



Serviço Público Federal
Ministério da Educação
Fundação Universidade Federal de Mato Grosso do Sul
Faculdade de Engenharias, Arquitetura e Urbanismo e Geografia - FAENG



ELOIZA MARQUES

**MAPEAMENTO DE RESERVATÓRIOS DE BARRAGENS
COM INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO
REMOTO**

Campo Grande, MS.

2024

**UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
FACULDADE DE ENGENHARIAS E ARQUITETURA E URBANISMO E GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM TECNOLOGIAS AMBIENTAIS**

ELOIZA MARQUES

**MAPEAMENTO DE RESERVATÓRIOS DE BARRAGENS
COM INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO
REMOTO**

Dissertação apresentada ao Programa de Pós-graduação em
Tecnologias Ambientais da Universidade Federal do Mato
Grosso do Sul como requisito parcial a obtenção do título de
Mestre em Tecnologias Ambientais.

Orientador: Prof. Dr. José Marcato Junior

Banca Examinadora:

Prof. Dr. José Marcato Junior
Orientador PPGTA - UFMS

Prof. Dr^a. Ana Paula Marques Ramos
Instituição: UNESP

Prof. Dr. Wesley Nunes Gonçalves
Instituição: UFMS

**Campo Grande, MS.
2024**

AGRADECIMENTOS

Primeiramente, agradeço à Deus, que me concedeu saúde e perseverança para desenvolver este trabalho. Um agradecimento muito especial à minha mãe, que foi verdadeiramente maravilhosa; sempre pronta a fazer tudo que fosse necessário para que eu pudesse focar integralmente nos estudos. Seu apoio incondicional foi um pilar fundamental em minha jornada. A meu pai, agradeço por todo o amor e carinho, sempre me encorajando com suas palavras afetuosas e apoio constante, que foram fundamentais para mim.

À minha irmã Helena, agradeço por toda a admiração e o carinho mútuo que sempre compartilhamos; sua presença é uma fonte constante de alegria e inspiração. À minha irmã Isabella, *in memoriam*, que sempre foi uma luz radiante em minha vida. Ela foi a primeira a comemorar minha aprovação no mestrado e me viu iniciar esta jornada com alegria e orgulho. Embora não esteja fisicamente presente para testemunhar a sua conclusão, seu espírito e sua memória continuam a me inspirar e guiar a cada dia. Sua falta é profundamente sentida, e o amor que sinto por ela é eterno.

Gostaria de expressar minha imensa gratidão ao meu noivo, Fabio, cujo apoio foi uma verdadeira âncora para mim neste período. Sempre se desdobrando, com dedicação e amor, buscando garantir minha felicidade, mesmo nos momentos mais desafiadores. Sua presença e esforços têm sido uma fonte constante de conforto e motivação.

Um agradecimento especial ao Prof. Dr. José Marcato Junior, que aceitou generosamente ser meu orientador a partir do meio do mestrado e conduziu minha pesquisa com dedicação e excelência, tornando este caminho mais rico e produtivo. Agradeço também à Prof. Dr^a. Ana Paula Marques Ramos e ao Prof. Dr. Wesley Nunes Gonçalves, por aceitarem fazer parte da minha banca e contribuírem significativamente para o enriquecimento do meu trabalho.

Gostaria também de agradecer a Wanderson Junior, que foi fundamental em auxiliar minha pesquisa na área de tecnologia. Sua expertise nesse campo foi essencial para o desenvolvimento do meu projeto.

Um agradecimento sincero a Leonardo Sampaio Costa que, mesmo indiretamente, desempenhou um papel importante ao permitir que eu assistisse às aulas sempre que necessário, apoiando assim a minha jornada acadêmica.

Cada um de vocês teve um papel indispensável em minha formação, e sou eternamente grata por todo o apoio recebido.

SUMÁRIO

RESUMO	5
ABSTRACT	5
INTRODUÇÃO GERAL: RELAÇÃO ENTRE A CLASSIFICAÇÃO DE BARRAGENS E O MAPEAMENTO COM IA E SENSORIAMENTO REMOTO.....	6
CAPÍTULO 1: A SEGURANÇA DE BARRAGENS NO ESTADO DE MATO GROSSO DO SUL: UMA ANÁLISE QUANTO A CLASSIFICAÇÃO.....	8
1.1 INTRODUÇÃO	8
1.2 POLÍTICA NACIONAL DE SEGURANÇA DE BARRAGENS.....	9
1.2.1. Classificação de Barragens.....	9
1.2.2. Sistema Nacional de Segurança de Barragens (SNISB)	11
1.3 DIAGNÓSTICO DAS BARRAGENS CADASTRADAS NO SNISB.....	12
1.3.1. Dano Potencial Associado.....	12
1.3.2. Categoria de Risco	14
1.4 CONCLUSÃO	15
1.5 REFERÊNCIAS.....	17
CAPÍTULO 2: MAPEAMENTO DE RESERVATÓRIOS DE BARRAGENS COM INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO REMOTO.....	18
2.1 INTRODUÇÃO	18
2.2 MATERIAIS E MÉTODOS.....	20
2.2.1. Aquisição de imagens	20
2.2.2. Processamento de dados.....	23
2.2.3. Métodos de segmentação	24
2.2.4. Métricas de avaliação	24
2.3 RESULTADOS E DISCUSSÃO	25
2.4 CONCLUSÃO	29
2.5 REFERÊNCIAS.....	30
CONSIDERAÇÕES FINAIS.....	32
REFERÊNCIAS.....	33

