

## XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS

### **VALIDAÇÃO DE DADOS DE ELEVAÇÃO DA SUPERFÍCIE DA ÁGUA DE PRODUTOS DE RIO DO SATÉLITE SWOT**

*Juliana Andrade Campos<sup>1,2</sup>; Edivaldo Afonso de Oliveira Serrão<sup>1</sup>; João Henrique Macedo Sá<sup>1</sup>;  
Paulo Roberto Estumano Beltrão Junior<sup>1</sup>; Renata G. Tedeschi<sup>1</sup>; Alice Cesar Fassoni Andrade<sup>3</sup>;  
Rosane Barbosa Lopes Cavalcante<sup>1</sup> & Paulo Rógenes Monteiro Pontes<sup>1</sup>.*

**Abstract:** The SWOT (Surface Water and Ocean Topography) satellite represents a significant advancement in global hydrological observation, enabling measurements of Water Surface Elevation (WSE) with high spatial resolution and broad coverage. Its innovative two-dimensional altimetry is made possible by the KaRIn (Ka-band Radar Interferometer) sensor, which provides accurate WSE estimates for continental water bodies, with a full revisit every 21 days and coverage exceeding 90% of the Earth's surface. This study evaluated the performance of the SWOT L2\_HR\_RiverSP product, focusing on the *river node* and *river reach* sub-products, at six gauging stations on Brazilian rivers with widths between 60 and 300 meters. Satellite-derived estimates were compared with observed data using statistical metrics such as the coefficient of determination ( $R^2$ ), root mean square error (RMSE), mean absolute error (MAE), and mean absolute percentage error (MAPE). Results indicated superior performance of the *river node* product, with an average  $R^2$  of 0.95 and MAE of 0.15 m, compared to the *river reach*, which showed an average  $R^2$  of 0.59 and MAE of 0.54 m. The higher accuracy of the *river node* is associated with better data quality, mostly classified as good according to a quality attribute provided by SWOT. In contrast, the *river reach* data were only classified as suspect or degraded, possibly due to the spatial aggregation along river segments. Overall, SWOT data show strong potential for water level estimation in ungauged areas, including smaller rivers.

**Resumo:** O satélite SWOT (Surface Water and Ocean Topography) representa um avanço significativo na observação hidrológica em escala global, permitindo medições da Elevação da Superfície da Água (WSE, na sigla em inglês) com alta resolução espacial e ampla cobertura. Sua altimetria bidimensional inovadora é viabilizada pelo sensor KaRIn (Ka-band Radar Interferometer), que fornece estimativas precisas da WSE em corpos hídricos continentais, com revisita completa a cada 21 dias e cobertura superior a 90% da superfície terrestre. Este estudo avaliou o desempenho do produto SWOT L2\_HR\_RiverSP, com foco nos subprodutos *river node* e *river reach*, em seis estações fluviométricas de rios brasileiros com larguras entre 60 e 300 metros. As estimativas do satélite foram comparadas com dados observados, utilizando métricas como coeficiente de determinação ( $R^2$ ), erro quadrático médio (RMSE), erro absoluto médio (MAE) e erro percentual absoluto médio (MAPE). Os resultados indicaram desempenho superior do *river node*, com  $R^2$  médio de 0,95 e MAE médio de 0,15 m, frente ao *river reach*, que obteve  $R^2$  médio de 0,59 e MAE de 0,54 m. A maior acurácia do *river node* está associada à melhor qualidade dos dados, que são

1) Afiliação: Instituto Tecnológico Vale Desenvolvimento Sustentável – ITVDS; Belém, PA, 66055-090, [juliana.campos@pq.itv.org](mailto:juliana.campos@pq.itv.org); [oliveira.serrao@pq.itv.org](mailto:oliveira.serrao@pq.itv.org); [joao.macedo@pq.itv.org](mailto:joao.macedo@pq.itv.org); [paulo.junior@pq.itv.org](mailto:paulo.junior@pq.itv.org); [renata.tedeschi@itv.org](mailto:renata.tedeschi@itv.org); [rosane.cavalcante@itv.org](mailto:rosane.cavalcante@itv.org); [paulo.pontes@itv.org](mailto:paulo.pontes@itv.org).

2) Instituto de Pesquisas Hidráulicas (IPH) - Universidade Federal do Rio grande do Sul (UFRGS).

3) Universidade de Brasília (UnB), [alice.fassoni@gmail.com](mailto:alice.fassoni@gmail.com)

classificados majoritariamente como bons segundo um atributo de qualidade do próprio SWOT. Já o *river reach* apresentou apenas dados suspeitos ou degradados, possivelmente devido à agregação espacial ao longo dos trechos. De modo geral, os dados do SWOT demonstram potencial para estimativas de nível d'água em áreas não monitoradas, inclusive em rios menores.

