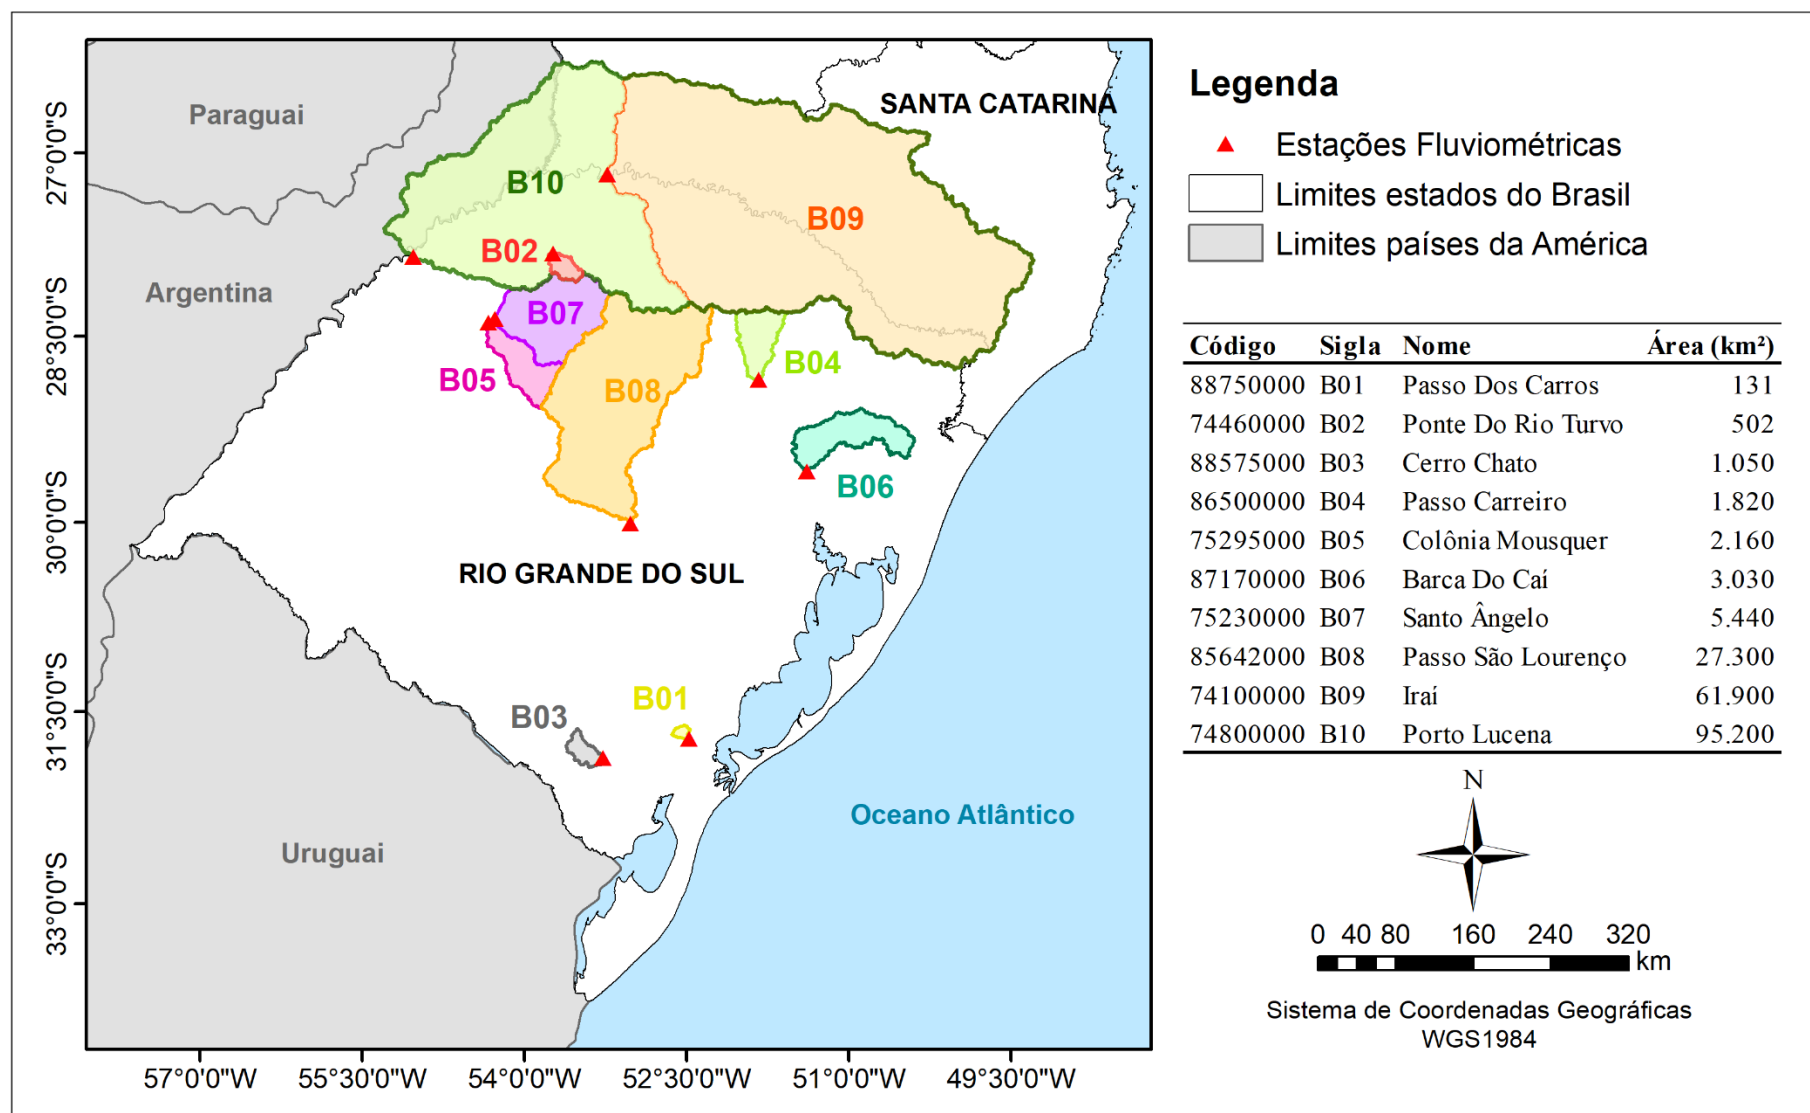


Figura 22. Bacias de estudo com suas estações fluviométricas e áreas de drenagem. Fonte: Autor.

A partir destas estações foram extraídas as bacias hidrográficas no *software* ArcGIS. Para o desenvolver desse procedimento foi necessário o auxílio de um *shapefile* dos pontos das estações fluviométricas selecionadas e um Modelo Digital de Elevação (MDE). O MDE foi obtido da missão *Shuttle Radar Topography Mission* (SRTM), com resolução espacial de aproximadamente 90 m (FARR *et al.*, 2007). Diversos estudos comprovam sua eficácia e precisão na caracterização e delimitação de bacias: Ahmed *et al.* (2010); Alves Sobrinho *et al.* (2010); Brubacher *et al.* (2012); Satgé *et al.* (2015); Scalco *et al.* (2018); Lopes, Leal e Ramos (2018). Esta missão é liderada pela Agência Nacional de Inteligência Geoespacial e pela *National Aeronautics and Space Administration* (NASA), e teve como intuito obter uma base de dados topográfica digital de alta resolução da Terra, seus dados têm acesso gratuito e sua cobertura abrange as latitudes 60° Norte e 56° Sul.

5.2.2 Coleta de dados

Foram obtidos dados observados de precipitação (estações pluviométricas), evapotranspiração (estações meteorológicas) e escoamento (estações fluviométricas), além de dados estimados por sensoriamento remoto de precipitação, evapotranspiração e armazenamento de água terrestre. O período de análise foi entre 2000 e 2018, em função da maior cobertura de dados de sensoriamento remoto. As séries foram discretizadas no intervalo de tempo mensal.

As vazões observadas em cada bacia hidrográfica foram utilizadas para o cálculo do armazenamento de água terrestre a partir de dados das estações instaladas *in situ*, por meio da Equação 14, a fim de realizar a comparação com o produto sensoriamento remoto.

$$\Delta S = P - ET - Q \quad (14)$$

Em que: ΔS é a variação do armazenamento de água terrestre mensal calculada; P é a precipitação observada nas estações pluviométricas na área da bacia; ET é a evapotranspiração observada na bacia; e Q é o escoamento observado na estação fluviométrica.

5.2.2.1 Dados observados nas estações

Os dados de precipitação mensal foram obtidos do sistema *Hidroweb* para os estados do Rio Grande do Sul e Santa Catarina, das estações pluviométricas a partir do ano de 2000, num total de 450 estações. Foi realizada uma interpolação dos valores de precipitação a partir do método do inverso do quadrado da distância para uma malha de pontos distribuídos com equidistância

de 20 km. Como esta interpolação foi utilizada para estimar a precipitação média da bacia, a escolha do método não interfere significativamente no valor final. Após atribuído o valor de precipitação mensal para cada ponto, foi realizada uma média dos valores dos pontos em cada bacia de estudo, para cada mês.

Os dados de evapotranspiração mensal foram obtidos do sistema Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) do Instituto Nacional de Meteorologia (INMET). Devido à baixa disponibilidade destes dados, com apenas 22 estações espalhadas pelo Rio Grande do Sul e Santa Catarina, procedeu-se da seguinte forma: para as bacias com mais de uma estação dentro de sua área, realizou-se as médias dos valores; para as bacias menores sem estações em sua abrangência, utilizou-se os dados da estação mais próxima.

No entanto, os dados destas estações apresentavam descontinuidades, desta forma para completar a série histórica aplicou-se o método de estimativa de evapotranspiração de Thornthwaite, o qual utiliza apenas como dado de entrada a temperatura média mensal.

Para aplicação de tal método, utilizou-se os dados de temperatura média mensal das estações meteorológicas, porém também havia deficiência de dados, de maneira que foi necessário empregar valores de ET de normais climatológicas oriundas do INMET nos meses faltantes.

Os dados de escoamento foram obtidos a partir do *software* Hidro 1.3 e exportados para o *Microsoft Office Excel*. A Figura 23 apresenta as estações fluviométrica em que se extraiu os dados de vazão, as estações pluviométricas, as quais foram interpoladas para obtenção dos dados de precipitação e as estações meteorológicas com séries de evapotranspiração disponíveis no estado do Rio Grande do Sul e Santa Catarina. Também apresenta a quantidade de estações (pluviométrica e meteorológicas) no interior de cada bacia de estudo e a distância da estação meteorológica mais próxima, caso não possua nenhuma no seu interior.

