

## CAPACIDADE DE ARMAZENAMENTO DE RESERVATÓRIOS DE ÁGUA DOCE DERIVADOS DE DADOS SRTM E ALOS – PALSAR

**YESICA RAMIREZ FLORES<sup>1\*</sup>; ADROALDO DIAS ROBAINA<sup>1</sup>; MARCIA XAVIER  
PEITER<sup>1</sup>; MIGUEL CHAIBEN NETO<sup>1</sup>; SILVANA ANTUNES RODRIGUES<sup>1</sup> E  
JÉSSICA DARIANE PIROLI<sup>1</sup>**

*<sup>1</sup>Departamento de Engenharia Rural, Universidade Federal de Santa Maria, Av. Roraima nº 1000 Cidade Universitária, Bairro - Camobi, 97103-900, Santa Maria, RS, Brasil. E-mail: [yeyiramiflo@gmail.com](mailto:yeyiramiflo@gmail.com); [diasrobaina@gmail.com](mailto:diasrobaina@gmail.com); [marcia.peiter@ufsm.br](mailto:marcia.peiter@ufsm.br); [miguelchaiben@gmail.com](mailto:miguelchaiben@gmail.com); [rodrigues.silvana.a@gmail.com](mailto:rodrigues.silvana.a@gmail.com); [jeh.pirol@gmail.com](mailto:jeh.pirol@gmail.com).*

*\* Este artigo é proveniente da dissertação de mestrado do primeiro autor.*

### 1 RESUMO

Reservatórios de água doce são fontes de armazenamento e fornecimento essenciais, entretanto, sua quantificação e caracterização volumétrica é negligenciada por inúmeros fatores. Uma forma de monitorá-los é usando modelos digitais de elevação. Sua precisão razoável tornam o método confiável e de baixo custo. Assim, o estudo objetivou identificar e determinar a capacidade de armazenamento dos reservatórios da região da Fronteira Oeste do Rio Grande do Sul por meio de MDEs. A identificação dos reservatórios deu-se por meio dos dados SRTM e ALOS – PALSAR na geração do TIN (Rede Triangular Irregular). Na sequência foi estimado os valores de volume e área dos reservatórios para a caracterização volumétrica dos mesmos. Tendo estabelecida a distribuição espacial dos reservatórios para a área de estudo, os dados para capacidade volumétrica, área de superfície e profundidade foram transformados em equações log para validação por meio de análise estatística. Os dados derivados dos modelos TIN SRTM e TIN ALOS – PALSAR demonstram o potencial do uso dessas ferramentas na identificação e caracterização de reservatórios de forma detalhada e precisa. Demonstra-se também a confiabilidade da estimativa de área e volume, combinando estimativas de extensão desses reservatórios por meio de dados de radar com relação à área, volume e profundidade.

**Palavras-chave:** disponibilidade hídrica, sensoriamento remoto, modelos de elevação, lagos.

**FLORES, Y. R.; ROBAINA, A. D.; PEITER, M. X.; CHAIBEN NETO, M.;  
RODRIGUES, S. A.; PIROLI, J. D.  
IDENTIFICATION AND DETERMINATION OF THE STORAGE CAPACITY OF  
FRESHWATER RESERVOIRS DERIVED FROM SRTM AND ALOS – PALSAR  
DATA**

### 2 ABSTRACT

Freshwater reservoirs are essential sources of storage and supply; however, their quantification and volumetric characterization are neglected due to several factors. One way to monitor them is by using digital elevation models. Its reasonable accuracy makes the method reliable and cost-effective. Thus, the study aimed to identify and determine the storage capacity of reservoirs

in the West Frontier region of Rio Grande do Sul through DEMs. The identification of the reservoirs occurred through the SRTM and ALOS – PALSAR data in the generation of the TIN (Irregular Triangular Network). Then, the volume and area values of the reservoirs were estimated for their volumetric characterization. Once the spatial distribution of the reservoirs for the study area was established, the volumetric capacity, surface area, and depth data were transformed into logarithmic equations for validation through statistical analysis. The data derived from the TIN SRTM and TIN ALOS – PALSAR models demonstrate the potential of using these tools in the identification and characterization of reservoirs in a detailed and precise manner. The reliability of the area and volume estimation is also demonstrated by combining estimates of the extent of these reservoirs using radar data in relation to area, volume, and depth.

**Keywords:** water availability, remote sensing, elevation models, lakes.

### 3 INTRODUÇÃO

Implementando tecnologias tradicionais de coleta de água da chuva e extração de água subterrânea (VAN DEN HOEK *et al.*, 2019), os reservatórios da fronteira oeste do Rio Grande do Sul são projetados para lidar com a variabilidade interanual da precipitação, estendendo a disponibilidade de água para uso agrícola e doméstico.

Tradicionalmente, reservatórios são identificados e monitorados usando níveis de água *in situ* calibrados por mapas batimétricos. No entanto, essa abordagem é desafiadora em áreas extensas, particularmente em regiões onde as estações hidrológicas não estão disponíveis. Consequentemente, o potencial hidrológico dos reservatórios permanece amplamente desconhecido (BITTERMAN *et al.*, 2016).

A disponibilidade de produtos de sensoriamento remoto vem sendo utilizada por pesquisadores e gestores de recursos hídricos em função de sua alta cobertura temporal e precisão razoável, o que não é fisicamente possível por meio de medições *in situ* (CHAWLA; KARTHIKEYAN; MISHRA, 2020). Entre as metodologias de sensoriamento remoto passíveis de aplicação para a detecção e monitoramento da disponibilidade de recursos hídricos, estão os dados digitais de terreno. Esses descrevem os atributos da superfície,

quantificam as características topográficas (WU; YANG; LI, 2018) e os aspectos morfométricos derivados de modelos digitais de elevação (MDEs) permitindo a detecção automática de formas elementares associadas ao relevo (BOLONGARO-CREVENNA *et al.*, 2005).

Entre os modelos mais utilizados, estão a Missão de Topografia de Radar de Varredura (*Shuttle Radar Topography Mission - SRTM*) (KALIRAJ *et al.*, 2017), o monitoramento em Tempo Real (PEKEL *et al.*, 2014) e, mais recentemente, o sensor ALOS – PALSAR (CLEWLEY *et al.*, 2015; PHAM *et al.*, 2018). Os sensores de satélite têm a capacidade de fornecer dados em escalas globais, o que é econômico em comparação com as aquisições de sensores terrestres ou aerotransportados (HUANG *et al.*, 2018).

Os dados de sensoriamento remoto são usados como entradas em modelos de sistema de informação geográfica (SIG) para detectar e monitorar áreas de grande produção agrícola, áreas essas que demandam grande consumo de água, como é o caso de lavouras de arroz (YEOM *et al.*, 2021). Além disso, a introdução da altimetria por satélite possibilita analisar as flutuações do nível de água em corpos d'água (BUSKER *et al.*, 2019).

O Rio Grande do Sul apresenta uma produção de 7,1 milhões de toneladas de arroz, em uma área plantada de 982.886 mil

hectares, representando 69% da produção nacional (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 2020). Dentre as diferentes regiões produtoras, a Região da Fronteira Oeste do Rio Grande do Sul vem sendo sucessivamente a líder nacional na produção do cereal. A expansão dos arrozais irrigados na planície alagada intensifica a fragmentação das áreas úmidas no sul do Brasil, que contém aproximadamente 72% dos fragmentos menores que 1 km<sup>2</sup>. Apesar de ser a maior região produtora de arroz, esta vem apresentando uma redução significativa no volume hídrico dos rios devido especialmente à grande demanda para irrigação (BOLSON; HAONAT, 2016). Desta forma, é importante a determinação da capacidade de armazenamento de reservatórios.