**Palavras-Chave** – SWOT, Altimetria, Nível d'água.

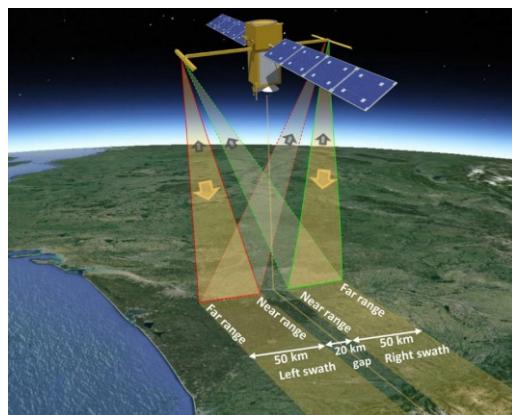
## INTRODUÇÃO

A Elevação da Superfície da Água (WSE, na sigla em inglês) representa a altura da lâmina d'água em relação a um referencial vertical conhecido, como o nível médio do mar ou um geoide. Na prática, ela equivale ao que chamamos de nível d'água, mas com a diferença de estar associada a um sistema geodésico padronizado. O monitoramento da WSE é estratégico para o acompanhamento das variações sazonais e extremas dos níveis dos rios e reservatórios, contribuindo para o controle de cheias, mitigação de desastres, gestão dos recursos hídricos e preservação dos ecossistemas aquáticos (Alsdorf et al., 2007). Tradicionalmente, esse monitoramento é feito por meio de régua limimétrica ou sensores automáticos instalados em postos fluviométricos fixos. Apesar de confiável, esse tipo de monitoramento depende de infraestrutura local, manutenção e mão de obra qualificada, o que dificulta sua implementação em bacias remotas ou de difícil acesso, como ocorre em várias regiões do Brasil (Calmant et al., 2008).

A altimetria por satélite surge como uma alternativa que permite observações da WSE em grande escala, com alta precisão e periodicidade, superando limitações dos métodos tradicionais. Essa tecnologia preenche lacunas em áreas com escassez de dados, sendo atualmente uma ferramenta crucial para monitorar WSE em oceanos e águas continentais (Abdalla et al., 2021). A altimetria convencional é realizada por meio de altímetros de radar e laser, cada um com características distintas quanto à resolução espacial, precisão e cobertura temporal. Altímetros de radar, como os dos satélites Envisat, Jason-1/2/3 e Sentinel-3, são eficazes independentemente das condições climáticas, garantindo aquisição de dados consistente ao longo do tempo. No entanto, apresentam baixa resolução espacial devido ao grande footprint, limitando sua aplicação em rios menores e na detecção de variações mais refinadas (Calmant et al., 2016). Altímetros a laser, como nos satélites ICESat e ICESat-2, oferecem maior resolução espacial e precisão nas estimativas de elevação, sendo mais adequados para o monitoramento detalhado de superfícies continentais (Brenner et al., 2007). Contudo, esses sensores têm alta sensibilidade à cobertura de nuvens e baixa frequência de revisita, comprometendo a continuidade e abrangência espacial dos dados. Além disso, as medições de ambos os sistemas são lineares ao longo da órbita, restringindo a observação de grandes áreas em uma única passagem.

Lançado em dezembro de 2022, o satélite SWOT (Surface Water and Ocean Topography) representa um avanço significativo em relação às limitações da altimetria tradicional. Diferentemente das missões anteriores, o SWOT oferece observações bidimensionais e contínuas das águas superficiais globais, cobrindo mais de 90% da superfície terrestre com uma revisita completa a cada 21 dias e, no mínimo, duas passagens por ponto em cada ciclo (Biancamaria et al., 2016). Seu grande diferencial é a combinação entre alta resolução espacial, de aproximadamente 50 metros, e precisão vertical centimétrica, em torno de 10 cm (Frasson et al., 2019), o que possibilita o monitoramento detalhado de rios com largura superior a 100 metros e corpos d'água com área acima de 0,06 km<sup>2</sup>. Esse desempenho é viabilizado pelo KaRIn (Ka-band Radar Interferometer), um sistema inovador a bordo do SWOT que permite medir a WSE em uma faixa de observação de 120 km de largura (Figura 1).

Figura 1 – Visão conceitual da missão SWOT com seus principais instrumentos: o interferômetro de radar de banda Ka (KaRIn, com as áreas observadas indicadas pelos polígonos amarelos) e um altímetro nadir de banda Ku (linha amarela). Fonte: Biancamaria et al., (2016).



A missão SWOT disponibiliza um conjunto de produtos voltados ao monitoramento hidrológico continental. O principal deles é o L2\_HR\_PIXC (*Pixel Cloud*), que contém a nuvem de pixels classificados como superfície de água, incluindo estimativas WSE, localização e indicadores de qualidade. Esse produto é complementado pelo L2\_HR\_PIXCVEC, uma versão auxiliar com menor nível de ruído e georreferenciamento ajustado por altura, que associa os pixels de água a feições hidrológicas mapeadas previamente nos bancos de dados SWOT. Juntos, esses produtos servem de base para a geração de produtos hidrológicos derivados por feição (SWOT, 2022).