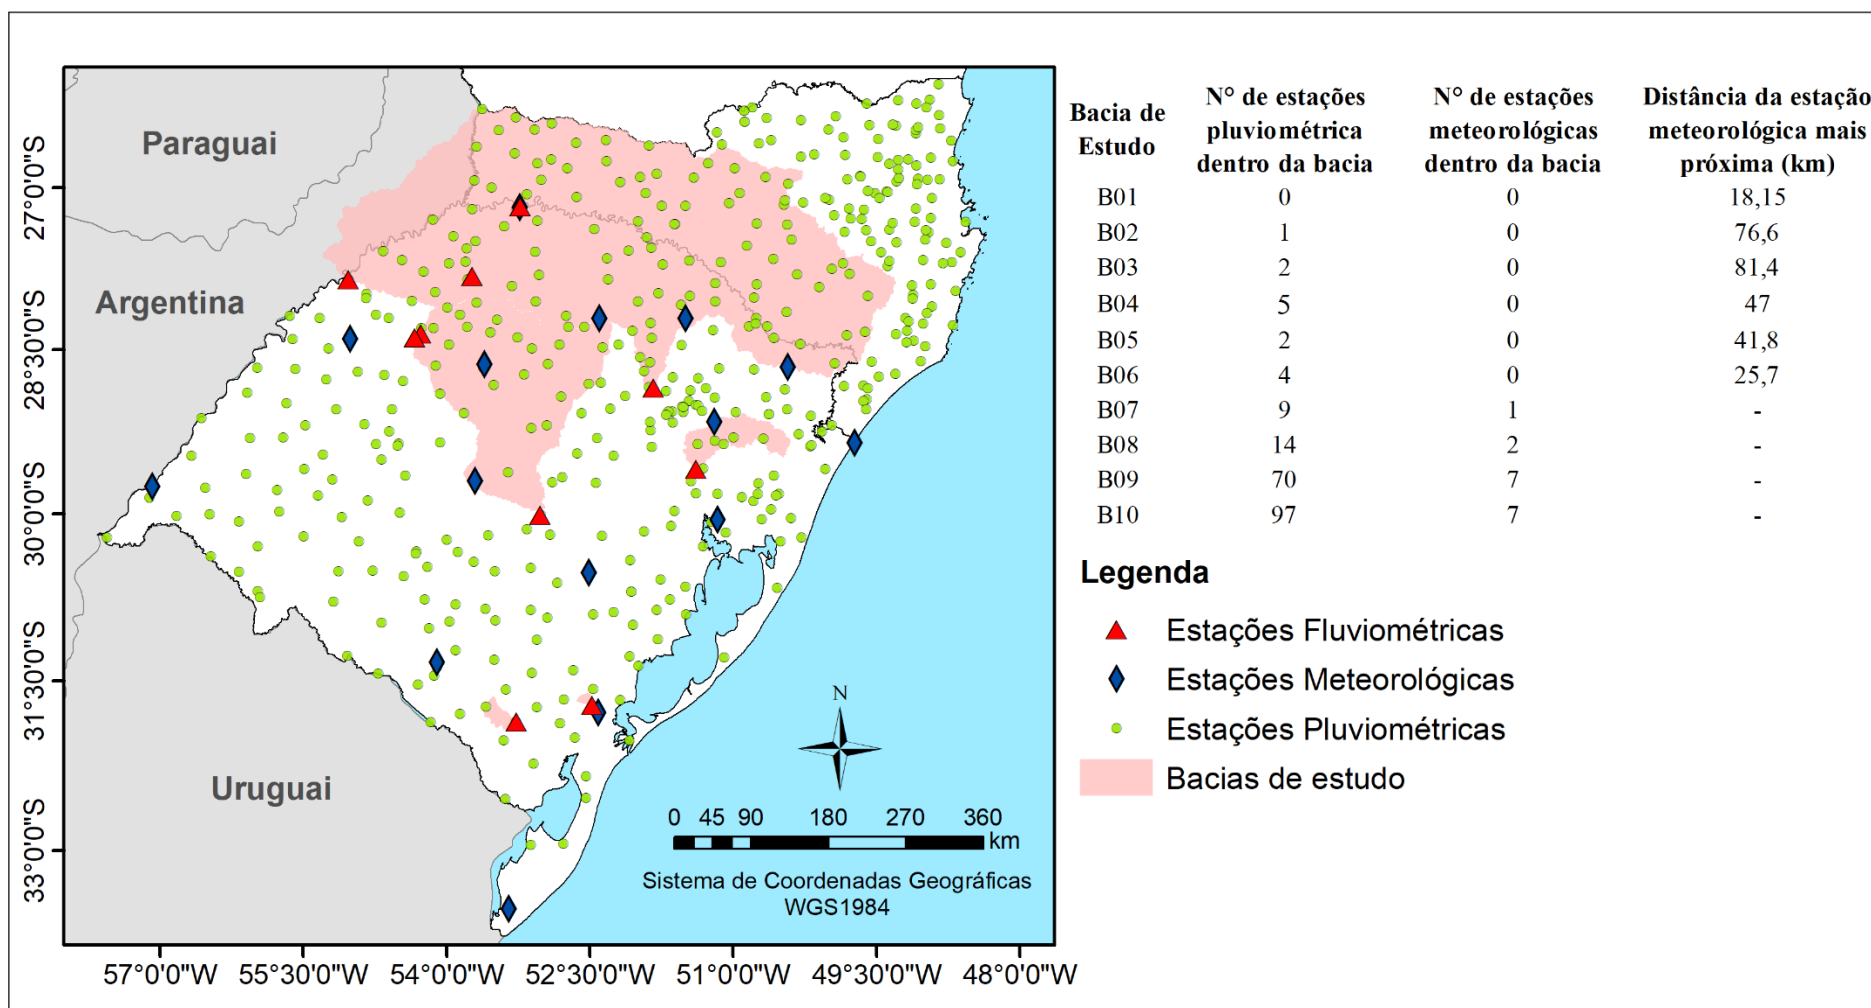


Figura 23. Estações utilizadas para extração de dados *in situ*. Fonte: Autor.

5.2.2.2 Dados de sensoriamento remoto

Para obtenção dos dados de precipitação por sensoriamento remoto, optou-se pelas imagens do satélite *Tropical Rainfall Measuring Mission* (TRMM), visto que é o produto com maior base bibliográfica, maior série de dados disponíveis e com alta precisão segundo estudos: Su, Hong e Lettenmaier (2008); Nastos, Kapsomenakis e Philandras (2016); Wang *et al.* (2017); Darand; Amanollahi e Zandkarimi (2017). O produto utilizado foi o TRMM 3B43, uma estimativa de precipitação com resolução espacial de $0,25^\circ \times 0,25^\circ$ (cerca de 27,8 km) e resolução temporal de 1 mês (TRMM, 2011), em mm/h no seguinte endereço: <<https://disc.gsfc.nasa.gov/>>.

Os dados de armazenamento de água terrestre foram obtidos do *Gravity Recovery and Climate Experiment* (GRACE). O produto utilizado foi o “*JPL TELLUS GRACE Level-3 Monthly LAND Water-Equivalent-Thickness Surface-Mass Anomaly Release 6*”, o qual fornece as anomalias de massa de água terrestre mensais expressas como espessura de água equivalente provenientes das observações da variação de gravidade no tempo do GRACE (FELIX LANDERER, 2019). Sua resolução espacial é de $1^\circ \times 1^\circ$ com unidade de mm/h, acessíveis no site: <<https://podaac.jpl.nasa.gov/>>.

Para estimativa de evapotranspiração por sensoriamento remoto selecionou-se o produto mensal *Global Amsterdam Evaporation Land Model* (GLEAM) (MARTENS *et al.*, 2017). O GLEAM é um conjunto de algoritmos que estimam separadamente os diferentes componentes da evaporação do solo: transpiração (Et), sublimação de neve (Es), perda por interceptação (Ei), evaporação (Eb) e sublimação em águas abertas (Ew). Fornecidos em uma grade de latitude-longitude de $0,25^\circ \times 0,25^\circ$ e com uma resolução temporal diária, os quais são agregados em mensais e anuais. Disponíveis em <<https://www.gleam.eu/>> e organizados em arquivos NetCDF.

Estes produtos mensais de sensoriamento remoto passaram por uma série de processamentos, extraída a média dos valores dos pixels para cada área de estudo para cada mês no *software* ArcGIS e transformados em mm/mês no *Microsoft Office Excel*.

5.2.3 Balanço Hídrico

Com todos dados devidamente processados e compatibilizados, foram aplicadas equações referentes ao balanço hídrico, algumas com o intuito de determinar a vazão e outras o armazenamento de água.

5.2.3.1 Vazões calculadas

Inicialmente utilizou-se uma equação de balanço hídrico mais simples (Equação 15), utilizando o intervalo de análise anual.

$$Q = P - ET \quad (15)$$

Calculou-se a Equação 15 com dados *in situ* (Q0), com a variável precipitação estimada por sensoriamento remoto e, em seguida, evapotranspiração (Q1 e Q2) e com as duas variáveis (P e ET) estimadas por sensoriamento remoto (Q3) (Quadro 12).

Quadro 12. Fonte dos dados utilizados para o cálculo das vazões a partir da Equação 15.

Cenários de vazão calculada	Fonte de dados	
	P	ET
Q0	<i>In situ</i>	<i>In situ</i>
Q1	Sensoriamento Remoto	<i>In situ</i>
Q2	<i>In situ</i>	Sensoriamento Remoto
Q3	Sensoriamento Remoto	Sensoriamento Remoto

Empregou-se a equação do balanço hídrico completa (Equação 16) isolando-se a vazão para períodos mensais, anuais e histórico.

$$Q = P - ET - S \quad (16)$$

Esta equação foi aplicada com uma variável estimada por sensoriamento remoto (Q4, Q5 e Q6), com duas variáveis estimadas por sensoriamento remoto (Q7, Q8 e Q9) e com três variáveis estimadas por sensoriamento remoto (Q10) (Quadro 13). Estas vazões calculadas foram analisadas frente ao dado de vazão medido *in situ* pelas estações fluviométricas.

Quadro 13. Fonte dos dados utilizados para o cálculo das vazões a partir da Equação 16.

vazão calculada	Fonte de dados		
	P	ET	S
Q4	<i>In situ</i>	<i>In situ</i>	Sensoriamento Remoto
Q5	Sensoriamento Remoto	<i>In situ</i>	<i>In situ</i>
Q6	<i>In situ</i>	Sensoriamento Remoto	<i>In situ</i>
Q7	Sensoriamento Remoto	Sensoriamento Remoto	<i>In situ</i>
Q8	Sensoriamento Remoto	<i>In situ</i>	Sensoriamento Remoto
Q9	<i>In situ</i>	Sensoriamento Remoto	Sensoriamento Remoto
Q10	Sensoriamento Remoto	Sensoriamento Remoto	Sensoriamento Remoto

5.2.3.2 Armazenamentos de água calculados

Para obtenção do armazenamento de água aplicou-se a Equação 17. Empregou-se dados medidos *in situ* (S0), uma das variáveis estimada por sensoriamento remoto (S1 e S2) e duas variáveis estimadas por sensoriamento remoto (S3) (Quadro 14). Para análise do armazenamento utilizou-se como referência o valor de S0, o qual serviu como base real para o cálculo dos índices de desempenho. Neste caso, as equações foram calculadas para intervalos mensais, anuais e histórico.

$$\Delta S = P - ET - Q \quad (17)$$

Quadro 14. Fonte dos dados utilizados para o cálculo dos armazenamentos de água terrestre a partir da equação 17.

Cenários de armazenamento de água terrestre calculado	Fonte de dados		
	P	ET	Q
S0	<i>In situ</i>	<i>In situ</i>	<i>In situ</i>
S1	Sensoriamento Remoto	<i>In situ</i>	<i>In situ</i>
S2	<i>In situ</i>	Sensoriamento Remoto	<i>In situ</i>
S3	Sensoriamento Remoto	Sensoriamento Remoto	<i>In situ</i>

5.2.4 Análise estatística

A partir dos cálculos de vazão e armazenamento de água, extraiu-se uma série de indicadores para análise das incertezas associadas a aplicação de dados provenientes de sensoriamento remoto na equação do balanço hídrico.

O Erro Absoluto Médio corresponde à diferença entre a variável estimada e a observada por mês. A Raiz do Erro Quadrático Médio elimina a existência de números negativos e informa a precisão e a acurácia das estimativas. Estes indicadores são obtidos pelas Equações 18 e 19.

$$EA = \frac{1}{n} \sum |X_{est} - X_{obs}| \quad (18)$$

$$REQM = \sqrt{\frac{1}{n} \sum (X_{est} - X_{obs})^2} \quad (19)$$

Em que: EA = erro absoluto médio; REQM = Raiz do Erro Quadrático Médio; n = número de meses analisados; X_{est} = variável estimada; X_{obs} = variável observada.

Obteve-se o índice de concordância (d) proposto por Wilmott para identificar o grau de concordância entre o valor observado e sua estimativa (KRAUSE *et al.*, 2005), quanto mais próximo de 1, melhor a exatidão do desempenho do modelo em prever a variável dependente (AIRES, NETO e DE MELLO, 2017). E o linear de Pearson (r), que mede a relação entre duas variáveis quantitativas e exprime o grau de correlação por meio de valores situados entre -1 e 1. Estes índices são calculados pelas equações 20 e 21.

$$d = 1 - \left[\frac{\sum(X_{est} - X_{obs})^2}{\sum(|X_{est} - \bar{X}_{obs}| + |X_{obs} - \bar{X}_{obs}|)^2} \right] \quad (20)$$

$$r = \frac{\sum(X_{est} - \bar{X}_{est}) \cdot (X_{obs} - \bar{X}_{obs})}{\sqrt{\sum(X_{est} - \bar{X}_{est})^2 \cdot \sum(X_{obs} - \bar{X}_{obs})^2}} \quad (21)$$

Em que: \bar{X}_{obs} = média dos valores observados; \bar{X}_{est} = média dos valores estimados.

Calculou-se o coeficiente Nash-Sutcliffe (E), amplamente utilizado em recursos hídricos para avaliar o desempenho de modelo hidrológico (Equação 22) e o valor da diferença do volume total para quantificação do erro para todo o período de análise (Equação 23).

$$E = 1 - \left[\frac{\sum(X_{obs} - X_{est})^2}{\sum(X_{obs} - \bar{X}_{obs})^2} \right] \quad (22)$$

$$\neq Vt = \sum X_{est} - \sum X_{obs} \quad (23)$$

5.3 RESULTADOS E DISCUSSÃO

Este tópico foi subdividido em: vazões calculadas e armazenamentos de água calculados. Cada qual expõem os índices calculados para os diversos cenários e uma breve discussão a respeito dos possíveis fatores de influência.

5.3.1 Vazões calculadas

5.3.1.1 Equação simples

Os gráficos de dispersão para as vazões anuais calculadas com a equação simples estão expressos na Figura 24. Para Q0 e Q1 os menores valores de vazão foram subestimados,

apresentando inclusive valores negativos, ou seja, evapotranspiração maior do que a precipitação, e os maiores valores foram superestimados. Esta tendência é confirmada pelas equações da reta, ambas foram muito similares e apresentaram coeficientes angulares mais baixos, 0,55 para Q0 e 0,53 para Q1. Q2 e Q3 apresentam seus dados muito mais próximos da linha ideal, sendo mais precisos para valores mais baixos de vazão e superestimando os valores mais altos, principalmente Q3.

A vazão calculada no cenário Q2 obteve o melhor desempenho com uma menor dispersão dos dados. Nesta equação, a vazão foi calculada utilizando a precipitação *in situ* e a evapotranspiração via sensoriamento remoto, o que nos permite concluir que são as fontes com menores incertezas nesta análise, o que é plenamente compreensível em razão da abundância de dados de precipitação medidos em campo, em contraponto com a ausência de dados de evapotranspiração. Q3 teve uma superioridade de predição se comparado a Q0, sendo que o primeiro utilizou apenas como fonte de dados o sensoriamento remoto e o segundo apenas dados *in situ*.