RESUMO

A gestão de segurança de barragens é fundamental para a prevenção de desastres e a preservação dos recursos hídricos. No estado de Mato Grosso do Sul, o Instituto de Meio Ambiente de Mato Grosso do Sul (Imasul) desempenha um papel essencial na fiscalização dessas estruturas, seguindo as diretrizes da Política Nacional de Segurança de Barragens (PNSB) e utilizando o Sistema Nacional de Informações sobre Segurança de Barragens (SNISB) para o monitoramento e a classificação das barragens. Este estudo avalia a atuação do Imasul no contexto do SNISB e analisa a eficácia de modelos de segmentação de imagens, como o Segformer e o DeepLabV3+, para o mapeamento de reservatórios de barragens. A pesquisa compara os resultados dos dois modelos, destacando a superioridade do Segformer, que apresentou melhores métricas de desempenho, como precisão, sensibilidade e acurácia. Os achados revelam o potencial da inteligência artificial e do sensoriamento remoto no monitoramento ambiental, proporcionando ferramentas mais precisas para a gestão e segurança das barragens.

Palavras-chave: Segurança de barragens, Segmentação de imagens, Segformer, DeepLab, Inteligência artificial.

ABSTRACT

The management of dam safety is crucial for disaster prevention and the preservation of water resources. In the state of Mato Grosso do Sul, the Institute of Environment of Mato Grosso do Sul (Imasul) plays a key role in overseeing these structures, following the guidelines of the National Policy on Dam Safety (PNSB) and utilizing the National Information System on Dam Safety (SNISB) for the monitoring and classification of dams. This study evaluates Imasul's performance within the SNISB context and analyzes the effectiveness of image segmentation models, such as Segformer and DeepLabV3+, for mapping dam reservoirs.

The research compares the results of both models, highlighting the superiority of the Segformer, which showed better performance metrics, such as precision, sensitivity, and accuracy. The findings reveal the potential of artificial intelligence and remote sensing in environmental monitoring, providing more accurate tools for dam management and safety.

Keywords: Dam safety, Image segmentation, Segformer, DeepLab, Artificial intelligence.

INTRODUÇÃO GERAL: RELAÇÃO ENTRE A CLASSIFICAÇÃO DE BARRAGENS E O MAPEAMENTO COM IA E SENSORIAMENTO REMOTO

A segurança de barragens é uma questão crítica, especialmente em um cenário onde os impactos de falhas nessas estruturas podem levar a consequências catastróficas para comunidades e o meio ambiente. No Brasil, a Política Nacional de Segurança de Barragens (PNSB), instituída pela Lei nº 12.334/2010, estabelece diretrizes para o monitoramento e fiscalização dessas estruturas, enfatizando a necessidade de uma gestão eficaz. No entanto, a implementação desses procedimentos enfrenta desafios significativos, como a ausência de dados atualizados e precisos, além da dificuldade em integrar novas tecnologias na gestão e fiscalização das barragens. Essa lacuna é ainda mais evidente em estados como Mato Grosso do Sul, onde as iniciativas de fiscalização e monitoramento têm enfrentado limitações operacionais e metodológicas.

Diante desse contexto, o objetivo geral desta pesquisa é analisar a segurança de barragens no estado de Mato Grosso do Sul, abordando tanto os critérios regulatórios de classificação por Dano Potencial Associado (DPA) e Categoria de Risco (CRI) quanto as possibilidades de aprimoramento desse processo por meio de inteligência artificial e sensoriamento remoto. Os objetivos específicos incluem: (i) realizar uma análise da situação atual das barragens no estado, utilizando dados disponíveis no SNISB; (ii) avaliar o desempenho de modelos de segmentação baseados em deep learning, como Segformer e DeepLabV3+, para o mapeamento de reservatórios; e (iii) propor estratégias que integrem dados regulatórios e tecnologias emergentes para aprimorar o monitoramento e a gestão dessas estruturas.

A presente dissertação está estruturada em dois capítulos, cada um focado em diferentes aspectos da segurança de barragens. Ambos os capítulos adotam uma abordagem complementar, com o primeiro focando na análise regulatória e o segundo trazendo inovações tecnológicas para o aprimoramento da classificação dessas estruturas.

O primeiro capítulo apresenta uma análise detalhada da segurança das barragens em Mato Grosso do Sul, com foco na classificação dessas estruturas em relação aos Dano Potencial Associado (DPA) e Categoria de Risco (CRI). O objetivo é desenvolver uma compreensão clara

da situação atual das barragens utilizando dados disponíveis no Sistema Nacional de Informações sobre Segurança de Barragens (SNISB) e outras fontes regulatórias.

No segundo capítulo, o foco se volta para o uso de tecnologias como inteligência artificial e sensoriamento remoto para melhorar o mapeamento de barragens. Com o uso dessas ferramentas, podem-se obter dados mais detalhados e precisos sobre o reservatório e seu entorno, o que complementa diretamente a análise de classificação realizada no Capítulo 1. O uso dessas tecnologias tem o potencial de apoiar a fiscalização e o monitoramento contínuos, fornecendo dados que podem auxiliar as avaliações de DPA e CRI discutidas no primeiro artigo.