Entre esses derivados, os produtos L2\_HR\_RiverSP e L2\_HR\_LakeSP fornecem informações estruturadas como largura, declividade e comprimento dos rios, bem como área, volume e elevação média de lagos. No contexto fluvial, destacam-se ainda o produto *river node*, que disponibiliza estimativas hidrológicas a cada 200 metros ao longo do eixo dos rios, e o *River reach*, que agrupa essas informações em segmentos contínuos de aproximadamente 10 km. Futuramente, o *River reach* também incluirá estimativas de vazão, ampliando o potencial da missão SWOT para aplicações hidrológicas (SWOT, 2022).

A validação dos produtos de WSE gerados pelo SWOT é essencial para garantir sua confiabilidade e aplicabilidade em pesquisas hidrológicas, gestão de recursos hídricos e modelagem hidráulica. Estudos recentes apontam forte correlação entre as medições do SWOT e dados in situ, bem como com outras missões de altimetria espacial, como ICESat-2, Sentinel-3 e Jason-3, com coeficientes de correlação superiores a 0,97 e erros sistemáticos geralmente inferiores a 1 metro (Normandin et al., 2024; Yu et al., 2024).

Diante desse contexto, o presente estudo tem como objetivo avaliar a qualidade dos produtos científicos da missão SWOT em alguns rios brasileiros, com larguras variando entre 60 e 300 metros. A análise concentra-se nos produtos voltados ao monitoramento fluvial, com ênfase no L2\_HR\_RiverSP, explorando suas duas estruturas de saída: *river node* e *River reach*. Ambos os produtos foram comparados entre si e validados com dados in situ, com o objetivo de avaliar seu desempenho relativo e seu potencial de aplicação.

## METODOLOGIA

### Área de Estudo e Dados In Situ

Foram selecionadas 6 estações fluviométricas do sistema nacional de informações sobre recursos hídricos (SNIRH - <https://www.snirh.gov.br/hidroweb/mapa>), localizadas em diferentes rios

brasileiros, com larguras variando entre 60m e 300m aproximadamente (Figura 2 e Tabela 1). As estações selecionadas possuem dados convencionais de medição diária de cota (nível d'água). Os valores médios diários do período entre 01/08/2023 e 30/05/2025 foram utilizados para comparações e validações com os dados do SWOT. Em cada estação, identificou-se os passes do SWOT que cobrem a região, bem como o trecho de rio e os 3 *nodes* mais próximos da estação.

Figura 2 – Localização das estações fluviométricas selecionadas

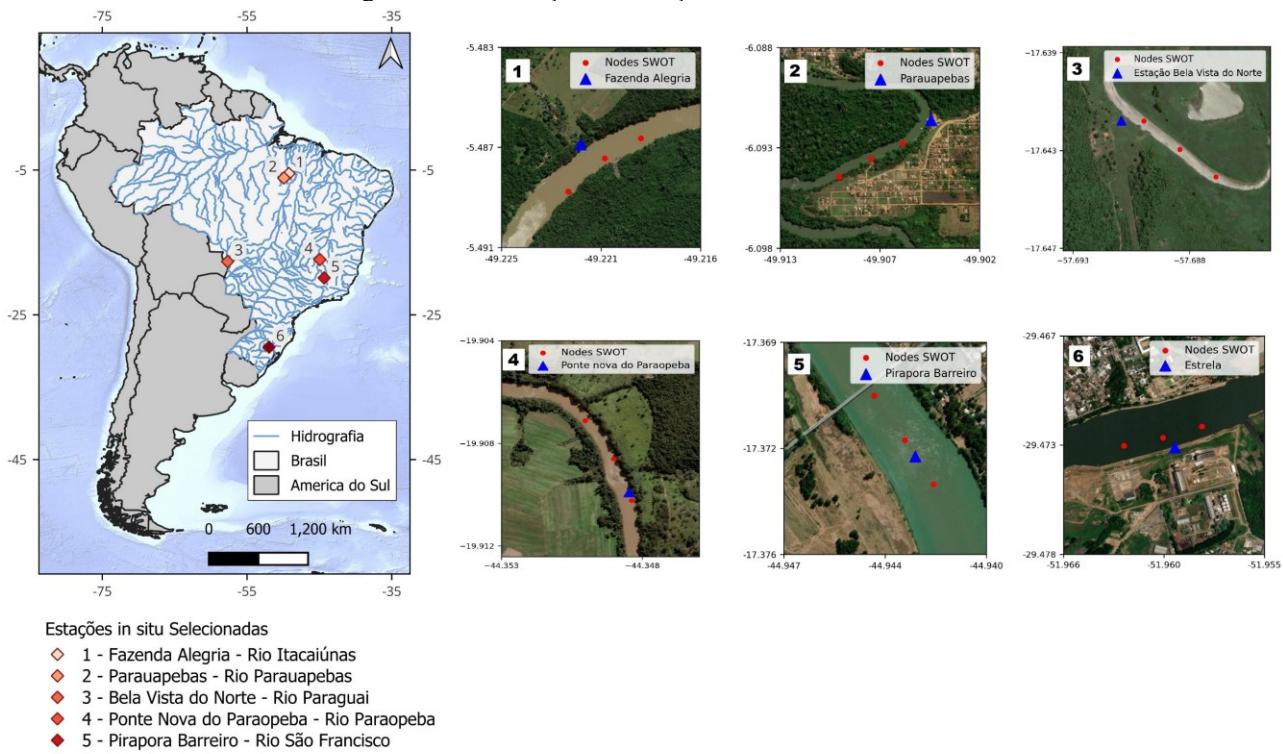


Tabela 1 – Informações sobre as estações fluviométricas e os respectivos dados do SWOT