Assim, este trabalho objetivou identificar e determinar a capacidade de armazenamento de reservatórios da região da Fronteira Oeste do Rio Grande do Sul por meio de MDEs. Demonstra-se nesse

trabalho também a confiabilidade da estimativa de área e volume, combinando as estimativas de extensão desses reservatórios através de dados de radar com relação à área, volume e profundidade dos mesmos. Evidenciando assim, o potencial hidrológico de pequenos reservatórios, o que pode auxiliar e estimular práticas agrícolas sustentáveis.

## 4 MATERIAIS E MÉTODOS

### 4.1 Área de estudo

Considerando a necessidade de cobrir diferentes tipos e tamanhos de corpos de água para testar a abordagem de mapeamento, parte da Fronteira Oeste do Rio Grande do Sul, Brasil, mais especificamente os municípios de Alegrete, Itaqui, Quaraí e Uruguai foram escolhidos para a realização deste estudo (Figura 1).

**Figura 1.** Área de estudo - Fronteira Oeste do Rio Grande do Sul, Brasil.



Fonte: autores (2021).

Esta região está no Platô da Campanha com a presença de planícies associadas ao Rio Uruguai e seus afluentes (TRENTIN *et al.*, 2018). A área pertence ao bioma Pampa, onde predominam os campos de *Vachellia caven* (MOREIRA *et al.*, 2019), apresentando altitude média de 100 metros (BRASIL, 1973) e abrangendo uma área de 20.000 km<sup>2</sup>. A mesma é composta por abundantes e diversificados corpos de água, como rios (Uruguai, Ibicuí, Ibirapuitã), lagoas (Parové, Bonita, da Música), e zonas úmidas. Alguns desses corpos de água exibem características complexas, como turbidez, eutrofização e poluição.

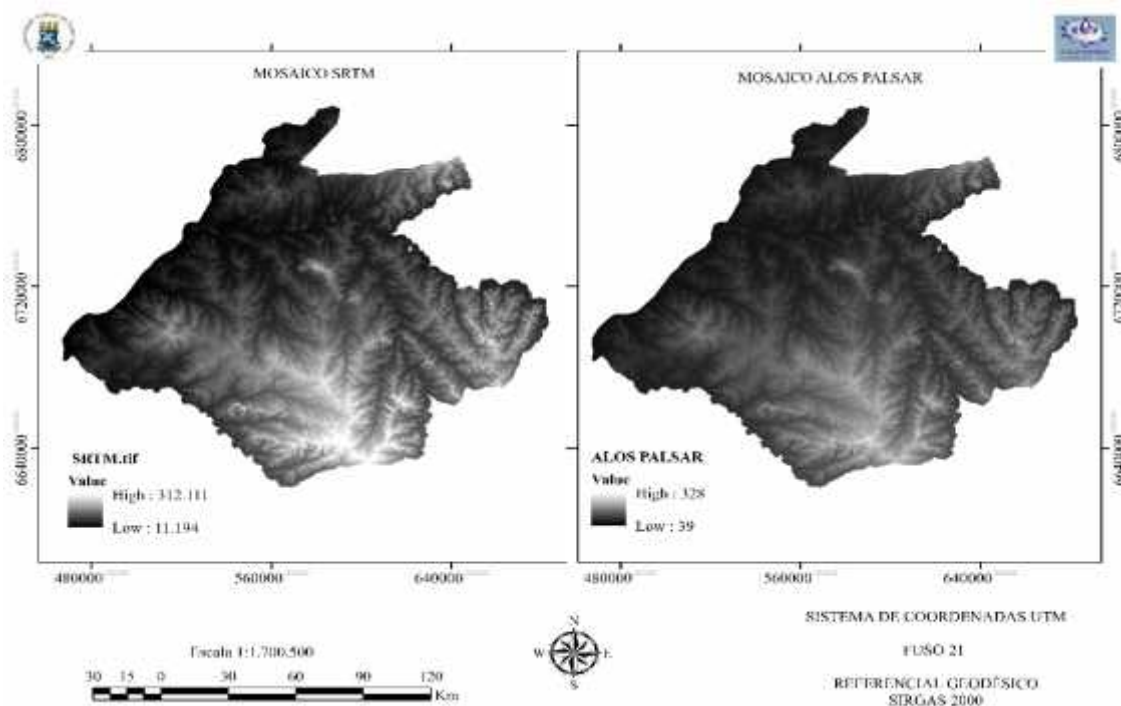
#### 4.2 Detecção dos reservatórios de água pelos Modelos *Shuttle Radar Topography Mission* (SRTM) e ALOS – PALSAR

Para o desenvolvimento deste trabalho, foi proposta uma metodologia dividida em duas etapas. Primeiramente,

para a identificação dos reservatórios de água, utilizou-se dados do SRTM e do ALOS – PALSAR. Na sequência, foi realizada a caracterização volumétrica dos reservatórios identificados

Para a detecção dos reservatórios, foram utilizados dados do *Shuttle Radar Topography Mission* (SRTM) e do ALOS – PALSAR. Os dados do SRTM, adquiridos do site Brasil em Relevo da Empresa Brasileira de Pesquisa Agropecuária (Embrapa) (<https://www.embrapa.br/>), apresentam resolução espacial de 30 metros. Oito (8) cenas SRTM para a cobertura total da área de estudo foram adquiridas. Utilizou-se também dados ALOS – PALSAR, com resolução espacial de 12,5 metros que foram adquiridos por meio do site da *Alaska Satellite Facility* (<https://www.asf.alaska.edu/>). Foram adquiridas dez (10) cenas para toda a área de estudo. Foi realizado um mosaico das cenas para contemplar toda a área de estudo (Figura 2).

**Figura 2.** Mosaicos gerados por meio de dados do *Shuttle Radar Topography Mission* (SRTM) e do sensor ALOS – PALSAR.



Fonte: autores (2021).

Além disso, foram geradas curvas de nível com intervalo de 5 metros, caracterizando de forma satisfatória o perfil topográfico da área de estudo. A partir do mosaico e das curvas de nível, foi gerado uma Rede Triangular Irregular - TIN contendo dados estimados de superfície (SRTM e ALOS – PALSAR).

Foram definidas as orientações do fluxo da água na superfície da área de estudo, aliada à correção das depressões superficiais, adicionando uma elevação artificial. A identificação e o tratamento de grandes depressões (células agrupadas e com direção de fluxo indefinida) visou verificar qual célula da borda tinha a célula vizinha de menor altitude. Essa célula vizinha foi tida como potencial exutório da depressão.

A análise também identificou se as depressões compartilhavam uma mesma célula exutória, o que possibilitou considerá-las como uma única depressão, ou seja, elas se fundiam. Para corrigir e possibilitar o fluxo, todas as células da depressão que tinham altitude inferior à altitude da célula exutória da depressão, passaram a ter esse valor.

Entre esses métodos de tratamento de dados em ambiente de SIG, a maior parte deles se baseiam no algoritmo chamado D8 (*deterministic eight-neighbors*), no qual é definida uma entre oito direções de escoamento, utilizando como critério a maior declividade, ou seja, cada célula escoará apenas para uma das oito células vizinhas mais próximas (FAN *et al.*, 2013). Posteriormente, foi realizada a determinação das linhas de drenagem da área, bacias e sub-bacias hidrográficas, realizando o preenchimento de depressões contidas no TIN original. Na sequência, o TIN original foi subtraído do TIN sem depressões, resultando em um arquivo *raster* com um valor zero para todos os pixels, exceto nas áreas onde antes havia uma depressão.