Portanto, os dois capítulos se complementam, pois enquanto o primeiro se concentra na análise de classificação das barragens com base nos dados existentes, o segundo introduz ferramentas que podem fornecer informações adicionais para melhorar a precisão e eficácia dessas classificações. A integração de inteligência artificial e sensoriamento remoto fortalece a gestão de barragens, promovendo uma abordagem moderna e eficaz de monitoramento e segurança.

CAPÍTULO 1: A SEGURANÇA DE BARRAGENS NO ESTADO DE MATO GROSSO DO SUL: UMA ANÁLISE QUANTO A CLASSIFICAÇÃO

1.1 Introdução

Barragens são estruturas construídas para modificar o fluxo natural de rios e córregos, criando reservatórios. Esses reservatórios desempenham diversas funções: o fornecimento de água, suportam sistemas de irrigação agrícola, geram energia hidrelétrica para o abastecimento de energia e são estratégicos na prevenção e controle de inundações, protegendo áreas habitadas e cultiváveis das devastadoras consequências das cheias (Marques, 2023).

Com o objetivo de assegurar a estabilidade estrutural das barragens e minimizar os riscos de acidentes, o governo brasileiro promulgou a Lei Nº 12.334, de 20 de setembro de 2010, estabelecendo um marco legal essencial para a regulação do setor de barragens no país. Essa legislação institui a Política Nacional de Segurança de Barragens (PNSB) e cria o Sistema Nacional de Informações sobre Segurança de Barragens (SNISB), delineando os princípios fundamentais, objetivos, critérios e ferramentas para a gestão segura das barragens. Adicionalmente, define as responsabilidades e deveres de cada entidade envolvida na segurança dessas estruturas (Brasil, 2010).

Para assegurar a implementação efetiva da PNSB em Mato Grosso do Sul, o Instituto de Meio Ambiente de Mato Grosso do Sul (Imasul), uma autarquia ligada à Secretaria de Meio Ambiente, Desenvolvimento, Ciência, Tecnologia e Inovação (Semadesc), coordena ações integradas que fortalecem a segurança das barragens (Imasul, 2024). Conforme a Lei 12.334/2010, o Imasul, órgão responsável pela outorga do uso dos recursos hídricos, também tem a atribuição de fiscalizar a segurança de barragens em corpos hídricos destinados à acumulação de água, exceto para fins de aproveitamento hidrelétrico (Brasil, 2010).

A crescente preocupação com a segurança das barragens, intensificada pelos grandes impactos sociais e ambientais visíveis em desastres como Mariana e Brumadinho, levou à promulgação da Lei n. 14.066, de 30 de setembro de 2020. Esta lei modificou a Lei n. 12.334/2010, reforçando as medidas regulatórias para a segurança de barragens.

Como resposta às necessidades normativas, o Imasul emitiu a Resolução Semagro n. 757, de 03 de agosto de 2021. Esta resolução define procedimentos e critérios adicionais para a classificação de barragens e estabelece a periodicidade das atualizações, a qualificação dos técnicos responsáveis, e o nível de detalhamento exigido para o Plano de Segurança da

Barragem, Inspeções de Segurança Regular e Especial, Revisão Periódica de Segurança de Barragem, e o Plano de Ação de Emergência para barragens fiscalizadas pelo Imasul.

Este capítulo objetiva apresentar uma análise da situação atual das barragens em Mato Grosso do Sul, destacando a metodologia do Imasul na gestão de sua segurança. A abordagem inclui uma avaliação das práticas de classificação das barragens e uma investigação sobre a condição atual de segurança, utilizando dados da plataforma digital do SNISB.

1.2 Política Nacional de Segurança de Barragens

A Política Nacional de Segurança de Barragens (PNSB) é definida pela Lei n. 12.334/2010, e foi alterada pela Lei n. 14.066/2020. O principal objetivo da PNSB é promover a prevenção e mitigação de desastres, assegurando a conformidade com os padrões de segurança estabelecidos para barragens (Brasil, 2024).

1.2.1. Classificação de Barragens

No contexto da PNSB, a legislação estabelece um sistema de classificação para barragens. Os agentes fiscalizadores classificam essas estruturas segundo três critérios principais: Categoria de Risco (CRI), Dano Potencial Associado (DPA) e volume, conforme as diretrizes do Conselho Nacional de Recursos Hídricos (CNRH). Os critérios específicos são definidos como segue:

“§ 1º A classificação por categoria de risco em alto, médio ou baixo será feita em função das características técnicas, dos métodos construtivos, do estado de conservação e da idade do empreendimento e do atendimento ao Plano de Segurança da Barragem, bem como de outros critérios definidos pelo órgão fiscalizador.

§ 2º A classificação por categoria de dano potencial associado à barragem em alto, médio ou baixo será feita em função do potencial de perdas de vidas humanas e dos impactos econômicos, sociais e ambientais decorrentes da ruptura da barragem”. (Lei 12.334/2010, Art. 7º)

Complementando essa estrutura, a Resolução CNRH nº 143, de 10 de julho de 2012, estabelece os critérios gerais para a classificação de barragens. Esses critérios estão detalhados no Quadro 1 e são baseados nos anexos da referida Resolução.