Nome	Código Hidroweb	Rio	Largura média (m)	Pass SWOT	Node_ID	Reach_ID
Fazenda Alegria	29100000	Itacaiúnas	110	130 e 255	62420300020541 62420300020551 62420300020561	62420300021
Parauapebas	29070100	Parauapebas	60	561 e 436	62420600120231 62420600120241 62420600120251	62420600121
Bela Vista do Norte	61125000	Paraguai	90	339 e 548	64248300010261 64248300010271 64248300010281	64248300011
Ponte Nova do Paraopeba	40800001	Paraopeba	60	102 e 477	63499000240801 63499000240831 63499000240841	63499000241
Pirapora Barreiro	41135000	São Francisco	300	102 e 477	63495000030371 63495000030381 63495000030391	63495000031
Estrela	86878300	Taquari	250	214 e 533	64120200090491 64120200090501 64120200090511	64120200091

## Dados do SWOT

Os dados de elevação da superfície da água utilizados neste estudo foram obtidos por meio do produto científico L2\_HR\_RiverSP. Esse produto é derivado de processamentos avançados aplicados aos dados de nuvem de pixels do produto L2\_HR\_PIXC, gerando parâmetros físicos específicos para ambientes fluviais. Por conter informações hidrológicas já processadas e espacialmente organizadas em formato vetorial, o L2\_HR\_RiverSP apresenta maior facilidade de uso em comparação com o produto original de nuvem de pixels, que requer etapas adicionais de processamento.

O produto L2\_HR\_RiverSP é composto por dois subprodutos principais: *river reach* e *river node*. O subproduto *river reach* fornece informações agregadas ao longo de trechos de rio com extensão média de aproximadamente 10 km, definidos a partir da base de dados vetorial SWORD (*Surface Water and Ocean Topography River Database*), que organiza os cursos d'água globais em uma estrutura hierárquica com conectividade topológica e informações geomorfológicas. Para cada *reach*, são disponibilizados diversos parâmetros, dentre os quais se destacam: WSE, área da superfície da água, declividade média da superfície da água, largura média do curso d'água, e, futuramente, estimativas de vazão. Já o subproduto *river node* apresenta dados em pontos discretos distribuídos ao longo do eixo dos rios a cada aproximadamente 200 metros, também definidos a partir da base SWORD. Para cada *node*, são fornecidos diversos parâmetros, dentre os quais destacam-se: WSE, área da lâmina d'água e largura local do rio.

Ambos os subprodutos contam com um atributo de qualidade da medição, denominado *reach\_q* para os trechos e *node\_q* para os pontos, com valores variando de 0 a 3. Esse atributo representa um indicador de qualidade da medição, sendo que valores iguais a 0 indicam medições nominais (alta confiabilidade), valor 1 indica medições suspeitas, enquanto valores iguais ou superiores a 2 correspondem a medições degradadas ou inválidas, recomendando-se cautela ou exclusão dessas observações nas análises.

Para a obtenção das séries temporais de WSE dos produtos *river node* e *river reach*, foram utilizados scripts em Python executados no ambiente *Google Colab*. A biblioteca *earthaccess* foi empregada para autenticação e download automatizado dos dados disponibilizados pela NASA/PO.DAAC. Os passes de observação que cobrem cada localidade foram identificados a partir do arquivo *KMZ* da órbita científica da missão, fornecido pelo PO.DAAC ([https://podaac.github.io/tutorials/quarto\\_text/SWOT.html](https://podaac.github.io/tutorials/quarto_text/SWOT.html), acesso em 15 maio de 2025).

Para o produto *river node*, foram selecionados os três *nodes* mais próximos de cada estação, e a média dos valores de *WSE* foi utilizada. Apenas observações com *node\_q* < 1 foram consideradas nas análises do produto *river node*, garantindo maior qualidade dos dados. Para o produto *river reach*, foi identificado o *reach\_id* correspondente ao trecho onde a estação está inserida, e os dados foram filtrados para *reach\_q* < 2. Em ambos os casos, apenas a variável *WSE* foi analisada. Os arquivos foram descompactados no próprio *Colab* e processados com a biblioteca *geopandas*, sendo os resultados organizados em séries temporais e exportados em formato CSV para análise posterior.