As depressões naturais, falhas de levantamento ou reservatórios, foram

obtidas através da diferença entre o TIN original e TIN preenchido. Neste caso, apenas a detecção do reservatório foi de interesse. As depressões naturais e as falhas foram consideradas como ruído e foram minimizadas.

Em seguida, foi desenvolvida a classificação do modelo no qual se utilizou duas classes, uma com as células com valor (Z) igual a zero, podendo ser classificada como terreno e a outra com as células com valores diferentes de zero, podendo ser classificada como reservatórios. Para a classificação, pode ser alterado o valor, o limite entre as classes de terreno e os reservatórios. Quando escolhido o valor limite nulo (0), todo o modelo numérico com valor diferente de zero será identificado como reservatório. Quanto maior esse limite, menos células são classificadas como depressões preenchidas, bem como, menor é a área das depressões encontradas. A operação identificou pequenos afundamentos no terreno, como também a rede de drenagem e falhas formadas na própria composição do TIN para a área de estudo.

Com a detecção dos reservatórios nos modelos *Shuttle Radar Topography Mission* - SRTM e ALOS – PALSAR, procedeu-se com a validação de dados por meio da observação de imagem captada pelo satélite Sentinel 2B – MSI, tendo como finalidade analisar se os mesmos coincidiam nas áreas identificadas como reservatórios.

### 4.3 Caracterização volumétrica dos reservatórios

A determinação do volume dos reservatórios foi realizada conforme a Equação 1. Primeiramente, o volume dos reservatórios foi estimado utilizando o TIN e a ferramenta *Area and Volume (3D Analyst)* do ArcGIS Desktop® 10.4.1. A ferramenta ‘*Area and Volume*’ calcula o volume e a área da superfície abaixo do plano que representa o nível da água. O

volume armazenado em cada célula ( $VCel$ ) é dado pelo produto entre a área do pixel ( $ACel$ ) e a diferença de altura entre o nível

do reservatório ( $HCel Res$ ) e a elevação do terreno ( $HCel Terreno$ ), como demonstra a Equação 1:

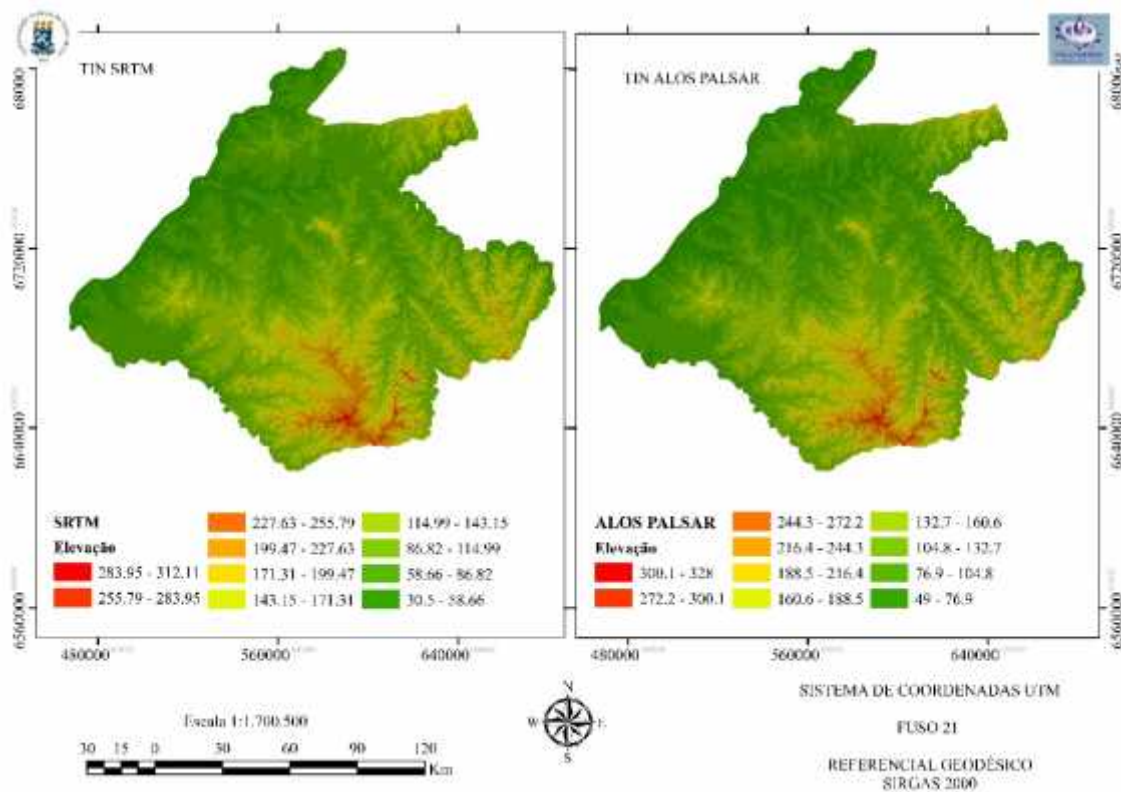
$$VCel = ACel \times (HCel Res - HCel Terreno) \quad (1)$$

## 5 RESULTADOS E DISCUSSÃO

### 5.1 Modelos TIN e direção de fluxo derivados de modelos SRTM (*Shuttle Radar Topography Mission*) e ALOS – PALSAR

A partir do mosaico, foram geradas curvas de nível com intervalo de 5 metros, caracterizando de forma satisfatória o perfil topográfico da área de estudo. Uma Rede Triangular Irregular – TIN, contendo dados estimados de superfície (SRTM e ALOS – PALSAR) foi gerada (Figura 3).

**Figura 3.** Modelos TIN (Rede Triangular Irregular) com dados de elevação derivados de modelos SRTM (*Shuttle Radar Topography Mission*) e ALOS – PALSAR.