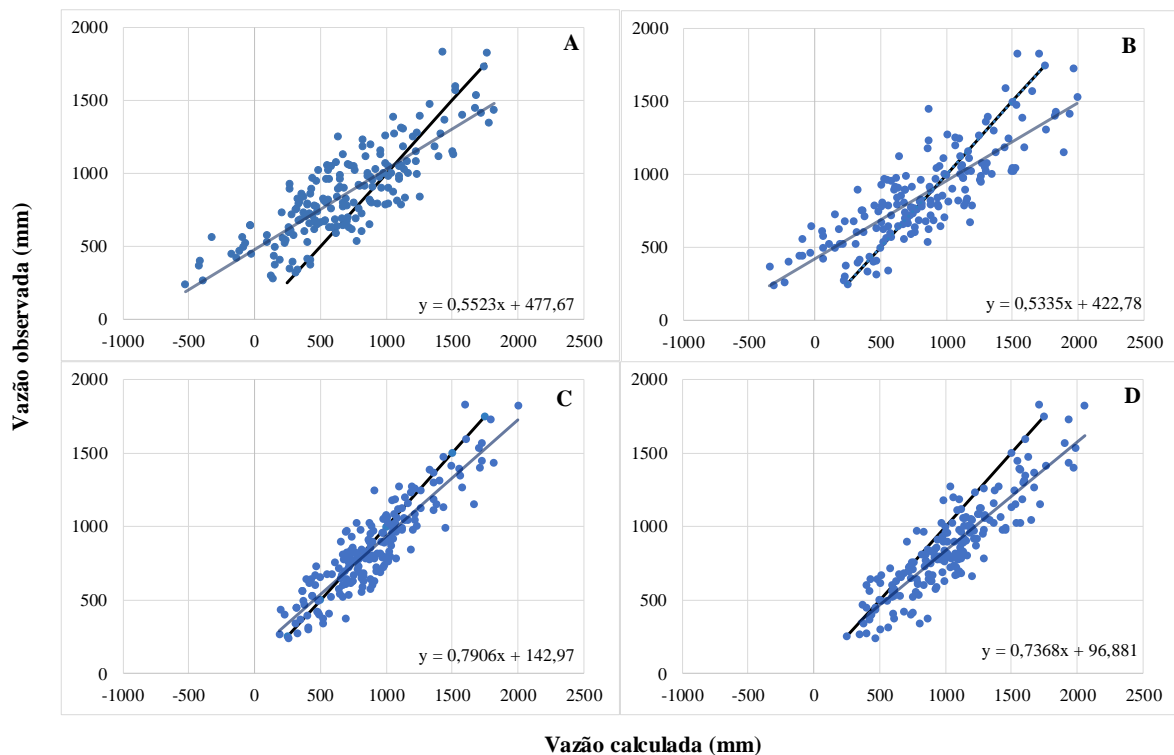



Figura 24. Gráficos de dispersão – vazão calculada pela equação simples X vazão observada. A) Q0; B) Q1; C) Q2; D) Q3.

A partir das vazões calculadas através da Equação 15, foi possível extrair indicadores de desempenho e identificar incertezas associadas a esta variável, por meio da comparação com os dados medidos pelas estações fluviométricas. O Quadro 15 mostra a análise estatística de

Q0, Q1, Q2 e Q3, considerando as 10 bacias em conjunto. Identifica-se um ótimo desempenho dos índices de concordância e coeficientes de correlação, em que as médias ficaram todas acima de 0,8. No que tange ao erro absoluto médio também foram muito satisfatórios, destaca-se Q2 com menores valores de média. Em geral, Q2 e Q3 demonstraram valores mais baixos e com menor amplitude, variando de 74,73 a 211,99 e de 82,29 a 335,10, respectivamente, seguido de Q1 com valores entre 167,01 e 411,90 e com pior desempenho Q0 de 107,95 a 513,78.

Quadro 15. Análise estatística das vazões calculadas pela equação simples ($Q = P - ET$).

ÍNDICES	Q0			Q1		
	Anual			Anual		
	Mín	Méd	Máx	Mín	Méd	Máx
EA médio	107,95	257,35	513,78	167,01	237,99	411,90
EA máximo	306,63	587,27	884,22	414,71	557,20	711,11
r	0,65	0,87	0,95	0,68	0,87	0,96
d	0,70	0,82	0,95	0,77	0,83	0,91
≠Vt	-9761,8	-3240,7	1501,2	-7762,0	-800,6	4576,6
ÍNDICES	Q2			Q3		
	Anual			Anual		
	Mín	Méd	Máx	Mín	Méd	Máx
EA médio	74,73	129,06	211,99	82,29	202,56	335,10
EA máximo	209,57	316,42	518,99	262,89	432,42	608,64
r	0,83	0,90	0,96	0,79	0,89	0,96
d	0,84	0,92	0,97	0,72	0,84	0,97
≠Vt	-1133,4	874,7	3693,0	866,5	3314,8	6366,9



Ao analisar os índices de concordância e coeficiente de correlação obtidos entre as bacias, apenas a bacia B01 apresentou uma leve redução do coeficiente de correlação frente as demais, 0,65 para Q0 e 0,68 para Q1. O que demonstra certa imprecisão associada aos dados de ET *in situ* para esta bacia. Os índices de concordância, ficaram todos acima de 0,7. O que comprova o bom desempenho das vazões calculadas pelas diferentes fontes de dados (Figura 25).




Figura 25. Coeficiente de correlação e índice de concordância para as vazões calculadas pela equação simples.

Os erros absolutos médios de cada bacia podem ser vistos na Figura 26. Na bacia B09 e B10 o erro absoluto médio diminui para Q0 e Q2, e aumenta para Q1 e Q3, ou seja, a precisão dos dados de precipitação *in situ* é maior do que via sensoriamento remoto para grandes áreas, visto que existe grande número de estações meteorológicas no interior destas bacias. Logo, nestes casos, a fonte dos dados de ET não atua significativamente na acurácia da vazão calculada.

Outro destaque é a bacia B03, em que Q2 e Q3 obtiveram erros absolutos médios menores e Q0 e Q1 valores maiores que as demais bacias. Este comportamento pode indicar problemas com os dados de ET *in situ*, visto que a estação meteorológica da qual foi obtida esta variável se encontrava bem distante do local de análise.

No panorama geral, não foi verificado um efeito de escala espacial muito visível, apenas para Q0 que se identificou uma redução dos erros absolutos médios para as bacias de maiores

dimensões (B08, B09 e B10). O que pode estar associado ao fato destas bacias possuírem mais estações meteorológicas no seu interior e conseqüentemente maior precisão dos dados *in situ*.




Figura 26. Erro Absoluto médio para as vazões calculadas pela equação simples.

A Figura 27 demonstra a diferença entre o volume total do período de análise (2000 a 2018) observado pelas estações fluviométricas e o estimado. Q0 e Q1 subestimaram os valores de vazão na maioria das bacias, no entanto para B09 e B10 (bacias de maiores áreas) os valores ficam acima do observado. Em contraponto, Q2 e Q3 superestimam os valores na maioria das bacias, sendo Q3 com uma amplitude maior de diferença histórica. As menores diferenças foram evidenciadas em Q2.




Figura 27. Diferença do volume total para as vazões calculadas pela equação simples.

Com isso, conclui-se que a tendência da diferença histórica é ditada pela fonte de obtenção dos dados de ET, de maneira que a equação que utilizou dados de ET *in situ*

subestimou os valores, com exceção das maiores bacias, e a que utilizou ET via sensoriamento remoto superestimou a vazão.

Q2 apresentou melhor performance ao analisar os indicadores, o que indica que a utilização de ET via sensoriamento remoto diminui as imprecisões se comparado com a ET medida *in situ*, visto que há uma baixa disponibilidade de dados. Esperava-se que Q0 apresentasse melhor previsão, haja vista que os dados de ambas as variáveis da equação foram extraídas em campo, no entanto obteve índices abaixo dos demais, ou seja, as imprecisões das medições *in situ* combinadas amplificaram o erro. Uma melhor alternativa é agregar dados de sensoriamento em condições de baixa disponibilidade de dados observacionais.

As normais para o período de análise para cada cenário de vazão calculada são expostas na Figura 28. Visualiza-se o padrão sazonal da vazão obtida com as diferentes fontes de dados, em que todas foram capazes de reproduzir este padrão comportamental. Q2 e Q3 tendem a superestimar a vazão para o período de abril a julho, atribuindo-se esta evidência a ET via sensoriamento remoto, a qual é utilizada em ambos os cálculos. Q0 e Q1 subestimam as vazões em agosto, associando-se a ET *in situ*, que provavelmente esteja acima do valor real.




Figura 28. Normais mensais de 2000 a 2018 das vazões calculadas pela equação simples.

5.3.1.2 Equação completa

Os gráficos de dispersão dos dados anuais de vazão calculada pela equação completa *versus* vazão podem ser vistos na Figura 29. Q4, Q8, Q9 e Q10 obtiveram uma grande dispersão dos dados e coeficientes angulares baixos, em que os valores baixos de vazão são subestimados e os altos são superestimados. Esta tendência está atrelada principalmente aos dados de

armazenamento proveniente do satélite GRACE. As vazões, Q5, Q6 e Q7 obtiveram um desempenho muito bom, em que os dados se dispõem próximos à reta ideal. No entanto, estes três modelos possuem melhor predição dos valores mais baixos de vazão e tendem a superestimar os valores mais altos. Q5 teve a melhor performance, os dados estão próximos do ideal com coeficiente angular de 0,81. Q6 fica em segundo lugar, com uma inclinação maior da reta. Desta forma, conclui-se que a menor fonte de incertezas proveniente de sensoriamento remoto na equação do balanço hídrico em uma escala anual é a precipitação, seguido da evapotranspiração e da combinação de ambas, por último o armazenamento de água terrestre.

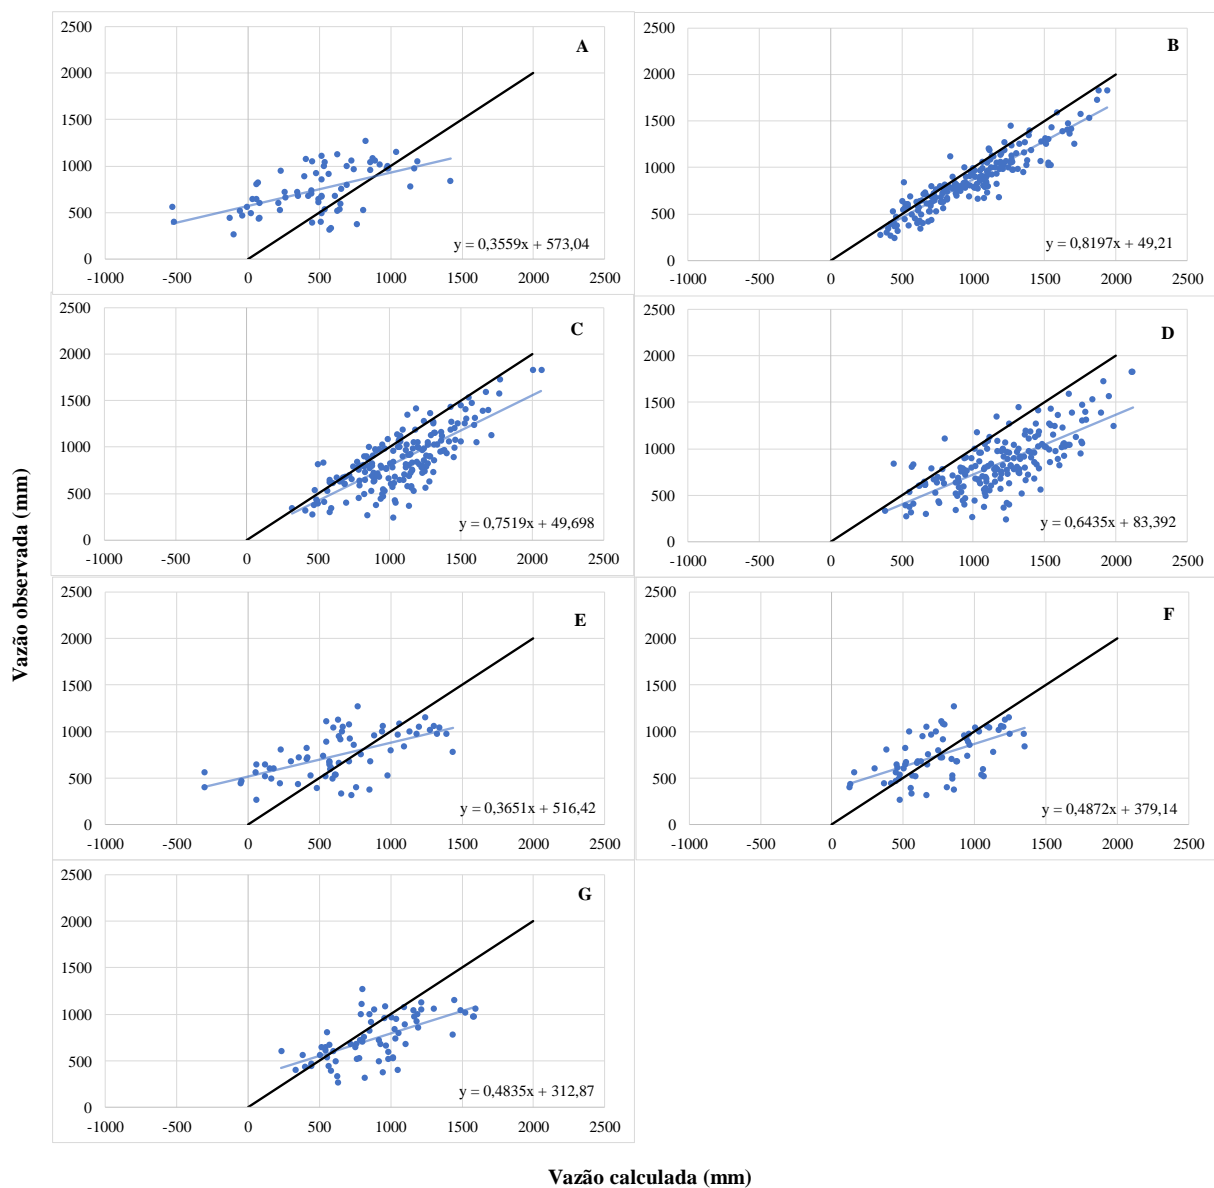


Figura 29. Gráficos de dispersão – vazão calculada pela equação completa X vazão observada. A) Q4; B) Q5; C) Q6; D) Q7; E) Q8; F) Q9; G) Q10.