## Processamento dos Dados

No processamento inicial, foram identificados os pares de dados entre as observações do produto SWOT (subprodutos *river reach* e *river node*) e os dados *in situ* obtidos para a mesma data de aquisição, a fim de permitir uma comparação direta entre as séries temporais. Após esse pareamento temporal, os dados de elevação da superfície da água (WSE) de ambas as fontes foram convertidos em anomalias, por meio da subtração da média de cada série individual. A anomalia foi calculada conforme a seguinte equação:

$$Anomalia_i(m) = WSE_i(m) - WSE_{méd}(m) \quad (1)$$

em que  $WSE_i$  representa o valor pontual da elevação da superfície da água em metros e  $WSE_{méd}$  é a média da série correspondente (SWOT ou in situ).

Esse procedimento foi adotado para tornar os dados comparáveis em termos relativos, uma vez que os produtos SWOT são referenciados ao geoide EGM2008, enquanto os dados obtidos pelas estações in situ geralmente não possuem referência geodésica padronizada, sendo representados em sistemas locais ou arbitrários. Dado que as altitudes absolutas podem apresentar diferentes níveis de deslocamento vertical entre as fontes, a remoção da média permite comparar as variações dinâmicas entre os sinais. Ressalta-se que o cálculo de anomalias não corresponde a um processo de normalização ou padronização, tampouco torna os dados adimensionais; trata-se apenas de uma transformação que preserva as unidades físicas originais (metros) e mantém o foco nas flutuações relativas da superfície da água, eliminando o efeito de deslocamentos verticais sistemáticos.

## Estatísticas de Validação

A validação dos dados do SWOT foi realizada com base na comparação com os dados in situ, considerando os pares de observações previamente pareados por data e convertidos em anomalias. Para quantificar a correspondência entre os conjuntos de dados, foram aplicadas três métricas estatísticas: o erro médio absoluto (MAE), a raiz do erro quadrático médio (RMSE) e o coeficiente de determinação ( $R^2$ ).

O MAE representa a média dos valores absolutos das diferenças entre os dados SWOT e os dados in situ, expressando o desvio médio independente do sinal do erro. Já o RMSE fornece uma medida da magnitude do erro que penaliza discrepâncias maiores, sendo mais sensível a outliers do que o MAE. Por fim, o  $R^2$  indica o grau de associação linear entre os dois conjuntos de dados, variando de 0 a 1, sendo que valores mais próximos de 1 indicam melhor ajuste entre as séries. Essas estatísticas foram calculadas separadamente para os subprodutos *river reach* e *river node*, de modo a avaliar o desempenho de cada nível de agregação espacial presente no produto L2\_HR\_RiverSP do SWOT.

## RESULTADOS E DISCUSSÕES

Nas Figuras 3 e 4 são apresentadas as comparações visuais entre os níveis d'água observados e os estimados pelo SWOT para as 6 localidades avaliadas. A Figura 3 refere-se ao produto *river node*, e a Figura 4 refere-se ao produto *river reach*.

As estatísticas de validação (Tabela 2) calculadas entre os níveis d'água observados nas estações fluviométricas e os estimados pelo produto River Node demonstram forte aderência, com  $R^2$  elevados, variando de 0,90 (Ponte Nova do Paraopeba) a 0,99 (Fazenda Alegria e Parauapebas). Os erros médios absolutos (MAE) mantiveram-se abaixo de 0,20 m, e o erro percentual médio absoluto (MAPE) também apresentou valores baixos em todas as estações. Por outro lado, o produto River Reach apresentou desempenho mais variável e, de forma geral, inferior ao produto Node. Os valores de  $R^2$  foram consideravelmente mais baixos em localidades, como Parauapebas ( $R^2 = 0,25$ ) e Pirapora Barreiro ( $R^2 = 0,27$ ). Além disso, os erros absolutos e percentuais foram significativamente maiores, como demonstrado pelo MAPE de até -72,6% em Pirapora. Em termos de médias, os resultados indicam bom desempenho para o *river node*, com valores médios de  $R^2 = 0,95$ , RMSE = 0,20 m, MAE = 0,15 m e MAPE médio em módulo = 9,5%, refletindo alta acurácia e baixa dispersão dos erros. Já para o *river reach*, o desempenho é mais variável e, em geral, inferior, com médias de  $R^2 = 0,59$ , RMSE = 0,75 m, MAE = 0,54 m e MAPE médio em módulo = 45,2%.