Os procedimentos e prazos para o cumprimento desses critérios são definidos pelos órgãos fiscalizadores, como previsto na Resolução Semagro n. 757/2021. Essa Resolução complementa a Resolução CNRH n. 143/2012 ao adicionar novos critérios, especificamente sobre Impacto Ambiental e Impacto Socioeconômico.

Quadro 1 – Detalhamento dos critérios de classificação

Critério	Detalhes
<p>Categoria de risco (CRI)</p>	<p>Conforme o Art. 4º da Resolução CNRH n. 143/2012, as barragens são classificadas com base em aspectos técnicos que podem influenciar a possibilidade de acidentes. São considerados:</p> <p>I - Características técnicas: altura, comprimento, tipo de barragem quanto ao material de construção, tipo de fundação, idade da barragem e vazão de projeto.</p> <p>II - Estado de conservação: confiabilidade das estruturas extravasoras, confiabilidade das estruturas de adução, percolação, deformações e recalques, deterioração dos taludes e eclusa.</p> <p>III - Plano de Segurança da Barragem.</p>
<p>Dano Potencial Associado (DPA)</p>	<p>De acordo com o Art. 5º da Resolução CNRH n. 143/2012, os critérios para classificação de DPA levam em conta o impacto que a barragem pode causar na área afetada. Os fatores são:</p> <p>I - Volume Total do Reservatório;</p> <p>II - Potencial de perdas de vidas humanas;</p> <p>III - Impacto ambiental;</p> <p>IV - Impacto socioeconômico.</p> <p>Conforme Art. 4º da Resolução Semagro n. 757/2021, o Imasul definiu critérios complementares referentes ao Impacto Ambiental e ao Impacto Socioeconômico.</p>
<p>Volume</p>	<p>Conforme o Art. 7º, as barragens são classificadas pelo volume do reservatório:</p> <p>I - Pequena: até 5 milhões de metros cúbicos;</p> <p>II - Média: entre 5 e 75 milhões de metros cúbicos;</p> <p>III - Grande: entre 75 e 200 milhões de metros cúbicos;</p> <p>IV - Muito grande: mais de 200 milhões de metros cúbicos.</p>

Fonte: Adaptado de Resolução CNRH n. 143/2012 (Brasil, 2012) e na Resolução Semagro n. 757/2021 (Semagro, 2021).

Complementando a classificação estabelecida pela PNSB e suas diretrizes, a Resolução Semagro n. 757/2021, aplicada pelo Imasul, apresenta uma metodologia própria para classificação quanto ao DPA. Essa metodologia permite que, com base em critérios específicos, certas barragens se enquadrem diretamente como de DPA baixo.

De acordo com o Art. 5º da Resolução, barragens com altura do maciço menor ou igual a 2 metros e capacidade total do reservatório inferior ou igual a 10.000 m³ são classificadas

como de DPA baixo. Com essa classificação, essas barragens são dispensadas das exigências da PNSB.


1.2.2. Sistema Nacional de Segurança de Barragens (SNISB)

O SNISB, um instrumento da PNSB, é responsável pela coleta, tratamento, armazenamento e recuperação de informações sobre barragens. Este sistema compreende dados de barragens em várias fases, incluindo as que estão em construção, em operação e desativadas.

Considerando o Artigo 16, Inciso I, da legislação de segurança de barragens, que obriga os órgãos fiscalizadores a manter um cadastro atualizado das barragens em sua área de atuação — incluindo a identificação dos empreendedores para integração ao SNISB —, o Imasul realiza esse cadastro por meio do instrumento de outorga. Este documento contém informações essenciais como o nome do empreendedor, CPF ou CNPJ, e a localização da barragem, servindo como um importante meio de identificação dos responsáveis pelas estruturas.

O Estado de Mato Grosso do Sul possui 2.205 barragens cadastradas, das quais mais de 90% são fiscalizadas pelo Imasul. A Figura 1 apresenta o gráfico com a distribuição percentual dessas barragens e seus respectivos órgãos fiscalizadores. Essa distribuição demonstra como a fiscalização se divide entre os órgãos federais e estaduais, com uma clara predominância do Imasul.

Figura 1 – Gráfico da distribuição percentual de barragens e órgãos fiscalizadores em MS



Fonte: Elaborada pela autora, 2024.

A Agência Nacional de Águas e Saneamento Básico (ANA) fiscaliza 6% das barragens no estado. Em menor escala, a Agência Nacional de Energia Elétrica (ANEEL) e a Agência Nacional de Mineração (ANM) são responsáveis por 2% e 1%, respectivamente. A maior parte, representando 91% das barragens, é supervisionada pelo Imasul, que exerce o papel mais significativo no monitoramento dessas estruturas, reforçando a importância do órgão estadual na gestão de barragens em Mato Grosso do Sul.


1.3 Diagnóstico das barragens cadastradas no SNISB

A análise da condição atual de segurança das barragens no Estado de Mato Grosso do Sul, utilizando os dados extraídos¹ da plataforma digital do SNISB, será focada exclusivamente nas barragens fiscalizadas pelo Imasul. O objetivo é verificar como está a classificação dessas barragens em termos de DPA e CRI, de forma a entender melhor a situação atual dessas estruturas no que tange à PNSB.

1.3.1. Dano Potencial Associado

O Imasul já classificou 1.192 barragens quanto ao DPA, conforme demonstrado no gráfico apresentado na Figura 2, que exibe a distribuição percentual dos diferentes níveis dessa classificação.