A análise estatística das vazões calculadas pela Equação 16 com diferentes fontes de dados teve o intuito de verificar as incertezas nestas estimativas. O Quadro 16 traz os valores mínimos, médios e máximos dos índices obtidos.

Em relação aos valores do coeficiente de correlação mensal, os resultados foram de moderados a bons. Ao se utilizar uma variável via sensoriamento remoto na equação apresentaram os seguintes coeficientes: Q4 (0,45 a 0,69), Q5 (0,71 a 0,92); Q6 (0,83 a 0,93); com duas variáveis: Q7 (0,59 a 0,87), Q8 (0,40 a 0,68), Q9 (0,38 a 0,68) e com três variáveis: Q10 (0,33 a 0,65). Para o coeficiente de correlação anual os dados apresentaram maior amplitude de valores, demonstrando desde performance ruim a muito boa em determinadas áreas de estudo.


Q5, Q6 e Q7 obtiveram melhores coeficientes de correlação se comparado aos demais, logo, o armazenamento de água terrestre advindo do satélite GRACE agrega um grande grau de imprecisão a equação, fazendo com que diminua a capacidade de replicação do dado.

Moreira e Ruhoff (2017) ao estimarem o balanço hídrico na América do Sul a partir de dados de sensoriamento remoto, obtiveram valores de variação do armazenamento de água calculado consistentes quando comparados aos dados GRACE. No entanto, os valores mais significativos estavam associados as maiores bacias e localizados mais ao norte da América do Sul (com climas equatorial e tropical), enquanto menores correlações foram encontradas em pequenas bacias na região sul do Brasil (tipicamente em clima subtropical). Observaram que os melhores resultados foram identificados para bacias com áreas maiores e com sazonalidade de precipitação bem definida, o que pode explicar a baixa capacidade de estimativa do armazenamento de água pelo satélite GRACE nas áreas do presente estudo.

Na nossa análise, o erro absoluto médio mensal encontrado foi satisfatório com valores baixos e de pouca amplitude entre as bacias. As piores análises para este índice foram verificadas em Q4 e Q8, as quais possuem em similar dados de ET *in situ* e S via sensoriamento remoto. Ou seja, em termos de quantificação da vazão estas fontes combinadas implicam no aumento dos erros. Para uma escala anual, os valores já apresentam uma amplitude maior, chegando a atingir 661 mm em Q4, no entanto Q5 e Q9 se destacam com menores valores.

Quadro 16. Análise estatística das vazões calculadas pela equação completa.

ÍNDICES	Q4			Q5			Q6			Q7		
	Mensal			Mensal			Mensal			Mensal		
	Mín	Méd	Máx	Mín	Méd	Máx	Mín	Méd	Máx	Mín	Méd	Máx
EA médio	50,55	60,44	75,20	20,56	25,34	31,29	19,66	27,81	40,21	28,04	41,95	53,26
EA máximo	159,34	220,88	290,35	83,85	149,80	261,35	74,11	106,33	153,93	110,64	164,87	285,15
REQM	64,82	75,69	93,14	26,71	34,25	43,35	23,89	33,42	47,57	34,61	51,03	63,89
r	0,45	0,56	0,69	0,71	0,86	0,92	0,83	0,89	0,93	0,59	0,77	0,87
d	0,56	0,67	0,79	0,82	0,91	0,95	0,86	0,91	0,95	0,69	0,82	0,89
E	-2,95	-1,10	0,14	0,15	0,59	0,80	0,38	0,62	0,81	-0,64	0,11	0,56
ÍNDICES	Anual			Anual			Anual			Anual		
	Mín	Méd	Máx	Mín	Méd	Máx	Mín	Méd	Máx	Mín	Méd	Máx
	EA médio	132,83	340,20	661,03	95,35	149,81	235,41	82,49	242,53	454,13	157,89	363,68
EA máximo	351,51	599,00	1092,18	240,23	379,74	522,03	293,86	519,71	783,01	364,54	701,14	992,42
r	-0,07	0,48	0,84	0,87	0,92	0,97	0,55	0,83	0,94	0,42	0,74	0,83
d	0,20	0,53	0,79	0,80	0,90	0,96	0,60	0,77	0,93	0,44	0,65	0,85
≠Vt	-8281,7	-4021,4	-350,0	385,2	2440,1	4367,0	-627,3	4115,4	8628,5	2121,1	6555,5	10628,3
ÍNDICES	Q8			Q9			Q10					
	Mensal			Mensal			Mensal					
	Mín	Méd	Máx	Mín	Méd	Máx	Mín	Méd	Máx			
EA médio	50,81	61,80	73,93	42,37	53,27	66,09	45,96	56,56	67,94			
EA máximo	151,95	213,89	289,74	134,39	207,65	295,80	156,10	219,60	291,21			
REQM	62,23	76,97	92,36	53,49	67,49	83,56	55,92	70,90	85,32			
r	0,40	0,53	0,68	0,38	0,53	0,68	0,33	0,50	0,65			
d	0,55	0,67	0,79	0,58	0,70	0,82	0,55	0,68	0,80			
E	-2,88	-1,17	0,05	-2,18	-0,71	0,31	-2,31	-0,87	0,18			
ÍNDICES	Anual			Anual			Anual					
	Mín	Méd	Máx	Mín	Méd	Máx	Mín	Méd	Máx			
	EA médio	171,67	283,93	485,04	119,32	200,67	245,56	161,54	233,21	395,54		
EA máximo	412,75	553,22	863,03	345,30	451,04	542,22	369,34	534,21	647,09			
r	0,06	0,53	0,78	0,00	0,48	0,72	0,11	0,54	0,73			
d	0,36	0,59	0,79	0,39	0,66	0,80	0,37	0,63	0,78			
≠Vt	-6793,4	-2334,4	1249,9	-2306,4	-894,6	1139,2	-620,2	792,3	3063,0			



Identifica-se uma diferença clara em relação ao coeficiente de correlação, tanto para intervalos mensais como anuais (Figura 30), em que Q5, Q6 e Q7 apresentam valores superiores aos demais, correspondem as equações que não possuem dados de armazenamento de água terrestre via sensoriamento remoto, o que nos permite concluir que a maioria das imprecisões estão associadas a essa fonte. Com valores mais baixos para escala mensal Q4, apesar de incluir dados de *S* via sensoriamento remoto, as demais variáveis provêm de medições *in situ* reduzindo as incertezas. No entanto em escala anual o mesmo não é observado, cada bacia apresenta um comportamento diferente. A maioria dos valores mínimos de *r* anual foram evidenciados na bacia B06, com exceção de Q9 e Q10, a qual foi atrelada a bacia B10.

A respeito de um padrão entre as bacias, não foi possível identificar uma influência da escala espacial. O que se observa é que para as menores bacias (B01 e B02) o *r* mensal de Q6 ficou bem superior as demais estimativas. Esta equação utilizou dados *in situ* de armazenamento de água terrestre e de precipitação, e agregou dados de sensoriamento remoto para evapotranspiração. Por se tratar de pequenas bacias o uso do sensoriamento remoto para estimativa de ET diminuiu a imprecisão desta variável, visto que os dados em terra são insuficientes para representação real da bacia.




Figura 30. Coeficiente de correlação para as vazões calculadas pela equação completa.

Os índices de concordância para cada bacia de estudo em escala mensal e anual são mostrados na Figura 31. Na escala mensal foi identificado o mesmo comportamento que o coeficiente de correlação, em que Q5, Q6 e Q7 se destacam com valores mais altos. Em escala anual, tanto para índice de concordância como para o coeficiente de correlação, Q5 apresenta melhor performance que as demais vazões calculadas, seguido de Q6. Ou seja, para períodos maiores agregar dados de precipitação via sensoriamento remoto traz resultados melhores do que agregar dados de evapotranspiração via sensoriamento remoto. A combinação de ambas causa uma queda da capacidade de replicação da realidade.




Figura 31. Índice de concordância para as vazões calculadas pela equação completa.

O coeficiente Nash-Sutcliffe varia de $-\infty$ a 1. Quanto mais próximo a 1, mais eficiente é o modelo de predição, se menor que zero significa que a média dos valores observados é melhor do que os valores preditos. Verificou-se que para Q4, Q8, Q9 e Q10 este índice teve uma predominância de valores negativos, com exceção da bacia B04 e B05 com valores foram positivos. Para Q5 e Q6 todos valores foram acima de zero, mostrando a validade da estimativa. Q7 também obteve valores positivos, no entanto para B06 e B08 estes valores ficaram abaixo de zero (Figura 32).

No que concerne as diferenças da quantificação no período de análise (Figura 33) é evidente a superestimativa por parte de Q7, seguido de Q6 e Q5. Este fato nos permite aferir que a maior influência na superestimativa dos valores está associada a ET via sensoriamento remoto, e em segundo a precipitação por satélite. Q4 se destaca na subestimativa dos dados, assim como Q8 e Q9.




Figura 32. Coeficiente Nash-Sutcliffe para as vazões calculadas pela equação completa.

Nesta análise, com um intervalo de tempo longo, evidencia-se a influência do efeito de escala, em que B09e B10, bacias de grandes dimensões, possuem erros reduzidos em comparação as demais. A bacia B03apresentou os maiores erros e B01, apesar do seu tamanho reduzido, conferiu valores baixos.

Além disso, para este período, a aplicação de dados de sensoriamento remoto se torna uma alternativa melhor do que o uso de dados *in situ*. Os erros diminuem significativamente, principalmente nas áreas maiores, com desempenhos superiores devido à resolução espacial destes produtos. Ao contrário das demais análises, para um intervalo de tempo longo e uma escala espacial grande, é possível a utilização dos dados de armazenamento de água terrestre do satélite GRACE, visto que houve uma redução dos erros para tais estimativas.

Sheffield *et al.* (2009) usaram estimativas de precipitação, evapotranspiração e variação do armazenamento de água por sensoriamento remoto para calcular o fechamento do balanço de água terrestre para a bacia do Mississippi entre 2003 e 2005. Concluíram que alcançar o fechamento do orçamento por sensores remotos ainda não era possível, em razão dos grandes

vieses na estimativa de precipitação detectada remotamente e na grande incerteza do armazenamento de água terrestre detectado remotamente.

Isso também foi identificado no presente estudo em relação a variação do armazenamento terrestre obtido por satélite para intervalos pequenos (mensais e anuais), porém a precipitação não atuou significativamente neste resultado. No entanto, em um longo período – neste caso, 19 anos – os valores estimados por sensoriamento remoto chegam muito próximos dos valores medidos em campo, obtendo uma diferença de apenas 13,67 mm na bacia B05 e 112,95 mm em B07 para Q10, a qual utilizou-se essencialmente dados de sensoriamento remoto.




Figura 33. Diferença do volume total para as vazões calculadas pela equação completa.

Nas normais mensais calculadas para o período de 2000 a 2018 (Figura 34), evidencia-se a reprodução do padrão comportamental da vazão, no entanto algumas discrepâncias são evidenciadas. Q4 tende a subestimar esta variável, principalmente de julho a dezembro, Q7 superestima os dados durante todo o ano. Q8, Q9 e Q10 ficam abaixo da Q observada de outubro a dezembro. As maiores diferenças para todas as vazões calculadas foram identificadas em agosto, sendo que Q4, Q8, Q9 e Q10 ficam abaixo da observada, este fato pode indicar uma resposta mais lenta do armazenamento de água por sensoriamento remoto, visto que é um mês de redução dos valores de vazão. Os meses de melhores estimativas foram fevereiro e março.

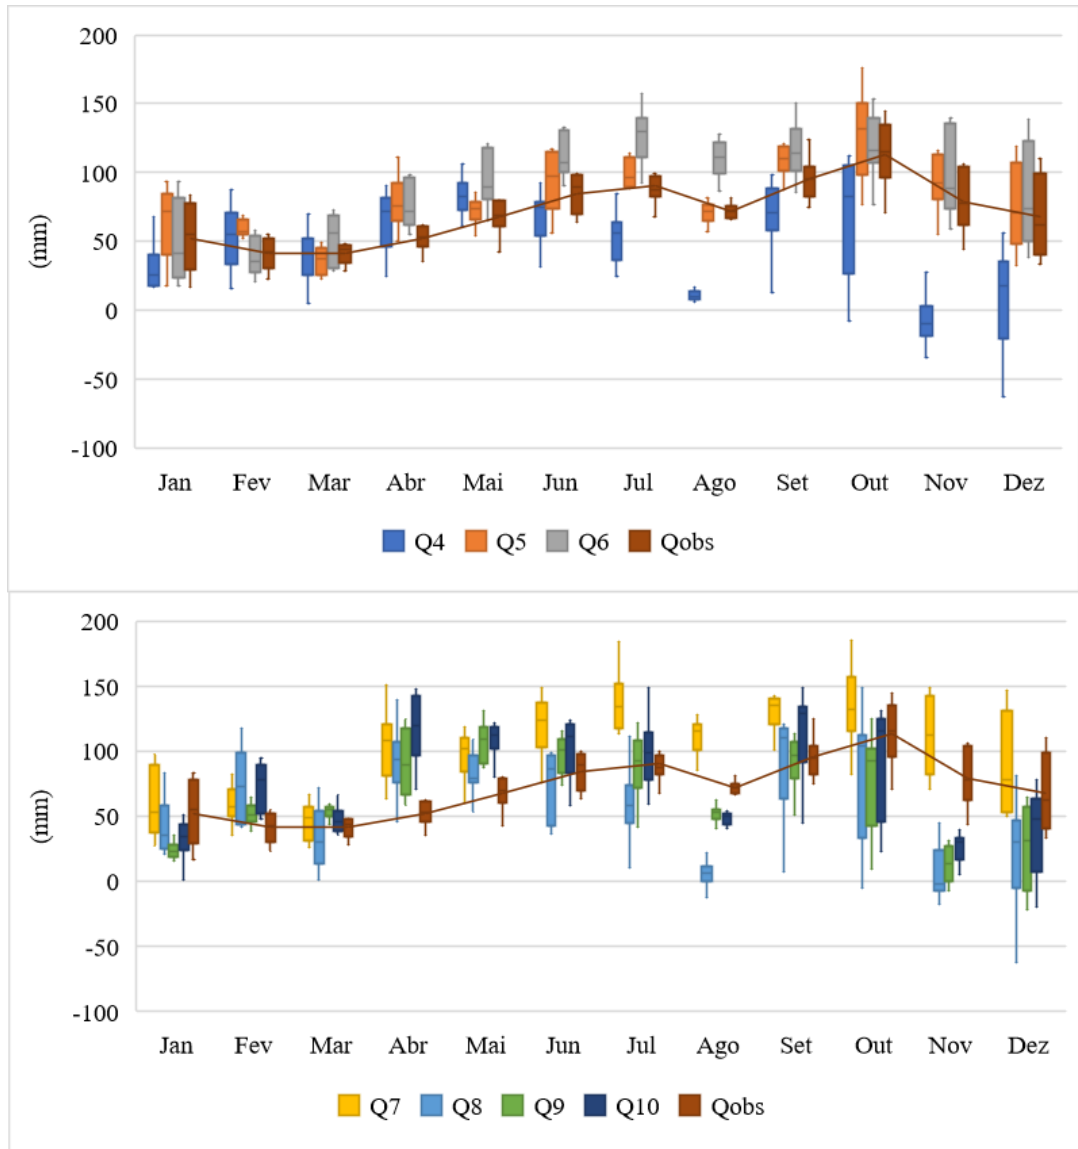


Figura 34. Normais mensais de 2000 a 2018 das vazões calculadas pela equação completa.