Tabela 2 – Estatísticas de validação

River Node				
Nome	R <sup>2</sup>	RMSE (m)	MAE (m)	MAPE
<b>Fazenda Alegria</b>	0,99	0,15	0,11	-3,5%
<b>Parauapebas</b>	0,99	0,12	0,09	9,3%
<b>Bela Vista do Norte</b>	0,95	0,14	0,11	4,0%
<b>Ponte Nova do Paraopeba</b>	0,90	0,24	0,19	-17,3%
<b>Pirapora Barreiro</b>	0,91	0,08	0,06	-7,6%
<b>Estrela</b>	0,97	0,47	0,33	-14,0%
River Reach				
Nome	R <sup>2</sup>	RMSE (m)	MAE (m)	MAPE
<b>Fazenda Alegria</b>	0,90	1,05	0,78	-22,0%
<b>Parauapebas</b>	0,25	1,15	0,97	95,9%
<b>Bela Vista do Norte</b>	0,68	0,41	0,24	-24,5%
<b>Ponte Nova do Paraopeba</b>	0,59	0,48	0,28	-35,9%
<b>Pirapora Barreiro</b>	0,27	0,46	0,39	-72,6%
<b>Estrela</b>	0,85	0,91	0,59	-20,1%

Figura 3 – Comparação entre os níveis d'água observados e os estimados pelo produto River Node do satélite SWOT

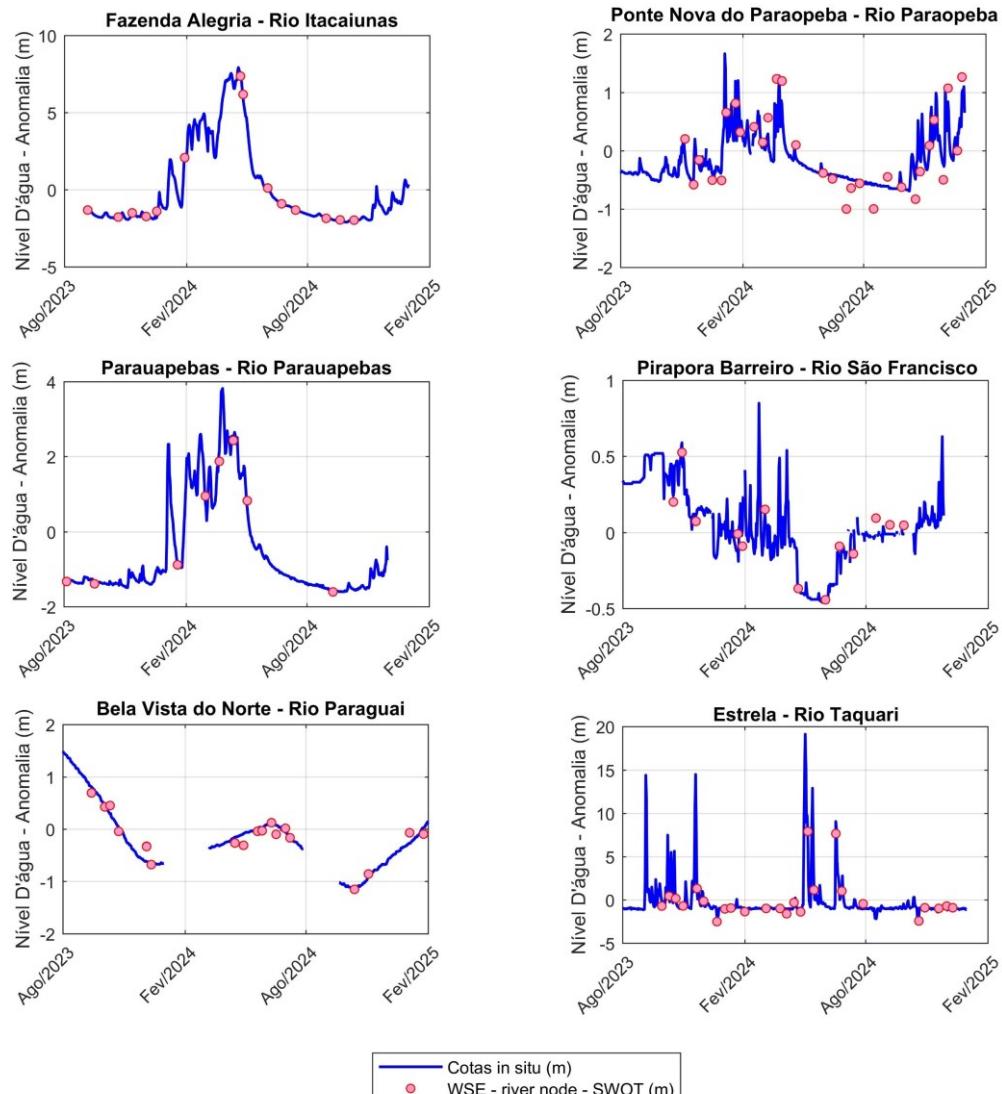
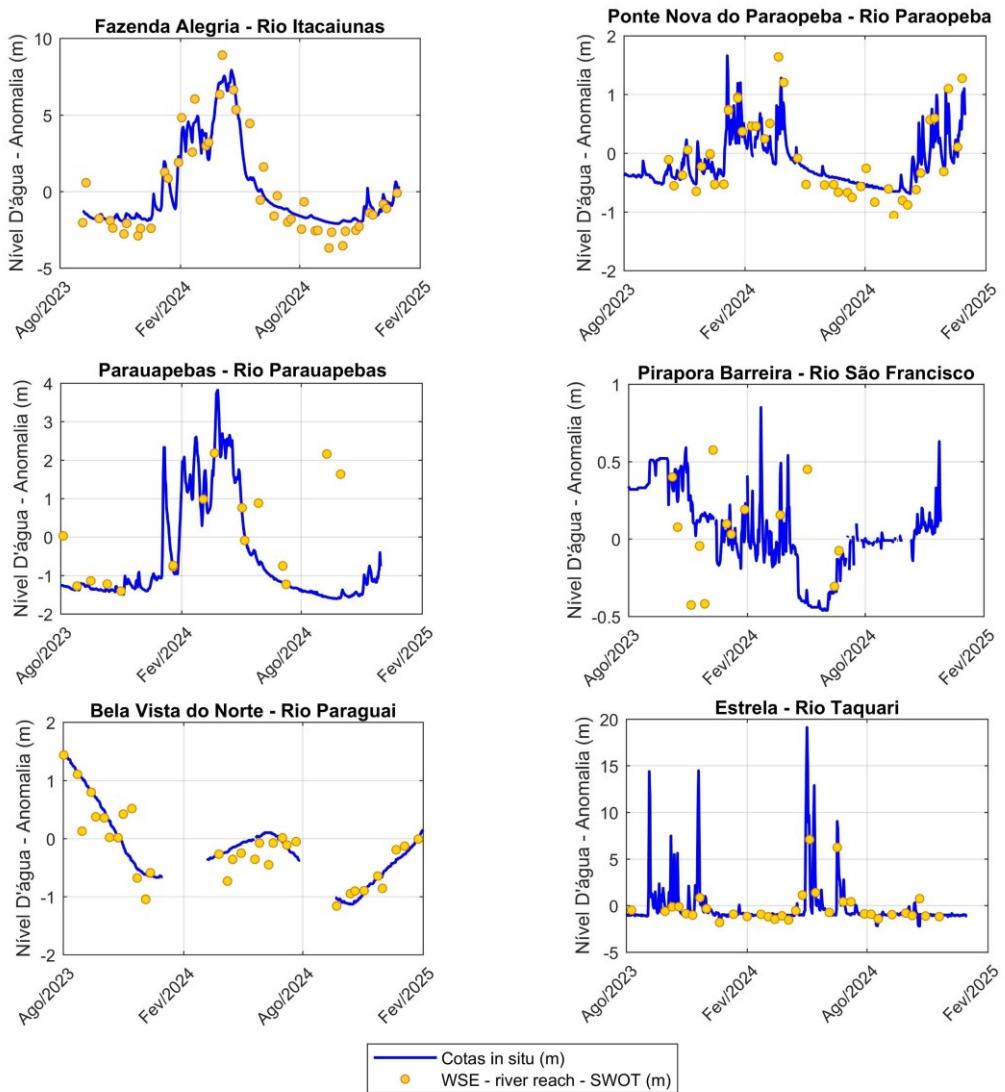