Figura 2 – Gráfico da classificação quanto ao DPA



Fonte: Elaborada pela autora, 2024.

¹ Os dados utilizados nesta análise foram extraídos em 04/09/2024, às 18:32:12, através do link <https://www.snisb.gov.br/portal-snisb/consultar-barragem>.

Um total de 40,87% das barragens ainda não foi classificada quanto ao DPA. Esse percentual significativo de barragens sem classificação representa uma lacuna importante na gestão da segurança dessas estruturas, evidenciando a necessidade de mais avaliações e monitoramento.

Apenas 1,19% das barragens estão classificadas com DPA alto, indicando que essas barragens apresentam o maior risco em termos de potenciais danos, e 0,94% possuem DPA médio, o que exige um nível de atenção intermediário.

Em contraste, a maior parte das barragens, representando 57,94%, está classificada como de DPA baixo. Essa quantidade elevada pode ser relacionada a características técnicas, como altura e volume do reservatório. A predominância de barragens de baixo potencial de dano também pode estar vinculada ao processo de classificação que permite que algumas barragens, com base em critérios específicos, sejam diretamente enquadradas nessa categoria, conforme detalhado anteriormente; e conforme evidenciado no Quadro 2, que demonstra o relacionamento de entre as alturas e volumes das barragens classificadas quanto ao DPA.

Quadro 2 – Cruzamento da altura e volume das barragens classificadas quanto ao DPA

Altura \ Volume	Volume		Total
	$\leq 10.000 \text{ m}^3$	$> 10.000 \text{ m}^3$	
≤ 2 metros	623	470	1093
> 2 metros	4	95	99
Total	627	565	1192

Fonte: Elaborada pela autora, 2024.

A maior parte das barragens, 1.093 no total, possui altura menor ou igual a 2 metros. Dessas, 623 barragens têm volume de até 10.000 m^3 , enquanto 470 possuem volume superior a 10.000 m^3 . Esse número elevado de barragens com altura ≤ 2 metros e volume $\leq 10.000 \text{ m}^3$ reflete a predominância de pequenas barragens no Estado, que podem representar um menor risco individual, mas que, em conjunto, podem demandar atenção.


Entre as barragens mais altas (com altura > 2 metros), apenas 99 foram registradas. Dessas, 4 possuem volume $\leq 10.000 \text{ m}^3$, e 95 barragens têm volume superior a 10.000 m^3 . Isso indica que as barragens mais altas tendem a ter volumes maiores, o que pode implicar em um maior DPA.

1.3.2. Categoria de Risco

Em relação à CRI, o Imasul classificou 1.192 barragens. Ao relacionar esses dados, verificou-se que as mesmas barragens também já tiveram o DPA classificado. Isso mostra uma uniformidade no processo de avaliação, indicando que todas as barragens com classificação de CRI também foram avaliadas quanto ao seu potencial de dano.

A Figura 3 apresenta a distribuição percentual dos diferentes níveis de classificação em relação à CRI.

Figura 3 – Gráfico da classificação quanto à CRI



Fonte: Elaborada pela autora, 2024.

O gráfico apresentado ilustra a distribuição percentual das barragens em relação à CRI. Verifica-se que 40,87% das barragens ainda não foram classificadas, evidenciando que uma parte significativa das estruturas não passou por avaliação de risco técnico. Além disso, apenas 1,24% das barragens foram classificadas como CRI alto, médio ou baixo.

Adicionalmente, 57,89% das barragens são classificadas como "não se aplica", uma vez que, devido ao enquadramento dessas estruturas no DPA baixo, elas não estão submetidas às exigências da PNSB e, portanto, não requerem a classificação de CRI.

1.4 Conclusão

Com base na análise apresentada sobre a PNSB e o sistema de classificação de barragens segundo o DPA e a CRI, podemos concluir que a PNSB estabelece uma estrutura sólida e rigorosa para a gestão da segurança de barragens no estado de Mato Grosso do Sul. A legislação em vigor, complementada por resoluções específicas, como a Resolução CNRH n. 143/2012 e a Resolução Semagro n. 757/2021, define critérios detalhados que permitem uma avaliação técnica das barragens, levando em consideração aspectos como volume, altura, estado de conservação, e o potencial impacto ambiental, social e econômico de uma possível falha.

A análise das barragens no estado de Mato Grosso do Sul revelou aspectos importantes relacionados à gestão de segurança dessas estruturas, de acordo com a PNSB. O Imasul, como órgão fiscalizador de Mato Grosso do Sul, desempenha um papel essencial na implementação dessas diretrizes, sendo responsável pela supervisão de mais de 90% das barragens do estado. Isso é especialmente relevante no caso das barragens de menor porte, classificadas como de DPA baixo, que, embora possam representar um menor risco individualmente, em conjunto demandam uma atenção contínua das autoridades fiscalizadoras. O fato de a maior parte dessas barragens estar isenta da classificação quanto ao CRI, devido ao enquadramento em DPA baixo, reforça a importância de um monitoramento eficaz para garantir a conformidade com os padrões de segurança estabelecidos. Além disso, o cruzamento de dados sobre altura e volume das barragens sugere que as estruturas maiores tendem a apresentar volumes mais elevados. Isso pode representar um risco mais significativo e, portanto, exigir uma fiscalização ainda mais rigorosa. No entanto, a análise também revela que uma parte significativa das barragens ainda não foi classificada. Esse fato aponta para desafios operacionais e a complexidade do processo de fiscalização, evidenciando a necessidade de maior agilidade no processo de avaliação.