5.3.2 Armazenamentos de água calculados

A Figura 35 exibe os gráficos de dispersão entre os dados estimados e dados observados do armazenamento de água terrestre em escala anual. O cenário S1 demonstrou uma performance superior a S2 e S3, sendo S3 o que apresentou maior dispersão dos dados no entorno da reta ideal, o que está de acordo com o esperado, visto que no cálculo de S3 foram incorporadas duas variáveis provenientes de sensoriamento remoto.

A partir das linhas de tendência identificou-se: para S1 quanto menor os valores de armazenamento de água, melhor a precisão do modelo, ou seja, para valores altos de armazenamento de água, há um aumento nos erros; S2 possui um coeficiente angular muito

próximo a 1, isso significa que quando há um aumento dos dados observados, os dados estimados aumentam na mesma proporção, no entanto há um deslocamento da reta o que faz com que os dados apresentem um erro constante nos valores; em S3 nota-se uma maior dispersão dos dados e, conseqüentemente, um aumento no erro absoluto.





Figura 35. Gráfico de dispersão – armazenamentos de água terrestre calculados X armazenamento de água terrestre observada. A)S1; B)S2; C)S3.

Os resultados da análise estatística dos armazenamentos de água terrestre calculados estão no Quadro 17. Os três modelos de estimativa apresentaram uma boa predição, em que os índices de concordância e coeficientes de correlação, em geral, apresentaram valores de moderados a bons. Há uma pequena redução destes indicadores em uma escala anual se comparado com os intervalos mensais. O coeficiente Nash-Sutcliffe também teve resultados favoráveis para S1 e S2. Em S3, três das bacias de análise demonstram valores negativos, ou seja, o modelo não foi efetivo na replicação dos dados nestas bacias.

Quadro 17. Análise estatística dos armazenamentos de água calculados.

ÍNDICES	S1			S2			S3		
	Mensal			Mensal			Mensal		
	Mín	Méd	Máx	Mín	Méd	Máx	Mín	Méd	Máx
EA médio	20,56	25,34	31,29	19,66	27,81	40,21	28,04	41,95	53,26
EA máximo	83,85	149,80	261,35	74,11	106,33	153,93	110,64	164,87	285,15
REQM	26,71	34,25	43,35	23,89	33,42	47,57	34,61	51,03	63,89
r	0,77	0,88	0,94	0,76	0,90	0,95	0,56	0,76	0,89
d	0,87	0,92	0,96	0,80	0,91	0,96	0,68	0,81	0,91
E	0,48	0,68	0,85	0,29	0,69	0,87	-0,28	0,29	0,74
ÍNDICES	Anual			Anual			Anual		
	Mín	Méd	Máx	Mín	Méd	Máx	Mín	Méd	Máx
	EA médio	95,35	149,81	235,41	82,49	242,53	454,13	157,89	363,68
EA máximo	240,23	379,74	522,03	293,86	519,71	783,01	364,54	701,14	992,42
r	0,68	0,84	0,93	0,44	0,65	0,87	-0,11	0,38	0,65
d	0,59	0,82	0,94	0,44	0,63	0,85	0,32	0,48	0,65
≠Vt	385,2	2440,1	4367,0	-627,3	4115,4	8628,5	2121,1	6555,5	10628,3



Os erros absolutos médios mensais foram muito aceitáveis em termos de armazenamento: S1(20,6 a 31,3mm), S2(19,7 a 40,2mm) e S3(28,0 a 53,3). A performance em relação aos erros dos valores apresentou a seguinte relação: $S1 < S2 < S3$. O mesmo é verificado em escala anual: S1 (95,35 a 235,41mm), S2 (82,49 a 454,13mm) e S3 (157,89 a 559,38). Além dos menores valores em S1, sua amplitude entre as bacias é bem reduzida em comparação as demais. Como já suposto, a precipitação via sensoriamento remoto tem uma alta precisão nas estimativas para ambas escalas temporais, demonstrando uma boa fonte de dados a ser utilizada no cálculo do balanço hídrico.

Ao analisar os coeficientes de correlação e índices de concordância dos armazenamentos de água terrestre calculados por bacia de estudo (Figura 36 e Figura 37) nota-se que em escala mensal S2 demonstrou uma performance levemente superior a S1 em ambos os indicadores, principalmente para pequenas bacias. No entanto, em escala anual, S1 se destacou na maioria das bacias com valores mais altos que S2. O que nos induz a conclusão de que a variável precipitação via sensoriamento remoto tem um bom desempenho tanto mensal como anual, em contraste a evapotranspiração por sensoriamento remoto que tem uma queda de desempenho em escala anual.




Figura 36. Coeficiente de correlação dos armazenamentos de água terrestre calculados por bacia de estudo.




Figura 37. Índice de concordância dos armazenamentos de água terrestre calculados por bacia de estudo.

O cenário S3 apresenta performance inferior as demais, porém com menores diferenças em escala mensal. Em escala anual esta diferença é mais acentuada, principalmente a respeito do coeficiente de correlação, apresentando, até mesmo, valores negativos na bacia B05 e B06. Este cenário agrega duas fontes de incerteza, amplificando as discordâncias, sendo que a ET por sensoriamento remoto não apresenta bons resultados em escala anual.

De maneira geral, os valores entre as bacias não divergiram muito em escala mensal. Anualmente houve uma maior variação, sendo as maiores diferenças entre os produtos nas bacias de tamanhos intermediários.

Os erros absolutos médios mensais e anuais (Figura 38), como já mencionados, são maiores em S3, tanto em escala mensal como anual. O cenário S1 demonstra menores erros em relação às demais estimativas de armazenamento em escala anual. Se destaca a bacia B03 com maiores erros, seguido de B02 que são bacias relativamente pequenas. Com valores mais baixos de erros anuais para os três modelos, B09 e B10 evidenciam um efeito de escala, sabendo-se que estas são as maiores bacias.




Figura 38. Erros absolutos médios dos armazenamentos de água terrestre calculados por bacia de estudo.

Na Figura 39 visualiza-se a diferença do somatório total dos armazenamentos de água estimados e observados para o período de 2000 a 2018. Condizente com os maiores erros, S3 possui as maiores diferenças. Outro ponto de destaque é que as três estimativas apresentam uma

tendência, em longo prazo, de superestimativa dos valores, em que apenas S2 apresentou valores negativos para duas bacias. É evidente a redução das diferenças em S2 e S3 nas bacias de maiores escalas espaciais (B09 e B10). O mesmo não é observado em S1, ou seja, o efeito escala age sobre a evapotranspiração obtida por satélite.




Figura 39. Diferença do volume total dos armazenamentos de água terrestre calculados por bacia de estudo para o ano de 2000 a 2018.

Além da diferença no volume total, outro dado importante de se analisar é o somatório dos armazenamentos de água no período de análise (2000 - 2018), conforme Figura 40.

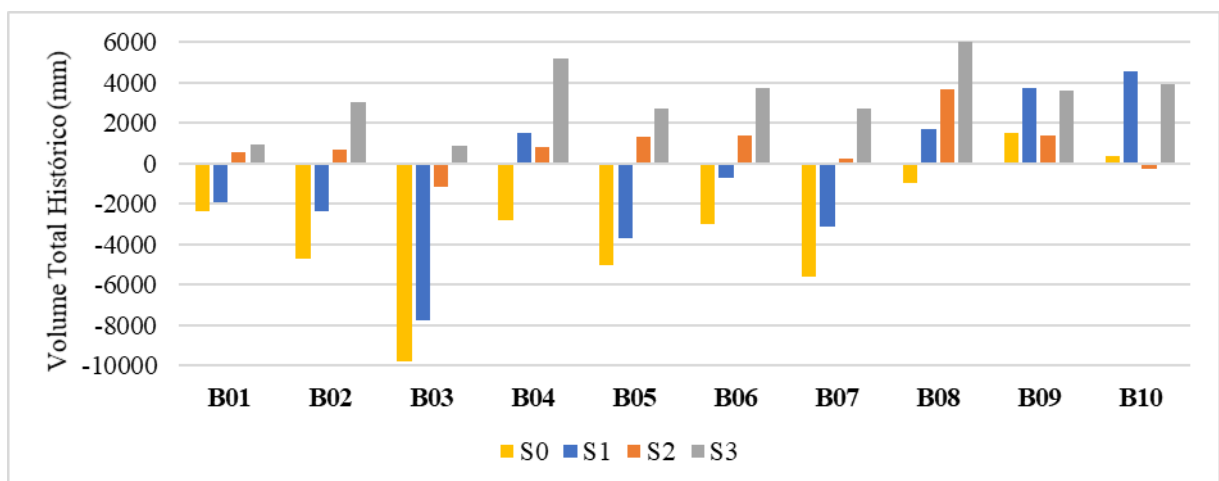


Figura 40. Volume total do período histórico de 2000 a 2018 dos armazenamentos de água terrestre calculados por bacia de estudo.

O modelo com melhores resultados foi S2, o qual se utilizou dados de evapotranspiração advindos de sensoriamento remoto. Isto nos induz a afirmar que agregar dados de

sensoriamento remoto no cálculo de armazenamento de água para um intervalo de tempo grande pode aumentar a acurácia da predição desta variável.

A respeito do padrão sazonal do armazenamento de água e possíveis períodos mais tendenciosos, calculou-se a normal mensal para o período de 2000 a 2018, Figura 41. Em geral todas estimativas de armazenamento de água representaram o comportamento sazonal desta variável muito bem, S1 foi o que se destacou com maior similaridade com os dados observados. S2 e S3 apresentam maior superestimativa entre abril e setembro, o que possivelmente está atrelado as limitações da evapotranspiração via sensoriamento remoto. Os três modelos tiveram maior precisão de janeiro a março.




Figura 41. Normais mensais de 2000 a 2018 do armazenamento de água terrestre calculado.

5.4 CONCLUSÕES

Neste trabalho foi possível identificar as maiores fontes de incertezas no cálculo do balanço hídrico integrando dados *in situ* e observados por satélite, além de verificar os efeitos de escala espacial em diferentes intervalos de tempo.

Ao aplicar a equação reduzida do balanço hídrico, Q0 e Q1 subestimaram os menores valores de vazão, o que se atrela a superestimativa da ET medida *in situ*. Q2 e Q3 foram mais precisos para valores mais baixos de vazão e superestimaram os valores mais altos. Para as quatro estimativas, obteve-se um ótimo desempenho dos índices de concordância e coeficientes de correlação.

Não foi verificado um efeito de escala espacial, Q0 teve uma redução dos erros absolutos médios para as bacias maiores, visto que estas bacias possuíam mais estações meteorológicas no seu interior e os produtos utilizados possuíam resolução espacial mais grosseira. A tendência da diferença histórica é ditada pela ET, quando se utilizou a ET *in situ* houve uma subestimativa dos valores, e quando se utilizou ET via sensoriamento remoto superestimou a vazão. Q2 apresentou melhor performance ao analisar os indicadores, o que indica que a utilização de ET via sensoriamento remoto é uma alternativa viável quando há escassez destes dados em campo. Em geral, todas estimativas foram capazes de reproduzir o padrão comportamental da vazão, porém recomendaríamos na seguinte ordem: Q2>Q3>Q0>Q1, considerando a situação de disponibilidade de dados de campo do trabalho atual.

Ao obter o balanço hídrico pela equação completa, evidenciou-se que a menor fonte de incertezas proveniente de sensoriamento remoto em uma escala anual foi a precipitação, seguido da evapotranspiração e da combinação de ambas, por último o armazenamento de água terrestre. Q5, Q6 e Q7 obtiveram um desempenho na predição da vazão muito bom, visto que seus índices foram bem superiores as demais estimativas.