**Fonte:** autores (2021).

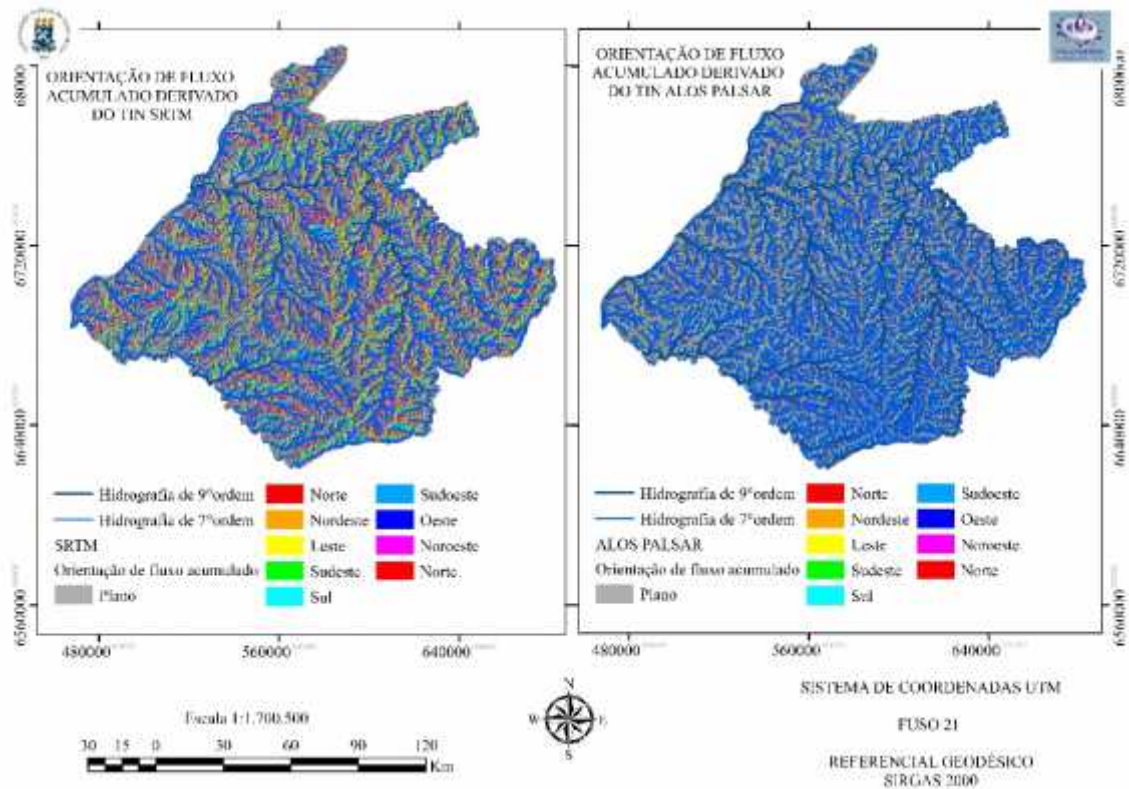
Foram definidas as orientações do fluxo da água na superfície da bacia, em conjunto com a correção das depressões superficiais, adicionando uma elevação artificial, o que possibilitou a identificação e o tratamento das grandes depressões que o

TIN SRTM apresentou, esse produto, mesmo com maior número de células agrupadas e uma direção de fluxo indefinida permitiu a constatação de que algumas depressões compartilhavam a mesma célula exotória, essas, por sua vez, foram

consideradas como uma única depressão. Para corrigir e possibilitar o fluxo, todas as células da depressão que apresentavam

altitude inferior à altitude da célula exotória da depressão, passaram a ter esse valor (Figura 4).

**Figura 4.** Orientação de fluxo acumulado derivados de modelos SRTM (*Shuttle Radar Topography Mission*) e ALOS – PALSAR.



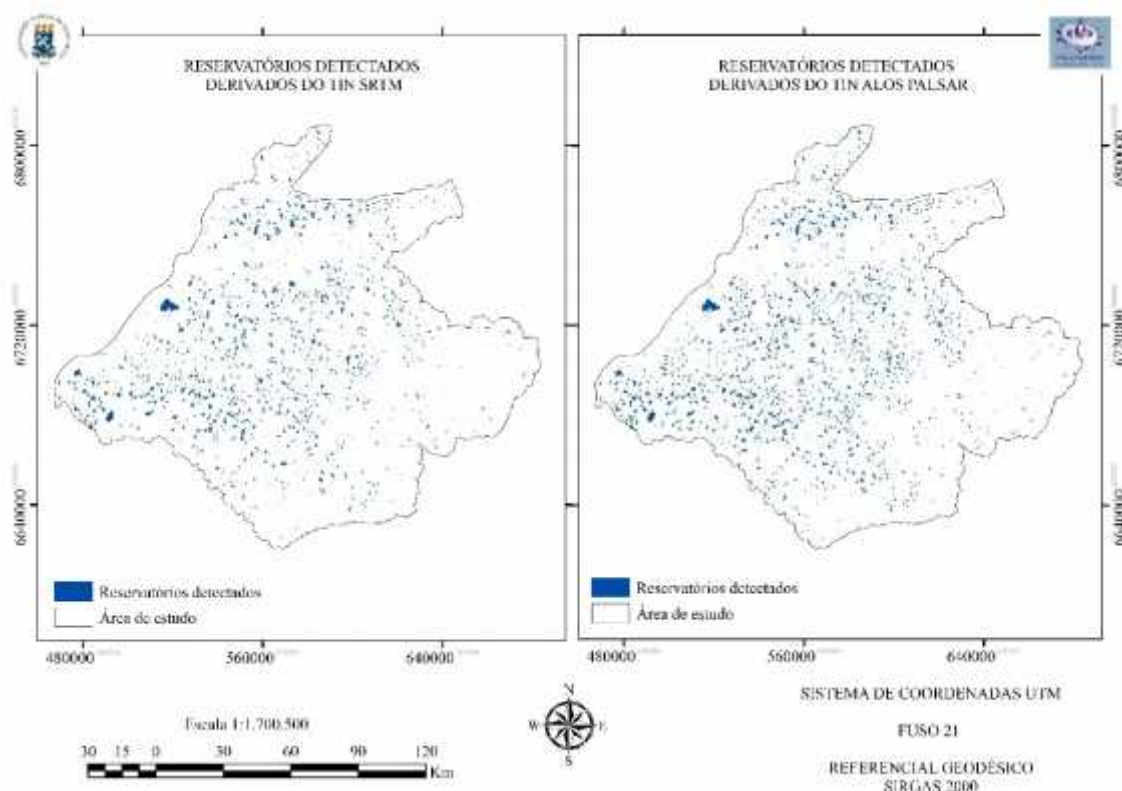
Fonte: autores (2021).

Os dados obtidos foram semelhantes para ambos os modelos (TIN SRTM e TIN ALOS – PALSAR), sendo que a menor depressão identificada foi de 30,5 e 49 metros acima do nível do mar, respectivamente. As elevações também foram diferentes para os dois modelos, sendo que para o TIN SRTM a elevação máxima foi de 312,11 metros acima do nível do mar e para o modelo TIN ALOS – PALSAR foi detectada elevação máxima de 328 metros acima do nível do mar (Figura 3). A determinação das direções de escoamento através do TIN foi fundamental para entender a importância do preenchimento de depressões.

## 5.2 Detecção de reservatórios derivados de modelos SRTM (*Shuttle Radar Topography Mission*) e ALOS – PALSAR

A detecção dos reservatórios utilizando dados TIN SRTM e TIN ALOS – PALSAR apresentou uma adequada identificação dos alvos (Figura 4). Em função da resolução espacial de 30 metros do SRTM, algumas áreas foram subestimadas, a área de lâmina d'água não preservou as dimensões da cota máxima de acumulação, bem como, pequenos reservatórios com diferença de cota para vertimento menor ou igual a 2 metros não foram identificados.

**Figura 4.** Reservatórios detectados derivados do TIN SRTM (*Shuttle Radar Topography Mission*) e TIN ALOS – PALSAR e suas características



**Fonte:** autores (2021).

O modelo TIN SRTM identificou uma menor área de superfície, igual a 0,15 hectares e também a maior área superficial, igual a 2,3 mil hectares. Quando comparada à sensibilidade de detecção de reservatórios

através de dados TIN ALOS – PALSAR, a menor área de superfície detectada foi de 0,027 hectares e a maior área foi de 2,3 mil hectares. As diferenças entre os dois modelos estão apresentadas na Tabela 1.

**Tabela 1.** Dados derivados dos modelos TIN SRTM e TIN ALOS – PALSAR.

Resultados	SRTM	ALOS – PALSAR
Reservatórios Identificados	1.268	1.510
Depressões ou vazios	254	276
Áreas	subestimadas	fidedignas
Preservação das áreas	não	sim
Área mínima	0,15 ha	0,027 ha
Área máxima	2.300 ha	2.200 ha

**Fonte:** autores (2021).

\*SRTM: *Shuttle Radar Topography Mission*

Nesse contexto, Carvalho *et al.* (2009), usando imagens do satélite CBERS-2, identificou 17.083 reservatórios com superfície maior que 5 hectares na região Nordeste do Brasil. No estudo, 48 de 61

reservatórios menores que 1 hectare foram detectados corretamente. Aliado a isso, recentemente Nascimento (2017), utilizando imagens Landsat 8 – OLI, identificou 79 reservatórios na bacia do Riacho Quixaba,



desses, 77,22% foram classificados corretamente.