Por fim, a uniformidade no processo de avaliação, conforme evidenciado pela correlação entre a classificação de DPA e CRI, demonstra o esforço contínuo do Imasul em garantir a segurança das barragens no estado de Mato Grosso do Sul, mas também aponta para a necessidade de modernização e otimização do processo, especialmente na implementação de tecnologias que possam automatizar e acelerar a classificação dessas estruturas.

Conclui-se, assim, que, embora os avanços na gestão da segurança de barragens sejam evidentes, ainda há pontos que necessitam de atenção, sobretudo no que se refere à necessidade de modernização e agilidade nos processos de fiscalização e classificação. A continuidade das

ações regulatórias, aliada à adoção de novas metodologias e tecnologias, poderá assegurar uma gestão mais eficaz da segurança das barragens no Estado de Mato Grosso do Sul.

1.5 Referências

Brasil. (2010). Lei n. 12.334, de 20 de setembro de 2010. Diário Oficial da União, 21 set 2010, p. 1. Disponível em: <https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2010/lei/112334.htm>. Acesso em: 2 set. 2024.

Brasil. *Relatório de Segurança de Barragens 2023*. Agência Nacional de Águas e Saneamento Básico. Brasília: ANA, 2024. Disponível em: <https://www.snisb.gov.br/portal-snisb/api/file/download/714/4/rsb_2023_2024_06_27_11_01_28.pdf>. Acesso em: 4 set. 2024.

Brasil. (2024) *Sistema Nacional de Informações sobre Segurança de Barragens (SNISB)*. Agência Nacional de Águas e Saneamento Básico. Brasília: ANA, 2024. Disponível em: <<https://www.snisb.gov.br/portal-snisb/inicio>>. Acesso em: 3 set. 2024.

CNRH. (2012). Resolução CNRH n. 143, de 10 de julho de 2012. Diário Oficial da União, 04 set 2012, Seção 1, p. 149, .

IMASUL. *Segurança de Barragem*. Instituto de Meio Ambiente de Mato Grosso do Sul. Campo Grande: Imasul, 2024. Disponível em: <<https://www.imasul.ms.gov.br/seguranca-de-barragem-2/>>. Acesso em: 4 abr. 2023.

Marques, E. (2023). *Segurança em barragens de terra: orientações gerais e práticas recomendadas*. Curitiba: Appris.

Petry, A., Laus, F., Anderáos, A. & Bomfim, M. (2018). *Classificação de barragens quanto ao Dano Potencial Associado: a experiência da Agência Nacional de Águas*. Foz do Iguaçu.

SEMAGRO. (2021) *Resolução Semagro n. 757, de 03 de agosto de 2021*. Diário Oficial do Estado de Mato Grosso do Sul, 04 ago. 2021, p. 22-32.

CAPÍTULO 2: MAPEAMENTO DE RESERVATÓRIOS DE BARRAGENS COM INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO REMOTO

2.1 Introdução

A água é essencial para a sustentabilidade e o desenvolvimento das sociedades, desempenhando um papel crítico em atividades econômicas e na subsistência humana (Rolo *et al.*, 2022). No contexto da engenharia civil e dos recursos hídricos, barragens são construídas para controlar o fluxo de água, criando reservatórios que são fundamentais para o abastecimento, irrigação, produção de energia hidrelétrica e controle de enchentes (Marques, 2023).

O desenvolvimento e a expansão de barragens exigem uma avaliação equilibrada dos impactos ambientais, sociais e econômicos, bem como um monitoramento eficaz para garantir a segurança das estruturas (Marques, 2023). Conforme a Lei n. 12.334, de 20 de setembro de 2010, a qual estabelece a Política Nacional de Segurança de Barragens, os agentes fiscalizadores devem classificar as barragens quanto ao Dano Potencial Associado (DPA) com base em critérios gerais estabelecidos pelo Conselho Nacional de Recursos Hídricos (CNRH). (Brasil, 2010).

De acordo com o CNRH (2012), os critérios de classificação de barragens em relação ao DPA consideram a extensão do impacto, abrangendo as áreas a jusante e a montante que poderiam ser afetadas em caso de ruptura da barragem. Esses critérios são fundamentais para a avaliação do potencial de risco e para a definição de prioridades na inspeção e manutenção das estruturas.

A classificação de barragens quanto ao Dano Potencial Associado (DPA) é um processo complexo e desafiador, que exige a avaliação de várias características, como a altura da barragem, o volume do reservatório e o tipo de fundação. Esse processo é ainda mais complicado devido à influência de fatores externos, como mudanças climáticas e atividades sísmicas (Salgado & Silva Carvalho, 2023). Além disso, a tarefa se torna mais desafiadora para os órgãos fiscalizadores devido à subjetividade na interpretação dos dados e à avaliação do risco pelos especialistas envolvidos (Rolo *et al.*, 2022).

Essa complexidade é agravada pela carência de dados de alta qualidade, tanto em relação ao relevo quanto ao projeto das barragens. A ausência desses dados impossibilita a

condução de simulações confiáveis de rompimento de barragem, o que, por sua vez, dificulta a avaliação da área potencialmente afetada e a consequente classificação em relação ao DPA (Petry *et al.*, 2018).