As equações que utilizaram dados de sensoriamento remoto na estimativa do armazenamento de água terrestre apresentaram coeficiente Nash-Sutcliffe para intervalos mensais ruins, não sendo capazes de quantificar e representar o comportamento desta variável de forma satisfatória. No entanto, a respeito das diferenças do somatório das vazões no período histórico, a aplicação de dados de sensoriamento remoto de armazenamento de água se torna uma alternativa melhor do que o uso de dados *in situ*, em que os erros diminuem significativamente, principalmente nas maiores bacias. Logo sugerimos o uso dos cenários na seguinte ordem: Q5>Q6>Q7, tanto em escala mensal quanto anual, não sendo recomendado os demais modelos para predição de vazão.

Ao estimar o armazenamento de água terrestre, os três modelos apresentaram uma boa predição, os índices de concordância e coeficientes de correlação demonstraram valores de moderados a bons, sendo superiores em escala mensal em relação a anual. S3 apresenta sua performance inferior as demais, porém esta diferença é mais acentuada em escala anual. Evidencia-se uma redução dos erros absolutos anuais para bacias maiores. Em geral, todas as estimativas de armazenamento de água representaram o comportamento sazonal desta variável muito bem, em que S1 foi o que se destacou com maior similaridade com os dados observados, a qual utilizava dados de precipitação via sensoriamento remoto, sendo a variável com menor imprecisão. Elencamos do melhor ao pior desempenho: S1>S2>S3.

5.5 REFERÊNCIAS BIBLIOGRÁFICAS

AHMED, S. A. *et al.* Evaluation of morphometric parameters derived from ASTER and SRTM DEM—a study on Bandihole sub-watershed basin in Karnataka. *Journal of the Indian society of remote sensing*, v. 38, n. 2, p. 227-238, 2010.

AIRES, Uilson Ricardo Venâncio; NETO, José de Oliveira Melo; DE MELLO, Carlos Rogério. Estimativas de precipitação pluvial derivadas do sensor TRMM para a bacia hidrográfica do rio paraopeba. *Scientia Agraria*, v. 17, n. 2, p. 57-66, 2017.

ALSDORF, Douglas E.; RODRÍGUEZ, Ernesto; LETTENMAIER, Dennis P. Measuring surface water from space. *Reviews of Geophysics*, v. 45, n. 2, 2007.

ALVES SOBRINHO, Teodorico *et al.* Delimitação automática de bacias hidrográficas utilizando dados SRTM. *Engenharia Agrícola*, v. 30, n. 1, p. 46-57, 2010.

BASTIAANSEN, Wim GM; CHANDRAPALA, L. Water balance variability across Sri Lanka for assessing agricultural and environmental water use. *Agricultural water management*, v. 58, n. 2, p. 171-192, 2003.

BRUBACHER, João Paulo *et al.* Avaliação de bases SRTM para extração de variáveis morfométricas e de drenagem. *Revista Geociências*, v. 31, n. 3, p. 381-393, 2012.

DARAND, Mohammad; AMANOLLAHI, Jamil; ZANDKARIMI, Soma. Evaluation of the performance of TRMM Multi-satellite Precipitation Analysis (TMPA) estimation over Iran. *Atmospheric Research*, v. 190, p. 121-127, 2017.

D'ANGIOLELLA, Gustavo; VASCONCELLOS, Vânia Lúcia Dias; ROSA, José Wilson Corrêa. Estimativa e espacialização do balanço hídrico na mesorregião sul da Bahia. *Simpósio Brasileiro de Sensoriamento Remoto*, v. 12, p. 83-90, 2005. FARR, Tom G. *et al.* The shuttle radar topography mission. *Reviews of geophysics*, v. 45, n. 2, 2007.

FARR, Tom G. *et al.* The shuttle radar topography mission. *Reviews of geophysics*, v. 45, n. 2, 2007.

FELIX LANDERER. 2019. JPL TELLUS GRACE-FO Level-3 Monthly Land Water-Equivalent-Thickness Surface-Mass Anomaly Release 6.0 in netCDF/ASCII/GeoTIFF Formats. Ver. 6.0. PO.DAAC, CA, USA. Disponível em: <https://doi.org/10.5067/GFLND-3AJ06>. Acesso em: Set. 2019.

GAO, Huilin *et al.* Estimating the water budget of major US river basins via remote sensing. *International Journal of Remote Sensing*, v. 31, n. 14, p. 3955-3978, 2010.

KRAUSE, P.; BOYLE, D. P.; BASE, F. Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences*, v. 5, p. 89-97, 2005.

LOPES, Iug; LEAL, Brauliro G.; RAMOS, Clovis MC. Morphometric characterization of the basin in the semi-arid region of Pernambuco using SRTM data in free software. **Journal of Hyperspectral Remote Sensing**, v. 8, p. 31-40, 2018.

MARTENS, Brecht *et al.* GLEAM v3: Satellite-based land evaporation and root-zone soil moisture. **Geoscientific Model Development**, v. 10, n. 5, p. 1903-1925, 2017.

MCCABE, M. F. *et al.* Hydrological consistency using multi-sensor remote sensing data for water and energy cycle studies. **Remote Sensing of Environment**, v. 112, n. 2, p. 430-444, 2008.

MOREIRA, Adriana Aparecida *et al.* Balanço hídrico no Pantanal: uma abordagem por sensoriamento remoto. *In: 7º Simpósio de Geotecnologias no Pantanal*, 2018, Jardim, MS. Anais... Jardim: Embrapa Informática Agropecuária/INPE, 2018, p. 695-704

MOREIRA, Adriana Aparecida; RUHOFF, Anderson Luis. Análise do balanço hídrico na América do Sul por sensoriamento remoto. **Simpósio Brasileiro de Recursos Hídricos (22.: Florianópolis, 2017)**. Anais [recurso eletrônico]. [Porto Alegre: ABRH, 2017], 2017.

NASTOS, P. T.; KAPSOMENAKIS, J.; PHILANDRAS, K. M. Evaluation of the TRMM 3B43 gridded precipitation estimates over Greece. **Atmospheric Research**, v. 169, p. 497-514, 2016.

PAIVA, Rodrigo Cauduro Dias de; RUHOFF, Anderson Luis. Desafios na estimativa do ciclo hidrológico terrestre por sensoriamento remoto. **Simpósio Brasileiro de Recursos Hídricos (22.: Florianópolis, 2017)**. Anais [recurso eletrônico]. [Porto Alegre: ABRH, 2017], 2017.

PAN, Ming *et al.* Multisource estimation of long-term terrestrial water budget for major global river basins. **Journal of Climate**, v. 25, n. 9, p. 3191-3206, 2012.

PORTO, Klayre Garcia; FERREIRA, Idelvone Mendes. Gestão das bacias hidrográficas urbanas e a importância dos ambientes ciliares. **Geografia em Questão**, v. 5, n. 2, 2012.

SATGÉ, F. *et al.* Accuracy assessment of SRTM v4 and ASTER GDEM v2 over the Altiplano watershed using ICESat/GLAS data. **International Journal of Remote Sensing**, v. 36, n. 2, p. 465-488, 2015.

SCALCO, Patricia Andréia Paiola *et al.* Validação do modelo digital de elevação (SRTM) com levantamento GNSS aplicado à bacia hidrográfica da Lagoa Mirim. **Bol. Ciênc. Geod. [online]**. 2018, vol.24, n.3, p.407-425. ISSN 1413-4853, 2018.

SENTELHAS, P. C. *et al.* Balanços hídricos climatológicos do Brasil. **Piracicaba: Esalq/USP**, v. 1, 1999.

SHEFFIELD, Justin *et al.* Closing the terrestrial water budget from satellite remote sensing. **Geophysical Research Letters**, v. 36, n. 7, 2009.

SOARES, Pétrick Anderson *et al.* Estimativa da disponibilidade hídrica em pequenas bacias hidrográficas com escassez de dados fluviométricos. **Revista de estudos ambientais**, v. 12, n. 1, p. 29-38, 2010.

SU, Fengge; HONG, Yang; LETTENMAIER, Dennis P. Evaluation of TRMM Multisatellite Precipitation Analysis (TMPA) and its utility in hydrologic prediction in the La Plata Basin. **Journal of Hydrometeorology**, v. 9, n. 4, p. 622-640, 2008.

TANG, Qihong *et al.* Dynamics of terrestrial water storage change from satellite and surface observations and modeling. **Journal of Hydrometeorology**, v. 11, n. 1, p. 156-170, 2010.

THOMAS, Alys C. *et al.* A GRACE-based water storage deficit approach for hydrological drought characterization. **Geophysical Research Letters**, v. 41, n. 5, p. 1537-1545, 2014.

TROCH, Peter *et al.* New data sets to estimate terrestrial water storage change. **Eos, Transactions American Geophysical Union**, v. 88, n. 45, p. 469-470, 2007.

Tropical Rainfall Measuring Mission (TRMM) (2011). TRMM (TMPA/3B43) Rainfall Estimate L3 1 month 0.25 degree x 0.25 degree V7, Greenbelt, MD, Goddard Earth Sciences Data and Information Services Center (GES DISC), Disponível em: <https://disc.gsfc.nasa.gov/datasets/TRMM_3B43_7/summary>. Acesso em: Set. 2019.

WANG, Gefei *et al.* Evaluation of precipitation from CMORPH, GPCP-2, TRMM 3B43, GPCC, and ITPCAS with ground-based measurements in the Qinling-Daba Mountains, China. **PloS one**, v. 12, n. 10, p. e0185147, 2017.

5.6 APÊNDICES

Apêndice A – Índices estatísticos de Q0 para cada bacia de estudo.

Q0										
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	248,26	328,98	513,78	185,68	298,13	237,62	323,25	183,60	146,28	107,95
EA máximo	670,28	673,39	884,22	611,89	578,83	589,42	653,51	465,96	438,58	306,63
R	0,65	0,90	0,92	0,84	0,95	0,72	0,93	0,93	0,89	0,93
D	0,76	0,78	0,70	0,86	0,87	0,71	0,81	0,89	0,89	0,95
≠Vt	-2330,47	-4731,79	-9761,84	-2826,57	-5046,61	-3002,59	-5596,05	-981,08	1501,25	368,98

Apêndice B – Índices estatísticos de Q1 para cada bacia de estudo.

Q1										
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	205,36	252,22	411,90	167,01	225,46	176,74	262,97	201,21	210,28	266,72
EA máximo	670,13	586,72	711,11	459,80	584,85	414,71	595,24	441,70	483,72	624,03
R	0,68	0,90	0,93	0,82	0,96	0,76	0,92	0,93	0,92	0,84
D	0,79	0,85	0,77	0,88	0,91	0,81	0,86	0,88	0,83	0,77
≠Vt	-1945,30	-2348,13	-7762,02	1540,40	-3693,20	-684,26	-3100,14	1692,77	3717,69	4576,58

Apêndice C – Índices estatísticos de Q2 para cada bacia de estudo.

Q2										
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	159,53	171,92	110,73	120,44	108,80	101,68	101,00	211,99	129,78	74,73
EA máximo	345,47	384,28	266,96	334,90	281,85	262,71	253,57	518,99	305,93	209,57
R	0,83	0,85	0,94	0,87	0,96	0,89	0,95	0,92	0,88	0,94
D	0,90	0,89	0,96	0,92	0,97	0,90	0,97	0,84	0,91	0,97
≠Vt	565,76	680,57	-1133,36	837,57	1351,68	1390,44	213,72	3693,03	1405,90	-258,30

Apêndice D – Índices estatísticos de Q3 para cada bacia de estudo.

Q3										
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	145,79	206,12	82,29	298,25	155,16	195,20	172,40	335,10	193,93	241,32
EA máximo	289,89	504,02	262,89	608,64	357,00	359,20	454,06	570,52	370,44	547,50
R	0,85	0,87	0,96	0,81	0,96	0,93	0,93	0,91	0,92	0,79
D	0,91	0,85	0,97	0,73	0,94	0,78	0,91	0,72	0,84	0,77
≠Vt	950,93	3064,23	866,46	5204,54	2705,09	3708,77	2709,64	6366,89	3622,35	3949,30

Apêndice E – Índices estatísticos de Q4 para cada bacia de estudo.

Q4										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	55,65	75,20	70,52	52,53	63,48	52,50	68,34	61,05	54,56	50,55
EA máximo	274,62	237,67	217,29	246,25	290,35	159,34	219,06	184,72	180,26	199,22
REQM	69,89	93,14	84,87	67,49	82,09	65,18	85,56	75,15	68,68	64,82
R	0,52	0,45	0,60	0,67	0,69	0,55	0,58	0,47	0,53	0,51
D	0,65	0,56	0,66	0,79	0,78	0,67	0,67	0,59	0,68	0,67
E	-1,21	-2,95	-0,70	0,14	-0,08	-0,92	-1,10	-2,48	-0,88	-0,85
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	329,92	374,21	661,03	261,96	413,76	340,79	417,69	254,82	132,83	215,03
EA máximo	584,85	670,13	1092,18	449,20	755,07	582,44	719,41	398,65	386,56	351,51
R	0,54	0,29	0,64	0,84	0,55	-0,07	0,44	0,77	0,66	0,15
D	0,53	0,45	0,35	0,79	0,54	0,20	0,48	0,71	0,78	0,43
≠Vt	-2360,22	-5396,42	-8281,71	-3568,11	-5971,14	-3962,12	-6149,37	-2605,37	-349,983	-1569,22

Apêndice F – Índices estatísticos de Q5 para cada bacia de estudo.