A dificuldade existente na classificação dos limites de água-terra deve-se, principalmente, à baixa resolução espacial das imagens bem como à reflectância emitida na bordadura dos corpos d'água (PALMER; KUTSER; HUNTER, 2015). Diante das dificuldades na identificação dos corpos d'água, são criados algoritmos de detecção baseados em dados de radar de abertura sintética (SAR).

Alguns autores, como Bolanos *et al.* (2016), Clement *et al.* (2018) e Martinis, Plank e Cwik (2018) utilizaram procedimentos baseados em limiares de nível de cinza, corroborando na metodologia utilizada no desenvolvimento deste estudo. Segundo Behnamian *et al.* (2017), o procedimento sugere que todos os valores de pixel menores que um limite definidos sejam categorizados como água para corpos d'água já identificados; porém, o retroespalhamento de pixel pode variar entre as aquisições de dados SAR, já que os mesmos são amplamente influenciados pelo clima, rugosidade da superfície, assim como a polarização e ângulo de incidência.

O limite definido deve ser determinado por cena e deve ser subdividido por regiões com os seus devidos limiares delimitados (BOLANOS *et al.*, 2016). Por mais que seja fácil de implementar essa técnica baseada em limites de nível de cinza, determinar o limite do mesmo foi um desafio, uma vez que cada cena apresentou uma característica diferente, por se tratar de uma região particularmente plana, e por possuir características próprias da região como a presença de áreas conhecidas como banhados.

Por outro lado, as características da água também podem influenciar na identificação de corpos d'água, já que uma superfície d'água limpa e uma água com

impurezas ou com turbidez se comportam espectralmente de forma diferente (CHAWLA; KARTHIKEYAN; MISHRA, 2020). Um corpo de água transparente absorve cerca de 97-99% da energia incidente e reflete apenas 1-3% das radiações incidentes (BÜTTNER *et al.*, 1987) e a água poluída possui uma maior reflectância. Essa proporção de reflectância é alterada com a mudança nos constituintes da água, quanto mais poluída, maior será sua reflectância, o comprimento de onda também se altera com os constituintes da água; portanto, as assinaturas espectrais são únicas para cada corpo d'água (CHAWLA; KARTHIKEYAN; MISHRA, 2020). Assim, a relação entre reflectância espectral e os parâmetros de qualidade devem ser levada em consideração sempre que possível.

### 5.3 Caracterização volumétrica dos reservatórios

Para o cálculo da área e do volume dos reservatórios identificados pelos TIN gerados a partir dos modelos *Shuttle Radar Topography Mission - SRTM* e *ALOS - PALSAR*, foi utilizado a ferramenta 'Area and Volume' do software ArcGIS® 10.4.1 (Tabela 2). Para dados calculados por meio do TIN ALOS - PALSAR, o volume mínimo encontrado foi de 257 m<sup>3</sup> e o maior volume foi de 245 milhões de m<sup>3</sup>, o volume disponível para toda área de estudo foi de 2,8 bilhões de m<sup>3</sup>. As profundidades dos reservatórios variaram de 1,2 a 53,0 m, com média de 12,5 m. Para o produto gerado com dados do TIN - SRTM, o volume mínimo encontrado foi de 401 m<sup>3</sup> e o maior de 255 milhões de m<sup>3</sup>. As profundidades dos reservatórios variaram de 3,0 a 59,0 m, apresentando média de 10,9 metros. O volume disponível para toda área de estudo foi de 2,2 bilhões de m<sup>3</sup>.

**Tabela 2.** Caracterização volumétrica dos reservatórios realizada pelo SRTM (*Shuttle Radar Topography Mission*) e pelo ALOS – PALSAR.

Resultados	SRTM	ALOS – PALSAR
Volume mínimo	401 m <sup>3</sup>	257 m <sup>3</sup>
Volume máximo	255 milhões m <sup>3</sup>	245 milhões m <sup>3</sup>
Volume disponível	2,2 bilhões m <sup>3</sup>	2,8 bilhões m <sup>3</sup>
Alturas	3 - 59 m	1,2 - 59 m

Fonte: autores (2021).

\*SRTM: *Shuttle Radar Topography Mission*

O sensor ALOS – PALSAR possibilitou a identificação de reservatórios com uma altura menor, fazendo com que qualquer depressão fosse classificada como reservatório, tornando-se uma técnica inadequada quando comparada ao TIN SRTM (*Shuttle Radar Topography Mission*).

Comparando os dados dos modelos digitais de elevação SRTM e ALOS – PALSAR, percebe-se uma diferença significativa entre a precisão vertical, já para a precisão horizontal essa diferença não é significativa. Khasanov e Ahmedov (2021) encontraram essa mesma característica no estudo da barragem *Pskom* na região de *Tashkent*, onde os autores compararam os modelos ALOS – PALSAR MDE, ASTER MDEG e SRTM.4 (*Shuttle Radar Topography Mission*), dentre os quais, o MDE ALOS – PALSAR apresentou melhor desempenho, visto que tratava-se de uma área relativamente grande.

Bakiev e Khasanov (2021) em um estudo de caso para locação de um reservatório de grande porte, ao compararem os modelos ALOS – PALSAR, SRTM e ASTER MDEG, observaram nos resultados de comparação do perfil longitudinal da barragem que o modelo ALOS – PALSAR apresentou uma melhor precisão. Devido a essa questão, alguns autores utilizam abordagens diferentes para calibrar os dados de sensoriamento remoto por satélite para corpos de águas superficiais, principalmente, para o volume de água de

pequenos reservatórios.

As abordagens de maior sucesso incorporam uma geometria de reservatório generalizada ou real (BAUP; FRAPPART; MAUBANT, 2014; GAO; BIRKETT; LETTENMAIER, 2012). A base teórica generaliza a forma do reservatório, que pode ser simplificada como uma pirâmide de base quadrada cortada diagonalmente pela metade. Uma expressão de lei de potência calibra a área de superfície e o volume dentro de uma região geomorfologicamente homogênea (ANNOR *et al.*, 2009; YOUNG *et al.*, 2017).

#### 5.4 Validação dos resultados

Tendo sido estabelecida a distribuição espacial dos reservatórios para a área de estudo, os dados para capacidade volumétrica, área de superfície e profundidade foram transformados em equações log para posterior validação dos mesmos. A regressão para os dados gerados pelos modelos TIN a partir de dados *Shuttle Radar Topography Mission* - SRTM e ALOS-PALSAR mostrou uma correlação entre logaritmos de profundidade e volume, sendo a profundidade a variável independente e o volume a variável dependente para os dados (Figura 5). Os dados de erro padrão de estimativa (Tabela 3) de 0,7401 para os dados ALOS – PALSAR e de 0,6978 para o SRTM, evidenciam a grande variabilidade das áreas encontradas.