A identificação e monitoramento de barragens é importante para a gestão de recursos hídricos e a prevenção de desastres naturais. Uma abordagem integrada que combina classificação baseada em objetos e rede neural convolucional profunda podem melhorar a precisão da detecção de barragens em imagens de sensoriamento remoto (Li *et al.*, 2021).

Band *et al.* (2022) utilizam algoritmos de inteligência computacional e dados do satélite Landsat-8 com auxílio de um modelo digital de elevação (DEM) com resolução de pixel de 5 metros, para otimizar a localização de barragens de contenção de água, visando controlar a sedimentação e o escoamento em uma bacia hidrográfica.

Li *et al.* (2023) propõem uma metodologia que visa a identificação de sistemas de barragens de contenção por meio da análise das considerações hidrológicas e de imagens de sensoriamento remoto provenientes do Google Earth com uma resolução de solo de 0,54 m. O estudo visa melhorar a eficiência da detecção de barragens em larga escala geográfica, especialmente nas áreas onde barragens são cobertas por vegetação.

No trabalho recente de Sun *et al.* (2023) a equipe visa desenvolver ferramentas que empregam aprendizado profundo e análise geoespacial para a detecção de barragens de contenção, utilizando imagens de alta resolução provenientes do satélite GF-2, com resolução de 1,0 m na banda pancromática e 4,0 m na banda multiespectral (espectro azul, verde, vermelho e infravermelho próximo).


Complementando este esforço, Sun *et al.* (2023b) conduzem uma avaliação criteriosa de diversos algoritmos de aprendizado profundo, com o objetivo de otimizar a extração de áreas de barragens e analisar a influência da combinação de dados entre imagens de sensoriamento remoto obtidas a partir do satélite GF-2, com resolução espacial de 0,8 metros e Modelos Digitais de Elevação (MDE) adaptados para ter a mesma resolução espacial das imagens GF-2.

Nesse contexto, este trabalho propõe a utilização de modelos de inteligência artificial, especificamente o Segformer e o DeepLabV3+, aplicados a imagens de sensoriamento remoto para o mapeamento de reservatórios de barragens no estado de Mato Grosso do Sul. Em contraste com estudos anteriores, que se concentraram em áreas geográficas mais amplas ou em metodologias tradicionais, esta pesquisa foca no desenvolvimento e na aplicação de tecnologias para a identificação dessas estruturas em um cenário regional. Esse avanço promove a inovação e o desenvolvimento contínuo não apenas no monitoramento das barragens, mas também ao fornecer subsídios técnicos para uma gestão mais eficaz dos recursos hídricos.

2.2 Materiais e métodos

O fluxo de trabalho foi composto por quatro etapas, conforme Figura 1: (1) aquisição de imagens; (2) processamento de dados, onde as imagens foram anotadas (rotuladas) e divididas em subconjuntos de treinamento e teste; (3) aplicação dos métodos de segmentação; e (4) avaliação dos resultados, onde o desempenho dos métodos de segmentação foram analisados e comparados.

Figura 4 – Fluxo de trabalho resumindo as etapas da abordagem realizada



Fonte: Elaborada pela autora, 2024.

2.2.1. Aquisição de imagens


2.2.1.1. Área de Estudo

De acordo com o Instituto Brasileiro de Geografia e Estatística - IBGE (2022), o Mato Grosso do Sul, situado no centro-oeste do Brasil, possui uma área territorial de cerca de 357.000 km². Até a data de início desta pesquisa, existem 1900 barragens de terra regularizadas no estado. Destas, 130 se destacam ao possuírem uma capacidade de acumulação que alcança ou supera a marca 100.000 m³, representando uma parcela de 6,8% em relação ao total (IMASUL, 2023).

Para a realização desta pesquisa, foram selecionadas 60 dentre as 130 barragens que possuem significativo volume acumulado, conforme demonstrado na Figura 2. Esta escolha recaiu sobre aquelas que não possuem classificação quanto ao DPA e, portanto, essa pesquisa visa auxiliar a produção de dados para a classificação das barragens que requerem essa

avaliação. O IMASUL desempenhou um papel fundamental ao prover informações essenciais sobre essas barragens, como coordenadas de entrada e de eixo, capacidade de acumulação de água e altura correspondente.

Figura 5 – Localização das 60 barragens no estado de Mato Grosso do Sul



Fonte: Elaborada pela autora, 2024.


2.2.1.2. Amostragem

As imagens utilizadas no presente estudo são do Google Earth Pro. Essas imagens foram acessadas via Terra Incógnita, um software que permite o download de imagens georreferenciadas em diferentes resoluções espaciais, incluindo a nível centimétrico, de acordo com o nível de zoom desejado. Isso resulta em imagens de alta resolução, adequadas para diversas finalidades. Para o estudo de caso, definiu-se o nível de zoom de 5 metros, o que resulta em uma resolução de pixel de 30 centímetros. Essa escala proporciona uma resolução suficiente para as análises dos entornos dos reservatórios.

Ao considerar as coordenadas das barragens selecionadas, procedeu-se com um recorte que inclui não apenas o reservatório de água, mas também uma área circundante que apresenta características relevantes para a análise dessa pesquisa, conforme evidenciado na Figura 3. Embora não tenha sido definida uma metragem específica para a área circundante, a seleção foi

feita com base em uma análise visual, buscando incluir elementos geográficos e ambientais essenciais para a avaliação detalhada do entorno das barragens.