Q5										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	27,98	31,29	26,17	28,61	23,54	21,08	22,36	21,09	20,56	30,74
EA	261,35	217,16	192,34	134,17	135,94	98,00	139,24	88,99	83,85	146,93
REQM	38,19	43,35	36,47	36,81	32,05	28,49	31,27	26,81	26,71	42,34
R	0,76	0,71	0,88	0,92	0,91	0,89	0,90	0,87	0,89	0,81
D	0,87	0,82	0,93	0,94	0,95	0,93	0,94	0,91	0,94	0,86
E	0,46	0,15	0,70	0,74	0,80	0,68	0,71	0,58	0,74	0,29
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	95,35	151,43	119,32	235,41	125,36	130,33	151,20	140,73	120,58	228,40
EA	325,41	337,49	240,23	503,75	409,72	370,18	403,59	374,77	310,19	522,03
R	0,91	0,90	0,97	0,89	0,93	0,88	0,94	0,94	0,95	0,87
D	0,95	0,90	0,96	0,82	0,95	0,84	0,93	0,90	0,92	0,80
≠Vt	385,17	2383,66	1999,82	4366,97	1353,41	2318,33	2495,92	2673,86	2216,44	4207,60

Apêndice G – Índices estatísticos de Q6 para cada bacia de estudo.

Q6										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	19,89	29,82	40,21	26,10	32,78	31,09	30,94	25,63	19,66	22,02
EA máximo	74,61	121,20	153,93	95,21	115,35	143,49	112,58	97,80	75,03	74,11
REQM	23,89	35,41	47,57	31,83	38,28	39,72	36,31	30,58	24,03	26,60
R	0,93	0,84	0,90	0,93	0,93	0,83	0,90	0,85	0,90	0,88
D	0,95	0,86	0,88	0,95	0,93	0,87	0,90	0,87	0,95	0,93
E	0,79	0,43	0,49	0,81	0,72	0,38	0,61	0,45	0,79	0,72
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	168,54	293,29	454,13	193,77	341,22	239,79	312,00	250,33	82,49	89,73
EA máximo	453,76	579,51	783,01	358,86	650,01	643,57	593,34	529,67	293,86	311,54
R	0,90	0,76	0,85	0,94	0,89	0,55	0,84	0,86	0,87	0,89
D	0,88	0,65	0,67	0,85	0,76	0,60	0,71	0,73	0,92	0,93
≠Vt	2896,23	5412,36	8628,49	3664,13	6398,29	4393,03	5809,77	4674,11	-95,35	-627,28

Apêndice H – Índices estatísticos de Q7 para cada bacia de estudo.

Q7										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	35,42	49,19	53,26	45,02	44,92	42,02	44,85	39,33	28,04	37,43
EA máximo	285,15	180,72	201,41	144,42	137,52	164,49	151,47	110,64	116,39	156,45
REQM	46,02	60,20	63,89	53,48	53,35	54,47	52,05	45,40	34,61	46,83
R	0,69	0,59	0,80	0,87	0,84	0,75	0,82	0,77	0,81	0,75
D	0,82	0,69	0,81	0,88	0,87	0,80	0,83	0,78	0,89	0,83
E	0,21	-0,64	0,09	0,45	0,46	-0,16	0,20	-0,20	0,56	0,13
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	223,22	423,84	559,38	424,73	440,93	353,23	437,14	386,94	157,89	229,49
EA máximo	463,27	704,69	992,42	752,38	784,82	818,38	807,55	706,90	364,54	616,44
R	0,81	0,66	0,77	0,77	0,80	0,42	0,83	0,77	0,82	0,74
D	0,82	0,53	0,59	0,60	0,70	0,44	0,63	0,60	0,85	0,76
≠Vt	3281,41	7796,02	10628,31	8031,10	7751,69	6711,36	8305,69	7347,97	2121,10	3580,32

Apêndice I – Índices estatísticos de Q8 para cada bacia de estudo.

Q8										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	54,88	73,93	69,37	55,58	64,70	50,81	68,29	60,84	57,27	62,28
EA máximo	188,82	239,57	236,10	236,50	201,33	151,95	216,52	172,23	206,12	289,74
REQM	68,80	92,36	85,14	71,28	80,40	62,23	84,65	73,87	71,20	79,82
R	0,44	0,40	0,56	0,64	0,68	0,55	0,58	0,49	0,48	0,48
D	0,63	0,55	0,67	0,79	0,78	0,69	0,68	0,60	0,66	0,61
E	-1,14	-2,88	-0,71	0,05	-0,04	-0,75	-1,06	-2,36	-1,02	-1,81
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	267,19	327,92	485,04	231,05	375,89	262,11	329,42	191,96	171,67	197,03
EA máximo	584,70	528,29	863,03	502,12	569,52	429,84	512,60	412,75	477,86	651,46
R	0,31	0,56	0,71	0,59	0,66	0,06	0,68	0,77	0,78	0,22
D	0,48	0,60	0,46	0,76	0,66	0,36	0,66	0,79	0,72	0,44
≠Vt	-1994,37	-4259,90	-6793,38	14,13	-5069,07	-2536,81	-4513,26	-681,65	1240,15	1249,91

Apêndice J – Índices estatísticos de Q9 para cada bacia de estudo.

Q9										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	48,25	66,09	54,67	46,02	55,71	42,37	59,52	56,64	52,03	51,44
EA máximo	250,82	217,05	164,96	214,49	295,80	134,39	229,62	198,18	183,63	187,61
REQM	61,09	83,56	67,25	60,47	71,65	53,49	74,29	70,34	66,16	66,60
R	0,54	0,38	0,53	0,68	0,65	0,59	0,52	0,41	0,51	0,47
D	0,70	0,58	0,72	0,82	0,80	0,74	0,70	0,59	0,68	0,64
E	-0,69	-2,18	-0,07	0,31	0,18	-0,30	-0,58	-2,05	-0,74	-0,96
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	241,52	245,56	205,86	154,51	232,00	119,32	219,12	192,51	156,45	239,86
EA máximo	508,61	508,28	425,30	415,67	542,22	345,30	458,12	367,05	477,47	462,42
R	0,68	0,15	0,57	0,70	0,46	0,68	0,33	0,72	0,46	0,00
D	0,67	0,50	0,69	0,80	0,70	0,77	0,65	0,76	0,64	0,39
≠Vt	-645,19	-1011,08	-2108,51	-923,71	-915,75	37,75	-1523,16	1139,24	-689,33	-2306,39

Apêndice K – Índices estatísticos de Q10 para cada bacia de estudo.

Q10										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	49,14	67,94	57,99	54,14	57,78	45,96	59,46	58,40	53,77	61,00
EA máximo	165,76	268,81	239,06	237,80	218,78	156,10	216,95	183,63	217,95	291,21
REQM	60,84	85,32	72,26	69,14	71,63	55,92	75,61	71,97	67,88	78,46
R	0,46	0,33	0,49	0,65	0,65	0,58	0,53	0,44	0,47	0,46
D	0,66	0,55	0,70	0,79	0,80	0,74	0,71	0,59	0,66	0,61
E	-0,68	-2,31	-0,23	0,10	0,18	-0,42	-0,64	-2,19	-0,84	-1,71
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	161,54	236,54	176,88	395,54	218,41	224,07	196,91	290,35	216,46	215,38
EA máximo	372,01	606,63	369,34	646,71	532,47	501,99	499,60	597,48	568,77	647,09
R	0,49	0,49	0,64	0,37	0,63	0,66	0,67	0,73	0,58	0,11
D	0,67	0,59	0,78	0,55	0,74	0,64	0,73	0,62	0,63	0,37
≠Vt	-279,34	125,43	-620,19	2658,53	-13,67	1463,05	112,95	3062,96	900,80	512,75

Apêndice L – Índices estatísticos de S1 para cada bacia de estudo.

S1										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	27,98	31,29	26,17	28,61	23,54	21,08	22,36	21,09	20,56	30,74
EA máximo	261,35	217,16	192,34	134,17	135,94	98,00	139,24	88,99	83,85	146,93
REQM	38,19	43,35	36,47	36,81	32,05	28,49	31,27	26,81	26,71	42,34
R	0,77	0,88	0,84	0,85	0,89	0,87	0,92	0,94	0,92	0,87
D	0,87	0,93	0,90	0,89	0,94	0,92	0,95	0,96	0,96	0,90
E	0,52	0,73	0,58	0,50	0,76	0,71	0,81	0,85	0,83	0,48
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	95,35	151,43	119,32	235,41	125,36	130,33	151,20	140,73	120,58	228,40
EA máximo	325,41	337,49	240,23	503,75	409,72	370,18	403,59	374,77	310,19	522,03
r	0,89	0,88	0,92	0,74	0,68	0,93	0,87	0,92	0,87	0,74
d	0,94	0,89	0,89	0,63	0,80	0,89	0,85	0,87	0,83	0,59
≠Vt	385,17	2383,66	1999,82	4366,97	1353,41	2318,33	2495,92	2673,86	2216,44	4207,60

Apêndice M – Índices estatísticos de S2 para cada bacia de estudo.

S2										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	19,89	29,82	40,21	26,10	32,78	31,09	30,94	25,63	19,66	22,02
EA máximo	74,61	121,20	153,93	95,21	115,35	143,49	112,58	97,80	75,03	74,11
REQM	23,89	35,41	47,57	31,83	38,28	39,72	36,31	30,58	24,03	26,60
r	0,93	0,95	0,86	0,85	0,92	0,76	0,93	0,95	0,93	0,89
d	0,94	0,95	0,80	0,89	0,91	0,82	0,93	0,95	0,96	0,94
E	0,81	0,82	0,29	0,63	0,66	0,44	0,74	0,81	0,87	0,79
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	168,54	293,29	454,13	193,77	341,22	239,79	312,00	250,33	82,49	89,73
EA máximo	453,76	579,51	783,01	358,86	650,01	643,57	593,34	529,67	293,86	311,54
r	0,87	0,76	0,49	0,84	0,44	0,47	0,58	0,81	0,72	0,54
d	0,81	0,65	0,44	0,70	0,45	0,58	0,51	0,66	0,85	0,71
≠Vt	2896,23	5412,36	8628,49	3664,13	6398,29	4393,03	5809,77	4674,11	-95,35	-627,28

Apêndice N – Índices estatísticos de S3 para cada bacia de estudo.

S3										
ÍNDICES	Mensal									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	35,42	49,19	53,26	45,02	44,92	42,02	44,85	39,33	28,04	37,43
EA máximo	285,15	180,72	201,41	144,42	137,52	164,49	151,47	110,64	116,39	156,45
REQM	46,02	60,20	63,89	53,48	53,35	54,47	52,05	45,40	34,61	46,83
r	0,66	0,82	0,69	0,70	0,79	0,56	0,86	0,89	0,85	0,78
d	0,79	0,86	0,70	0,75	0,82	0,68	0,86	0,89	0,91	0,86
E	0,30	0,49	-0,28	-0,05	0,34	-0,06	0,47	0,58	0,74	0,36
ÍNDICES	Anual									
	PDC	PRT	CCH	PCA	CMO	BCA	SAN	PSL	IRA	PLU
EA médio	223,22	423,84	559,38	424,73	440,93	353,23	437,14	386,94	157,89	229,49
EA máximo	463,27	704,69	992,42	752,38	784,82	818,38	807,55	706,90	364,54	616,44
r	0,63	0,63	0,13	0,43	-0,04	-0,11	0,55	0,65	0,57	0,40
d	0,65	0,53	0,37	0,41	0,32	0,45	0,45	0,50	0,61	0,49
≠Vt	3281,41	7796,02	10628,31	8031,10	7751,69	6711,36	8305,69	7347,97	2121,10	3580,32

CAPÍTULO 6. CONSIDERAÇÕES FINAIS

No desenvolvimento deste trabalho como área de estudo selecionou-se 10 bacias hidrográficas com dados observacionais disponíveis. Nestas foi possível calcular o balanço hídrico a partir de dados *in situ* e dados de sensoriamento remoto, além de mesclar ambas as fontes para identificação das principais fontes de incertezas no cálculo. Ademais investigou-se os efeitos de escala espacial e temporal na precisão das estimativas das variáveis hidrológicas (P, ET, Q, S), tanto individualmente quanto aplicadas na equação do balanço hídrico simples e completa.

Concluiu-se que é possível estimar o balanço hídrico em bacias hidrográficas a partir de dados obtidos por sensoriamento remoto, no entanto a precisão destas estimativas é resultado de diversos fatores: localização e, área de drenagem da bacia hidrográfica e também a escala temporal da análise.

Vale ressaltar que os dados *in situ*, tomados como verdade, também possuíam incertezas, visto que estes valores foram obtidos pontualmente e neste estudo foram estimados para uma determinada área de análise, em que foram aplicados métodos como interpolação, preenchimento de falhas e uso de dados próximos ao local de análise. Além disso, devemos considerar os erros inerentes ao equipamento de medição.

A par destes fatores, obteve-se resultados muito satisfatórios na estimativa de precipitação e evapotranspiração por sensoriamento remoto, no entanto os dados de armazenamento de água terrestre não obtiveram uma boa concordância com os valores calculados a partir de dados de campo.

Quando aplicadas as equações de balanço hídrico, no cálculo da vazão pela equação simples as quatro estimativas obtiveram um ótimo desempenho e constatou-se que a utilização de ET via sensoriamento remoto é uma alternativa viável quando há escassez de dados em campo. Ao aplicar a equação completa evidenciou-se que a menor fonte de incertezas proveniente de sensoriamento remoto em uma escala anual foi a precipitação, seguido da evapotranspiração e da combinação de ambas, por último o armazenamento de água terrestre. Ao utilizar dados de sensoriamento remoto de armazenamento de água terrestre no cálculo o resultado foi ruim, porém na quantificação das vazões para um período histórico, estes dados se tornam uma alternativa melhor do que o uso de dados *in situ*, visto que os erros diminuem significativamente, principalmente nas maiores bacias.

Ao estimar o armazenamento de água terrestre, os três cenários apresentaram uma boa predição, representando o comportamento sazonal desta variável muito bem. Novamente, a

variável estimada por sensoriamento remoto com menor imprecisão foi a precipitação, seguido da evapotranspiração, a qual apresenta uma queda de desempenho quando analisada anualmente.