**Tabela 3.** Resumo estatístico de profundidade e volume dos modelos ALOS – PALSAR e TIN SRTM.


TIN	R	R <sup>2</sup>	R <sup>2</sup> Ajus.	Erro Padrão Est.	Coefficientes	Erro Padrão	t	P	
ALOS - PALSAR	0,391	0,391	0,390	0,7401	y0	3,002	0,082	36,273	<0,0001
					a	2,462	0,079	31,117	<0,0001
SRTM	0,528	0,528	0,527	0,6978	y0	3,377	0,058	57,899	<0,0001
					a	2,224	0,059	37,605	<0,0001

**Fonte:** autores (2021).

TIN: *Triangulated Irregular Network*; SRTM: *Shuttle Radar Topography Mission*; R: coeficiente de correlação múltipla; R<sup>2</sup>:coeficiente de determinação; R<sup>2</sup> Ajus.: coeficiente de determinação ajustado; Erro Padrão da Estimativa; Coeficientes: y0 e a; Erro Padrão: dos coeficientes; t: Teste t de *Student*, P:Coeficiente de correlação de Pearson.

Falhas de elevação, mais conhecidas por vórtices, podem ser as responsáveis pelos altos valores da variável erro padrão de estimativa, e são geralmente representadas por cotas negativas (-100 m). Tais artefatos são facilmente reconhecíveis nas imagens devido a área de estudo ser relativamente pequena, porém, em virtude do elevado módulo desse valor, sua remoção requer operações cuidadosas para que não se

contaminem as informações válidas. Isso deve-se a resolução espacial inicial de 90 metros que posteriormente foi reamostrada para 30 metros, com isso algumas áreas são subestimadas, o teste t e as análises de correlação de Pearson indicaram uma correlação positiva perfeita entre as duas variáveis, com valor de p <0,0001 para a imagem ALOS – PALSAR e *Shuttle Radar Topography Mission* – SRTM (Tabela 3).

**Figura 5.** Dependência espacial entre as variáveis profundidade e volume.

**Fonte:** autores (2021).

\*SRTM: *Shuttle Radar Topography Mission*

Em ambos os casos, as variáveis são positivamente correlacionadas e apresentam uma correlação linear significativa forte. Quanto maior a profundidade dos reservatórios, maior é o volume armazenado

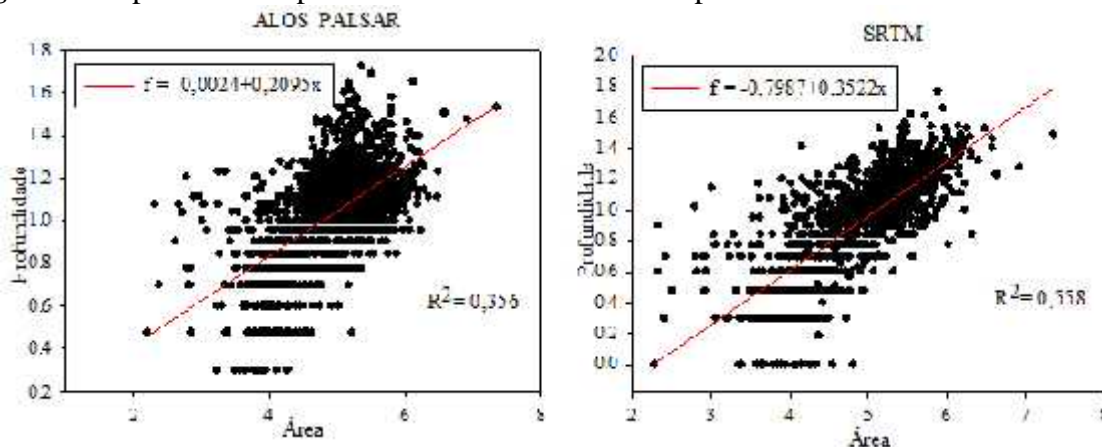
por eles. Para dados ALOS – PALSAR, o modelo explica 39% dos dados observados, enquanto para os dados do SRTM (*Shuttle Radar Topography Mission*), o modelo explica 52% dos casos observados. Isso se

deve à fraca dependência entre essas variáveis (PACHECO et al., 2015).

A correlação entre logaritmos de área e profundidade, sendo a área variável independente e a profundidade variável dependente para dados ALOS – PALSAR e SRTM demonstra, em ambos casos, que as variáveis são positivamente correlacionadas,

e que existe uma correlação linear significativa moderada (Figura 6). Para dados ALOS – PALSAR, o modelo explica 35% dos dados observados. Já para dados SRTM (Shuttle Radar Topography Mission), o modelo explica 55% dos casos observados.

**Figura 6.** Dependência espacial entre as variáveis área e profundidade.



**Fonte:** autores (2021).

\*SRTM: *Shuttle Radar Topography Mission*

Os dados de erro padrão de estimativa (Tabela 4) de 0,2204 para os dados SRTM (Shuttle Radar Topography Mission) é maior do que o erro para os dados ALOS – PALSAR. O teste t e as análises de correlação de Pearson no intervalo de confiança de 95% indicaram que as variâncias das duas variáveis são iguais ( $p <$

0,0001), o que significa que as áreas e alturas estão correlacionadas no modelo SRTM; enquanto para o modelo ALOS – PALSAR, o t -teste e as análises de correlação de Pearson no intervalo de confiança de 95% não indicaram correlação entre as variáveis analisadas.

**Tabela 4.** Resumo estatístico de área e profundidade dos modelos ALOS – PALSAR e TIN SRTM.

TIN	R	R <sup>2</sup>	R <sup>2</sup> Ajus.	Erro Padrão Est.	Coefficiente s	Erro Padrão	t	P	
ALOS - PALSAR	0,597	0,356	0,356	0,193	y0 a	-0,0024 0,2095	0,035 0,007	-0,066 28,902	0,9467 <0,0001
SRTM	0,747	0,558	0,558	0,220	y0 a	-0,7987 0,3522	0,043 0,008	-18,317 40,021	<0,0001 <0,0001


**Fonte:** autores (2021).

TIN: *Triangulated Irregular Network*; SRTM: *Shuttle Radar Topography Mission*; R: coeficiente de correlação múltipla; R<sup>2</sup>:coeficiente de determinação; R<sup>2</sup> Ajus.: coeficiente de determinação ajustado; Erro Padrão da Estimativa; Coeficientes: y0 e a; Erro Padrão: dos coeficientes; t: Teste t de *Student*, P:Coeficiente de correlação de Pearson.

A correlação entre logaritmos de área e volume, considerou a área como variável independente e o volume como a variável dependente para dados do ALOS – PALSAR e da SRTM (Figura 7). Em ambos casos, as variáveis são positivamente correlacionadas, e há uma correlação linear significativa forte. Para dados do ALOS – PALSAR, o

modelo explica 86% dos dados observados. Já para dados da SRTM (*Shuttle Radar Topography Mission*), o modelo explica 89% dos casos observados. Isso é resultante da dependência entre as variáveis, ou seja, quanto maior a área, maior será o volume suportado pelos reservatórios.

**Figura 7.** Dependência espacial entre as variáveis área e volume.



Fonte: autores (2021).

\*SRTM: *Shuttle Radar Topography Mission*

A regressão linear demonstrou que o erro padrão de estimativa para o modelo SRTM foi de 0,3300, havendo uma dependência entre as variáveis; para o modelo ALOS – PALSAR, esse resultado foi de 0,3458. O teste t e as análises de correlação de Pearson indicaram uma correlação positiva perfeita entre as duas

variáveis, com valor de  $p < 0,0001$  para a imagem PALSAR e SRTM (Tabela 5).

O coeficiente de Normalidade W para os dados SRTM foi de  $W = 0,9971$ , enquanto os dados ALOS – PALSAR apresentaram  $W = 0,9894$ ; o teste de normalidade dos dados foi significativo para os dois modelos.