Figura 4 – Comparação entre os níveis d’água observados e os estimados pelo produto River Reach do satélite SWOT



Esses resultados indicam que o produto Reach pode ser mais suscetível a erros sistemáticos, possivelmente por sua estrutura agregada (ao longo de trechos do rio), que pode não capturar com precisão as variações locais detectadas no produto Node. Futuramente, a vantagem desse produto será a estimativa de dados de vazão por trecho.

Também foi feita uma análise da qualidade das estimativas de WSE, com base nos atributos *node\_q* e *reach\_q*, ambos disponibilizados nos produtos de rio do SWOT (Tabela 3). Observa-se que o número total de dados do produto *River Node* é maior porque foram considerados os três nodes mais próximos de cada estação, gerando até três estimativas de WSE por data, posteriormente agregadas por média. Já o *River Reach* fornece apenas uma estimativa por data, associada a um único trecho.

Quanto à qualidade, no *River Node* foram utilizadas apenas estimativas com *node\_q* = 0, o que provavelmente contribuiu para melhores estatísticas de validação. No caso do *River Reach*, como não havia estimativas com *reach\_q* = 0, foi necessário utilizar dados com *reach\_q* = 1, considerados *suspect*, o que provavelmente levou à piora dos resultados nesse produto.

Tabela 3 – Classificação da Qualidade das Estimativas de WSE pelo SWOT (Node e Reach)

node_q					
Nome Estação	0	1	2	3	Total
<b>Fazenda Alegria</b>	14	88	32	52	186
<b>Parauapebas</b>	9	31	58	96	192
<b>Bela Vista do Norte</b>	22	72	39	44	177
<b>Ponte Nova do Paraopeba</b>	30	97	12	41	180
<b>Pirapora Barreiro</b>	13	87	45	37	182
<b>Estrela</b>	25	72	35	48	180
reach_q					
Nome Estação	0	1	2	3	Total
<b>Fazenda Alegria</b>	0	44	18	0	62
<b>Parauapebas</b>	0	16	48	0	64
<b>Bela Vista do Norte</b>	0	42	17	0	59
<b>Ponte Nova do Paraopeba</b>	0	46	14	0	60
<b>Pirapora Barreiro</b>	0	21	39	0	60
<b>Estrela</b>	0	33	25	0	60

Segundo a documentação do SWOT, dados *suspect* (*node\_q* e *reach\_q* = 1) podem apresentar erros comparáveis aos dados *good* (*node\_q* e *reach\_q* = 0), mas devem ser usados com cautela, enquanto dados *degraded* e *bad measurement* (*node\_q* e *reach\_q* = 2 ou 3) normalmente apresentam erros maiores e só devem ser utilizados na ausência de dados melhores. Assim, uma alternativa, além do uso dos indicadores de qualidade, é a aplicação de filtros adicionais, como remoção de outliers, para garantir a confiabilidade das análises temporais.

## CONSIDERAÇÕES FINAIS

Os resultados indicam que o produto *river node* apresentou desempenho superior ao *river reach* na estimativa de níveis d'água, com coeficientes de determinação mais altos e menores erros. Essa diferença está associada, principalmente, à disponibilidade de dados de maior qualidade no produto *river node* (*node\_q* = 0), consideradas confiáveis. No caso do *river reach*, como não havia dados classificados como bons (*reach\_q* = 0), foi necessário utilizar medições com dados de qualidade suspeita (*reach\_q* = 1), o que pode ter afetado negativamente o desempenho. Além disso, o *river reach* consiste em um produto agregado em trechos de aproximadamente 10 km, o que pode suavizar variações locais importantes do nível d'água, dificultando a comparação direta com medições pontuais *in situ*. Futuramente, este produto será importante pois fornecerá dados estimados de vazão. No entanto, para estimativas de WSE, o produto *river node* se mostrou mais adequado.

Sendo assim, os resultados deste estudo demonstram o potencial dos produtos de rio SWOT em estimar níveis d'água com boa acurácia, inclusive em rios menores e regiões remotas, com expectativa futura de avanços como a geração direta de estimativas de vazão para complementar o monitoramento hidrológico.

## AGRADECIMENTOS

Os autores agradecem ao Instituto Tecnológico Vale Desenvolvimento Sustentável (ITV DS) pelo suporte financeiro e institucional oferecido ao grupo de pesquisas em Geologia e Recursos Hídricos, que viabilizou a realização desta pesquisa.

## REFERÊNCIAS

- ABDALLA, S. *et al.* (2021). Altimetry for the future: Building on 25 years of progress. *Advances in Space Research*, 68, 319–363. <https://doi.org/10.1016/j.asr.2021.01.022>.
- ALSDORF, D. E.; RODRÍGUEZ, E.; LETTENMAIER, D. P. (2007). Measuring surface water from space. *Reviews of Geophysics*, 45. <https://doi.org/10.1029/2006RG000197>.
- BIANCAMARIA, S.; LETTENMAIER, D. P.; PAVELSKY, T. M. (2016). The SWOT mission and its capabilities for land hydrology. In: *Remote Sensing in Water Resources*, p. 117–147.
- BRENNER, A. C.; DIMARZIO, J. P.; ZWALLY, H. J. (2007). Precision and accuracy of satellite radar and laser altimeter data over the continental ice sheets. *IEEE Transactions on Geoscience and Remote Sensing*, 45, 321–331. <https://doi.org/10.1109/TGRS.2006.887172>.
- CALMANT, S.; CRÉTAUX, J.-F.; RÉMY, F. (2016). Principles of radar satellite altimetry for application on inland waters. In: *Microwave Remote Sensing of Land Surface*. Elsevier, p. 175–218. <https://doi.org/10.1016/B978-1-78548-159-8.50004-9>.
- CALMANT, S.; SEYLER, F.; CRÉTAUX, J.-F. (2008). Monitoring continental surface waters by satellite altimetry. *Surveys in Geophysics*, 29, 247–269.
- FRASSON, R. P. de M. *et al.* (2019). Will the Surface Water and Ocean Topography (SWOT) satellite mission observe floods? *Geophysical Research Letters*, 46, 10435–10445. <https://doi.org/10.1029/2019GL084686>.
- NORMANDIN, C. *et al.* (2024). First results of the Surface Water Ocean Topography (SWOT) observations to rivers elevation profiles in the Cuvette Centrale of the Congo Basin. *Frontiers in Remote Sensing*, 5. <https://doi.org/10.3389/frsen.2024.1466695>.
- SWOT PROJECT. (2022). *SWOT Level 2 Hydrology User Handbook*. Version 1.3, JPL D-58157. Jet Propulsion Laboratory, California Institute of Technology. Disponível em: <https://podaac.jpl.nasa.gov/swot>. Acesso em: 23 jun. 2025.
- YU, L. *et al.* (2024). Validation of mainland water level elevation products from SWOT satellite. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 13494–13505. <https://doi.org/10.1109/JSTARS.2024.3435363>.