REFERÊNCIAS

ADLER, Robert F. *et al.* The version-2 global precipitation climatology project (GPCP) monthly precipitation analysis (1979–present). **Journal of hydrometeorology**, v. 4, n. 6, p. 1147-1167, 2003.

ALLEN, Richard *et al.* Satellite-based ET estimation in agriculture using SEBAL and METRIC. **Hydrological Processes**, v. 25, n. 26, p. 4011-4027, 2011.

ALLEN, Richard G. *et al.* Satellite-based energy balance for mapping evapotranspiration with internalized calibration (METRIC)—Applications. **Journal of irrigation and drainage engineering**, v. 133, n. 4, p. 395-406, 2007.

ALSDORF, Douglas E.; LETTENMAIER, Dennis P. Tracking fresh water from space. **Science**, v. 301, n. 5639, p. 1491-1494, 2003.

ALSDORF, Douglas E.; RODRÍGUEZ, Ernesto; LETTENMAIER, Dennis P. Measuring surface water from space. **Reviews of Geophysics**, v. 45, n. 2, 2007.

ANDERSON, M. C. *et al.* A two-source time-integrated model for estimating surface fluxes using thermal infrared remote sensing. **Remote sensing of environment**, v. 60, n. 2, p. 195-216, 1997.

ASADULLAH, Anita; MCINTYRE, N. E. I. L.; KIGOBE, M. A. X. Evaluation of five satellite products for estimation of rainfall over Uganda/Evaluation de cinq produits satellitaires pour l'estimation des précipitations en Ouganda. **Hydrological Sciences Journal**, v. 53, n. 6, p. 1137-1150, 2008.

BARRETT, E. C. Precipitation measurement by satellites: Towards community algorithms. **Advances in Space Research**, v. 13, n. 5, p. 119-136, 1993.

BASTIAANSEN, Wim GM *et al.* A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. **Journal of hydrology**, v. 212, p. 198-212, 1998.

BHATTARAI, Nishan *et al.* Evaluating five remote sensing based single-source surface energy balance models for estimating daily evapotranspiration in a humid subtropical climate. **International journal of applied earth observation and geoinformation**, v. 49, p. 75-86, 2016.

BIRKINSHAW, S. J. *et al.* Daily discharge estimation at ungauged river sites using remote sensing. **Hydrological Processes**, v. 28, n. 3, p. 1043-1054, 2014.

BJERKLIE, David M. *et al.* Evaluating the potential for measuring river discharge from space. **Journal of Hydrology**, v. 278, n. 1-4, p. 17-38, 2003.

BRAKENRIDGE, G. Robert *et al.* Orbital microwave measurement of river discharge and ice status. **Water Resources Research**, v. 43, n. 4, 2007.

BRAKENRIDGE, G. Robert *et al.* Space-based measurement of river runoff. *Eos, Transactions American Geophysical Union*, v. 86, n. 19, p. 185-188, 2005.

BROOKFIELD, A. E. *et al.* *In Situ* and GRACE-Based Groundwater Observations: Similarities, Discrepancies, and Evaluation in the High Plains Aquifer in Kansas. **Water Resources Research**, v. 54, n. 10, p. 8034-8044, 2018.

CHEN, J. L. *et al.* 2005 drought event in the Amazon River basin as measured by GRACE and estimated by climate models. **Journal of Geophysical Research: Solid Earth**, v. 114, n. B5, 2009.

CONTI, Guilherme Nobel. Estimativa da precipitação através de técnicas de sensoriamento remoto: Estudo de caso para o estado do Rio Grande do Sul. Dissertação (Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Saneamento Ambiental). **Universidade Federal do Rio Grande do Sul**, 2002.

D'ANGIOLELLA, Gustavo; VASCONCELLOS, Vânia Lúcia Dias; ROSA, José Wilson Corrêa. Estimativa e espacialização do balanço hídrico na mesorregião sul da Bahia. **Simpósio Brasileiro de Sensoriamento Remoto**, v. 12, p. 83-90, 2005.

DEBRUIN, Henk AR. Time to think: Reflections of a pre-pensioned scintillometer researcher. **Bulletin of the American Meteorological Society**, v. 90, n. 5, p. ES17-ES26, 2009.

DURAND, Michael *et al.* An intercomparison of remote sensing river discharge estimation algorithms from measurements of river height, width, and slope. **Water Resources Research**, v. 52, n. 6, p. 4527-4549, 2016.

DURAND, Michael *et al.* Estimating reach-averaged discharge for the River Severn from measurements of river water surface elevation and slope. **Journal of Hydrology**, v. 511, p. 92-104, 2014.

ENGMAN, Edwin T. *et al.* Remote sensing in hydrology. **London: Chapman and Hall**, 1991.

FISCHER J.B. *et al.* The future of evapotranspiration: global requirements for ecosystem functioning, carbon and climate feedbacks, agricultural management and water resources. **Water Resources Research**, v.53, p. 2618-2626, 2017.

GARAMBOIS, Pierre-André; MONNIER, Jérôme. Inference of effective river properties from remotely sensed observations of water surface. **Advances in Water Resources**, v. 79, p. 103-120, 2015.

GLEASON, Colin J.; SMITH, Laurence C. Toward global mapping of river discharge using satellite images and at-many-stations hydraulic geometry. **Proceedings of the National Academy of Sciences**, p. 201317606, 2014.

HOUBORG, Rasmus *et al.* Drought indicators based on model-assimilated Gravity Recovery and Climate Experiment (GRACE) terrestrial water storage observations. **Water Resources Research**, v. 48, n. 7, 2012.

HSU, Kou-lin *et al.* Precipitation estimation from remotely sensed information using artificial neural networks. **Journal of Applied Meteorology**, v. 36, n. 9, p. 1176-1190, 1997.

HUFFMAN, George J. *et al.* The TRMM multisatellite precipitation analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. **Journal of hydrometeorology**, v. 8, n. 1, p. 38-55, 2007.

INMET. Instituto Nacional de Meteorologia. NOTA TÉCNICA Nº. 001/2011/SEGER/LAIME/CSC/INMET. 2011.

IRMAK, Ayse *et al.* Estimation of land surface evapotranspiration with a satellite remote sensing procedure. **Great plains research**, p. 73-88, 2011.

JIA, Li *et al.* Estimation of sensible heat flux using the Surface Energy Balance System (SEBS) and ATSR measurements. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 28, n. 1-3, p. 75-88, 2003.

JOYCE, Robert J. *et al.* 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, p. 487-503, 2004.

JPL (Jet Propulsion Laboratory). Overview - Monthly Mass Grids. Disponível em: <https://grace.jpl.nasa.gov/data/monthly-mass-grids/>. Acesso em: Fev. 2019.

JPL (Jet Propulsion Laboratory). SWOT Surface Water and Ocean Topography. Atualizado em: Abr. 2020. Disponível em: <https://swot.jpl.nasa.gov/mission.htm> . Acesso em: Mai. 2020.

KAMARIANAKIS, Yiannis *et al.* Comparing rainfall estimates derived from rain gauges and satellite images at the eastern Mediterranean region. In: **Proceedings of the 9th Conference on Geographical Information Science**, Visegrad, Hungary. 2006.

KARIMI, P.; BASTIAANSEN, Wim GM. Spatial evapotranspiration, rainfall and land use data in water accounting–Part 1: Review of the accuracy of the remote sensing data. **Hydrology and Earth System Sciences**, v. 19, n. 1, p. 507-532, 2015.

KIDD, Chris. Satellite rainfall climatology: A review. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, v. 21, n. 9, p. 1041-1066, 2001.

KUSTAS, W. P.; NORMAN, J. M. Use of remote sensing for evapotranspiration monitoring over land surfaces. **Hydrological Sciences Journal**, v. 41, n. 4, p. 495-516, 1996.

LI, Zhao-Liang *et al.* A review of current methodologies for regional evapotranspiration estimation from remotely sensed data. **Sensors**, v. 9, n. 5, p. 3801-3853, 2009.

LONG, Di; LONGUEVERGNE, Laurent; SCANLON, Bridget R. Uncertainty in evapotranspiration from land surface modeling, remote sensing, and GRACE satellites. **Water Resources Research**, v. 50, n. 2, p. 1131-1151, 2014.

MENENTI, M.; CHOUDHURY, B. J. Parameterization of land surface evapotranspiration using a location dependent potential evapotranspiration and surface temperature range. **Exchange processes at the land surface for a range of space and time scales**, v. 212, p. 561-568, 1993.

NASA. April 1960 - Television Infrared Observation Satellite (TIROS) Launched. Atualizado em Out, 2014. Disponível em: <<https://www.nasa.gov/directorates/heo/scan/images/history/April1960.html>>. Acesso em: jan. 2019.

NASA. Global Precipitation Measurement. Atualizado em Ago, 2017. Disponível em: <https://www.nasa.gov/mission_pages/GPM/science/index.html>. Acesso em: jan. 2019.

NASA. GRACE Mission - Mission Overview. Atualizado em Fev, 2012. Disponível em: <https://www.nasa.gov/mission_pages/Grace/overview/index.html> Acesso em: jan. 2019.

NOAA. Defense Meteorological Satellite Program (DMSP). Atualizado em Jun, 2018. Disponível em: <<https://www.ospo.noaa.gov/Operations/DMSP/index.html>>. Acesso em: jan.2019.

NORMAN, J.M.; KUSTAS, W.P.; HUMES, K.S. A two-source approach for estimating soil and vegetation energy fluxes in observations of directional radiometric surface temperature. **Agric. For. Meteor.** 77, 263-293, 1995.

PAIVA, Rodrigo Cauduro Dias de; RUHOFF, Anderson Luis. Desafios na estimativa do ciclo hidrológico terrestre por sensoriamento remoto. **Simpósio Brasileiro de Recursos Hídricos (22.: Florianópolis, 2017). Anais [recurso eletrônico]**. [Porto Alegre: ABRH, 2017], 2017.

PASSOW, Michael J. TRMM-Tropical Rainfall Measuring Mission: Bringing remote sensing of precipitation into your classroom. **Terræ Didática**, v. 6, n. 1, p. 03-08, 2010.

PRICE, John C. The potential of remotely sensed thermal infrared data to infer surface soil moisture and evaporation. **Water Resources Research**, v. 16, n. 4, p. 787-795, 1980.

RANA, G.; KATERJI, N. Measurement and estimation of actual evapotranspiration in the field under Mediterranean climate: a review. **European Journal of agronomy**, v. 13, n. 2-3, p. 125-153, 2000.

RANGO, A. Application of remote sensing methods to hydrology and water resources. **Hydrological Sciences Journal**, v. 39, n. 4, p. 309-320, 1994.

RODELL, Matthew. Satellite Gravimetry Applied to Drought Monitoring. **Remote Sensing of Drought: Innovative Monitoring Approaches**, p. 261, 2012.

ROERINK, G. J.; SU, Zhongbo; MENENTI, M. S-SEBI: A simple remote sensing algorithm to estimate the surface energy balance. **Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere**, v. 25, n. 2, p. 147-157, 2000.

SMITH, Laurence C.; PAVELSKY, Tamlin M. Estimation of river discharge, propagation speed, and hydraulic geometry from space: Lena River, Siberia. **Water Resources Research**, v. 44, n. 3, 2008.

SOARES, Alexleide Santana Diniz *et al.* Avaliação das estimativas de chuva do satélite TRMM no Estado da Paraíba. Dissertação (Programa de Pós-Graduação em Engenharia Urbana e Ambiental) – Universidade Federal da Paraíba, 2014.

SOROOSHIAN, Soroosh *et al.* Advanced concepts on remote sensing of precipitation at multiple scales. **Bulletin of the American Meteorological Society**, v. 92, n. 10, p. 1353-1357, 2011.

STEPHENS, Graeme L.; KUMMEROW, Christian D. The remote sensing of clouds and precipitation from space: A review. *Journal of the Atmospheric Sciences*, v. 64, n. 11, p. 3742-3765, 2007.

SU, Zhongbo. The Surface Energy Balance System (SEBS) for estimation of turbulent heat fluxes. **Hydrology and earth system sciences**, v. 6, n. 1, p. 85-100, 2002.

TANG, Qihong *et al.* Dynamics of terrestrial water storage change from satellite and surface observations and modeling. **Journal of Hydrometeorology**, v. 11, n. 1, p. 156-170, 2010.

TAPIADOR, Francisco J. *et al.* A neural networks–based fusion technique to estimate half-hourly rainfall estimates at 0.1 resolution from satellite passive microwave and infrared data. **Journal of Applied Meteorology**, v. 43, n. 4, p. 576-594, 2004.

TROCH, Peter *et al.* New data sets to estimate terrestrial water storage change. **Eos, Transactions American Geophysical Union**, v. 88, n. 45, p. 469-470, 2007.

WAHR, John; MOLENAAR, Mery; BRYAN, Frank. Time variability of the Earth's gravity field: Hydrological and oceanic effects and their possible detection using GRACE. **Journal of Geophysical Research: Solid Earth**, v. 103, n. B12, p. 30205-30229, 1998.

WAHR, John; SWENSON, Sean; VELICOGNA, Isabella. Accuracy of GRACE mass estimates. **Geophysical Research Letters**, v. 33, n. 6, 2006.

WU, Bingfang *et al.* Validation of ETWatch using field measurements at diverse landscapes: A case study in Hai Basin of China. **Journal of hydrology**, v. 436, p. 67-80, 2012.

YOON, Yeosang *et al.* Improved error estimates of a discharge algorithm for remotely sensed river measurements: Test cases on Sacramento and Garonne Rivers. **Water Resources Research**, v. 52, n. 1, p. 278-294, 2016.

ZAITCHIK, Benjamin F.; RODELL, Matthew; REICHLER, Rolf H. Assimilation of GRACE terrestrial water storage data into a land surface model: Results for the Mississippi River basin. **Journal of Hydrometeorology**, v. 9, n. 3, p. 535-548, 2008.