**Tabela 5.** Resumo estatístico de área e volume dos modelos ALOS – PALSAR e TIN SRTM (*Shuttle Radar Topography Mission*).

TIN	R	R <sup>2</sup>	R <sup>2</sup> Ajus.	Erro Padrão Est.	Coefficientes	Erro Padrão	T	P	
ALOS - PALSAR	0,931	0,867	0,867	0,345	y0	-0,7571	0,0638	-11,866	<0,0001
					a	1,2869	0,013	99,173	<0,0001
SRTM	0,945	0,894	0,894	0,33	y0	-1,2463	0,0653	-19,088	<0,0001
					a	1,364	0,0132	103,503	<0,0001

Fonte: autores (2021).

TIN: *Triangulated Irregular Network*; SRTM: *Shuttle Radar Topography Mission*; R: coeficiente de correlação múltipla; R<sup>2</sup>:coeficiente de determinação; R<sup>2</sup> Ajus.: coeficiente de determinação ajustado; Erro Padrão da

Estimativa; Coeficientes:  $y_0$  e  $a$ ; Erro Padrão: dos coeficientes;  $t$ : Teste  $t$  de *Student*,  $P$ : Coeficiente de correlação de Pearson.

O trabalho de Wang *et al.* (2005), utilizou MDE's adquiridos pelo programa espacial da *National Aeronautics and Space Administration* (NASA) e Shuttle Radar Topography Mission (SRTM) para o cálculo de área e volume do reservatório da represa de Três Gargantas, no município de Chongqing na China. Esses autores verificaram ser possível a identificação e a caracterização de reservatórios de água doce. É importante destacar que a Barragem de Três Gargantas é a segunda maior represa do mundo e suas dimensões possibilitam que, utilizando MDE's com resolução espacial de 90 metros, seja possível obter-se resultados satisfatórios.

Levando em consideração as resoluções espaciais e o número elevado de reservatórios identificados, o Modelo ALOS – PALSAR, por possuir uma melhor resolução espacial, não resultou em melhores resultados estatísticos. Isso se deve ao grande número de reservatórios pequenos identificados, fazendo com que as variáveis área, altura e volume tenham uma maior amplitude nos dados, influenciando diretamente nos resultados encontrados. Já o modelo SRTM, apesar de sua resolução grosseira de 30 metros, torna possível a identificação de reservatórios; todavia, esses devem apresentar uma área superior a 1.500 m<sup>2</sup>, já que foi a menor área identificada.

Assim, a partir da comparação de áreas geradas pelos modelos TIN, entende-se que as áreas cobertas com água podem ter sido classificadas como vegetação, o que levou à contagem de pixels de forma errônea. Esse problema pode ser encontrado em Crapper (1980), em que o autor estimou áreas contando pixels em imagens Landsat 8 – OLI. Nesse trabalho, as células perimetrais com assinatura espectral mista influenciaram nos resultados gerados. Para Costello, Cheung e Hauwere (2010), os dados estatísticos sobre profundidade oceânica e topografia são frequentemente

citados; porém, os métodos derivativos desses resultados raramente são apresentados. Para o autor, a menos que seja calculada usando a mesma resolução espacial, as estatísticas resultantes não serão estritamente comparáveis, impossibilitando a comparação com os dados gerados neste trabalho.

A validação dos dados obtidos com dados reais de terreno não foi possível por dois motivos. O primeiro é que a área de estudo é extensa o que demandaria tempo e recurso para a realização das batimetrias dos reservatórios e para os levantamentos topográficos da região. Por esse motivo, a quantificação e caracterização volumétrica dos reservatórios de água doce é negligenciada por parte dos pesquisadores, visto que os métodos de monitoramento *in-situ* são desafiadores em áreas extensas. Segundo os dados reais de batimetrias que possuíamos, levantados na década de 80, não foram comparados com os dados identificados no trabalho, já que muitos dos reservatórios identificados no presente estudo não existiam na época dessa coleta a campo, outros deixaram de existir com o passar do tempo ou sofreram alguma alteração na sua estrutura.

## 6 CONCLUSÃO

Os métodos utilizados possibilitaram detectar reservatórios consideravelmente pequenos, aliado à possibilidade de calcular a capacidade volumétrica dos reservatórios, sendo passíveis de comparação com outros trabalhos que utilizam dados de sensoriamento remoto como os modelos MDE e TIN. Assim, as análises realizadas neste estudo são importantes para a identificação e caracterização de recursos hídricos, gerando informações detalhadas da área pesquisada. Por fim, demonstra-se o potencial do uso das ferramentas de

geoprocessamento no monitoramento, no planejamento e na gestão dos recursos hídricos para a produção agrícola, podendo

essa metodologia ser utilizada em estudos futuros em outras regiões.

## 7 REFERÊNCIAS

- ANNOR, F. O.; VAN DE GIESEN, N.; LIEBE, J.; VAN DE ZAAG, P.; TILMANT, A.; ODAI, S. N. Delineation of small reservoirs using radar imagery in a semi-arid environment: A case study in the upper east region of Ghana. **Physics and Chemistry of the Earth**, Oxford, v. 34, n. 4-5, p. 309-315, 2009.
- BAKIEV, M.; KHASANOV, K. Comparison of digital elevation models for determining the area and volume of the water reservoir. **International Journal of Geoinformatics**, Pathum Thani, v. 17, n. 1, p. 37-45, 2021.
- BAUP, F.; FRAPPART, F.; MAUBANT, J. Combining high-resolution satellite images and altimetry to estimate the volume of small lakes. **Hydrology and Earth System Sciences**, Gottingen, v. 18, n. 5, p. 2007-2020, 2014.
- BEHNAMIAN, A.; BANKS, S.; WHITE, L.; BRISCO, B.; MILLARD, K.; PASHER, J.; CHEN, Z.; DUFFE, J.; BOURGEOU-CHAVEZ, L.; BATTAGLIA, M. Semi-automated surface water detection with synthetic aperture radar data: A wetland case study. **Remote Sensing**, Basel, v. 9, n. 12, p. 1209-1230-, 2017.
- BITTERMAN, P.; TATE, E.; VAN METER, K. J.; BASU, N. B. Water security and rainwater harvesting: A conceptual framework and candidate indicators. **Applied Geography**, Oxford, v. 76, n. 1, p. 75-84, 2016.
- BRASIL. Ministério da Agricultura. Divisão de Pesquisas Pedológicas. **Levantamento de reconhecimento de solos do Rio Grande do Sul**. Boletim Técnico 30, Recife, Departamento Nacional de Pesquisa Agropecuária - Divisão de Pesquisa Pedológica, 1973.
- BOLANOS, S.; STIFF, D.; BRISCO, B.; PIETRONIRO, A. Operational surface water detection and monitoring using Radarsat 2. **Remote Sensing**, Basel, v. 8, n. 4, p. 285-303, 2016.
- BOLONGARO-CREVENNA, A.; TORRES-RODRIGUEZ, V.; SORANI, V.; FRAME, D.; ORTIZ, M. A. Geomorphometric analysis for characterizing landforms in Morelos State, Mexico. **Geomorphology**, Amsterdam, v. 67, n. 3-4, p. 407-422, 2005.
- BOLSON, S. H.; HAONAT, A. I. A governança da água, vulnerabilidade hídrica e os impactos das mudanças climáticas no Brasil. **Veredas do Direito: Direito Ambiental e Desenvolvimento Sustentável**, Belo Horizonte, v. 13, n. 25, p. 223-248, 2016.
- BÜTTNER, G.; KORANDI, M.; GYÖMÖREI, A.; KÖTE, Z.; SZABÓ, G. Satellite remote sensing of inland waters: Lake Balaton and reservoir Kisköre. **Acta Astronautica**, Elmsford, v. 15, n. 6-7, p. 305-311, 1987.

BUSKER, T.; ROO, A. D.; GELATI, E.; SCHWATKE, C.; ADAMOVIC, M.; BISSELINK, B.; PEKELL, J. F.; COTTAM, A. A global lake and reservoir volume analysis using a surface water dataset and satellite altimetry. **Hydrology and Earth System Sciences**, Gottingen, v. 23, n. 2, p. 669-690, 2019.

CARVALHO, M. S. B. S., MARTINS, S. P. R. M., SOARES, A. M., CHAVES, L. C., OLIVEIRA, F. A., PERINI, D. S., MENESCAL, A. R.; WARREN, M. Levantamento dos espelhos d'água acima de 20 ha em todo o território brasileiro através de sensoriamento remoto. In: **Remote Sensing Symposium**, Natal: INPE, p. 1967-1974, 2009.

CHAWLA, I.; KARTHIKEYAN, L.; MISHRA, A. K. A review of remote sensing applications for water security: Quantity, quality, and extremes. **Journal of Hydrology**, Amsterdam, v. 585, n. 124826, p. 01-28, 2020.

CLEMENT, M. A.; KILSBY, C. G.; MOORE, P. Multi temporal synthetic aperture radar flood mapping using change detection. **Journal of Flood Risk Management**, London, v. 11, n. 2, p. 152-168, 2018.

CLEWLEY, D.; WHITCOMB, J.; MOGHADDAM, M.; MCDONALD, K.; CHAPMAN, B.; BUNTING, P. Evaluation of ALOS – PALSAR data for high-resolution mapping of vegetated wetlands in Alaska. **Remote Sensing**, Basel, v. 7, n. 6, p. 7272-7297, 2015.

COSTELLO, M. J.; CHEUNG, A.; HAUWERE, N. Surface area and the seabed area, volume, depth, slope, and topographic variation for the world's seas, oceans, and countries. **Environmental science & technology**, Washington, DC, v. 44, n. 23, p. 8821-8828, 2010.

CRAPPER, P. F. Errors incurred in estimating an area of uniform land cover using Landsat. **Photogrammetric Engineering and Remote Sensing**. Falls Church, v. 46, n. 10, p. 1295-1301, 1980.

FAN, F. M.; COLLISCHONN, W.; SORRIBAS, M. V.; RÓGENES, P.; PONTES, M. Sobre o Início da Rede de Drenagem Definida a Partir dos Modelos Digitais de Elevação. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 18, n. 3, p. 241-257, 2013.

GAO, H.; BIRKETT, C.; LETTENMAIER, D. P. Global monitoring of large reservoir storage from satellite remote sensing. **Water Resources Research**, Washington, v. 48, n. 9, p. 01-12, 2012.

HUANG, Y.; CHEN, Z. X.; TAO, Y. U.; HUANG, X. Z.; GU, X. F. Agricultural remote sensing big data: Management and applications. **Journal of Integrative Agriculture**, Beijing, v. 17, n. 9, p. 1915-1931, 2018.

IBGE. **Produção Agrícola Municipal**. Rio de Janeiro: IBGE, 2020. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9117-producao-agricola-municipal-culturas-temporarias-e-permanentes.html?=&t=destaques>. Acesso em: 13 maio 2021.



- KALIRAJ, S.; CHANDRASEKAR, N.; RAMACHANDRAN, K. K. Mapping of coastal landforms and volumetric change analysis in the south west coast of Kanyakumari, South India using remote sensing and GIS techniques. **The Egyptian Journal of Remote Sensing and Space Science**, Cairo, v. 20, n. 2, p. 265-282, 2017.
- KHASANOV, K.; AHMEDOV, A. Comparison of Digital Elevation Models for the designing water reservoirs: a case study Pskom water reservoir. **E3S Web of Conferences**, Les Ulis, v. 264, p. 03058, 2021.
- MARTINIS, S.; PLANK, S.; WIK, K. The use of Sentinel-1 time-series data to improve flood monitoring in arid areas. **Remote Sensing**, Basel, v. 10, n. 583, p. 01-13, 2018.
- MOREIRA, A.; BREMM, C.; FONTANA, D. C.; KUPLICH, T. M. Seasonal dynamics of vegetation indices as a criterion for grouping grassland typologies. **Scientia Agricola**, São Paulo, v. 76, n. 1, p. 24-32, 2019.
- NASCIMENTO, V. F.; RIBEIRO NETO, A. Characterization of reservoirs for water supply in Northeast Brazil using high resolution remote sensing. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 22, n. 50, p. 01-09, 2017.
- PACHECO, A.; HORTA, J.; LOUREIRO, C.; FERREIRA, O. Retrieval of nearshore bathymetry from Landsat 8 images: a tool for coastal monitoring in shallow waters. **Remote Sensing of Environment**, New York, v. 159, p. 102-116, 2015.
- PALMER, S. C. J.; KUTSER, T.; HUNTER, P. D. Remote sensing of inland waters: Challenges, progress and future directions. **Remote Sensing of Environment**, New York, v. 157, p. 1-8, 2015.
- PEKEL, J. F.; VANCUTSEM, C.; BASTIN, L.; CLERICI, M.; VANBOGAERT, E.; BARTHOLOMÉ, E.; DEFOURNY, P. A. Near real-time water surface detection method based on HSV transformation of MODIS multi-spectral time series data. **Remote Sensing of Environment**, New York, v. 140, p. 704-716, 2014.
- PHAM, T. D.; BUI, D. T.; YOSHINO, K.; LE, N. N. Optimized rule-based logistic model tree algorithm for mapping mangrove species using ALOS – PALSAR imagery and GIS in the tropical region. **Environmental Earth Sciences**, Heidelberg, v. 77, n. 5, p. 01-13, 2018.
- TRENTIN, R.; ROBAINA, L. E. S. Study of the landforms of the ibicuí river basin with use of topographic position index. **Revista Brasileira de Geomorfologia**, São Paulo, v. 19, n. 2, p. 423-431, 2018.
- VAN DEN HOEK, J.; GETIRANA, A.; JUNG, H. C.; OKEOWO, M. A.; LEE, H. Monitoring reservoir drought dynamics with Landsat and radar/Lidar altimetry time series in persistently cloudy Eastern Brazil. **Remote Sensing**, Basel, v. 11, n. 827, p. 01-24, 2019.
- WANG, Y.; LIAO, M.; SUN, G.; GONG, J. Analysis of the water volume, length, total area and inundated area of the Three Gorges Reservoir, China using the SRTM DEM

data. **International Journal of Remote Sensing**, Basingstoke, v. 26, n. 18, p. 4001-4012, 2005.

WU, J.; YANG, Q.; LI, Y. Partitioning of terrain features based on roughness. **Remote Sensing**, Basel, v. 10, n. 12, p. 1985-2006, 2018.

YEOM, J. M.; JEONG, S.; DEO, R. C.; KO, J. Mapping rice area and yield in northeastern asia by incorporating a crop model with dense vegetation index profiles from a geostationary satellite. **GIScience & Remote Sensing**, London, v. 58, n 01, p. 1-27, 2021.

YOUNG, S.; PESCHEL, J.; PENNY, G.; THOMPSON, S.; SRINIVASAN, V. Robot-assisted measurement for hydrologic understanding in data sparse regions. **Water**, Basel, v. 9, n. 494, p. 01-20, 2017.