Figura 6 – Representação de algumas barragens e suas áreas adjacentes (sem escala)



Fonte: Elaborada pela autora, 2024.


As imagens de satélite utilizadas neste estudo possuem datas variadas para cada barragem, em decorrência da disponibilidade de dados. Apesar disso, os resultados permanecem consistentes e adequados ao objetivo da análise, que foca nos aspectos estruturais e geoespaciais relevantes para o estudo.

2.2.2. Processamento de dados

2.2.2.1. Anotação

Anotou-se manualmente os reservatórios de cada barragem, conforme ilustrado na Figura 4. A área correspondente aos reservatórios foi delimitada e rotulada, sendo o restante considerado como fundo. Esse processo foi realizado por meio do software QGIS, utilizando-se as ferramentas de vetorização.

Figura 7 – Anotação e rotulagem de imagens (sem escala)



Fonte: Elaborada pela autora, 2024.


Cada imagem analisada abrange uma área distinta, refletindo características únicas de cada barragem e de seu entorno. Essa especificidade exige que o procedimento de análise seja adaptado para cada caso, considerando as particularidades geográficas e visuais presentes em cada imagem, como variações no tamanho, formato e composição do reservatório.

A presença de diferentes tipos de vegetação, variações topográficas e a influência de sombras criadas pela infraestrutura e relevo local contribuem para que a análise dos elementos seja distinta e complexa. Além disso, o reflexo do sol na água no momento da captura da imagem pelo satélite também interferiu, adicionando um desafio adicional para a anotação precisa das áreas de interesse.

2.2.2.2. Divisão dos dados

Conforme demonstrado na Figura 5, das 60 barragens selecionadas para o estudo, 34 foram utilizadas na etapa de treino, onde o algoritmo foi ajustado para identificar o elemento de interesse nas imagens. As outras 26 barragens foram reservadas para a etapa de teste, permitindo que o modelo fosse testado em novos dados não vistos anteriormente.

Figura 8 - Distribuição das barragens entre as etapas de segmentação e teste



Fonte: Elaborada pela autora, 2024.

2.2.3. Métodos de segmentação

Os algoritmos utilizados para o treinamento foram arquiteturas de redes neurais projetadas para segmentação semântica de imagens, como o DeepLabV3+ e o Segformer. O dataset empregado no processo de segmentação consistiu em 2111 imagens, recortadas em dimensões de 512x512 pixels.

O DeepLab é um método de segmentação semântica de imagens que utiliza redes neurais convolucionais profundas e técnicas de processamento de imagem para segmentar objetos em imagens. O DeepLabV3+ é uma nova versão que apresenta várias melhorias em relação à sua primeira versão, incluindo a capacidade de segmentar objetos em múltiplas escalas, através do processamento de entrada em múltiplas escalas (Chen et al., 2016).

O SegFormer utiliza uma arquitetura baseada em Transformers, que são mecanismos baseados em atenção e são compostos por uma série de camadas que se comunicam entre si para aprender representações complexas de dados de entrada. Os Transformers se tornaram populares em tarefas de processamento de linguagem natural e, mais recentemente, têm sido aplicados com sucesso em tarefas de visão computacional (Xie et al., 2021).

2.2.4. Métricas de avaliação

Uma matriz de confusão foi gerada para realizar o processo de avaliação do desempenho de cada modelo. Essa matriz fornece detalhes sobre as amostras que foram

corretamente identificadas e aquelas que sofreram classificação equivocada em relação aos dados de referência. Utilizando a matriz de confusão, é possível calcular métricas como sensibilidade/recall, precisão, acurácia e a pontuação F1, que são importantes para avaliar o desempenho do modelo de classificação.

A sensibilidade (Equação 1) quantifica a proporção de casos positivos que foram corretamente identificados pelo modelo. A precisão (Equação 2) mede a quantidade de verdadeiros positivos em relação ao total de predições positivas feitas. A acurácia (Equação 3) representa a capacidade global do modelo em acertar suas previsões. Por fim, a Pontuação F1/F-score (Equação 4) é a média harmônica entre a precisão e a sensibilidade. As equações que representam cada uma dessas métricas encontram-se abaixo:

$$\text{Sensibilidade} = \frac{VP}{(VP+FN)} \quad (1)$$

$$\text{Precisão} = \frac{VP}{(VP+FP)} \quad (2)$$

$$\text{Acurácia} = \frac{(VP+VN)}{(VP+VN+FP+FN)} \quad (3)$$

$$\text{Pontuação F1} = 2 \times \frac{\text{precisão} \times \text{sensibilidade}}{(\text{precisão} + \text{sensibilidade})} \quad (4)$$


Além das métricas mencionadas acima, a qualidade dos resultados alcançados com as técnicas de segmentação semântica, também, pode ser avaliada usando a métrica IoU (Intersection over Union) (Equação 5). Essa representa a razão entre a área de interseção e a área de união das máscaras de segmentação, de referência (*ground truth*) e preditas pelo modelo, conforme demonstrado na fórmula a seguir.

$$\text{IoU} = \frac{|\text{reais} \cap \text{previstas}|}{|\text{reais} \cup \text{previstas}|} \quad (5)$$

2.3 Resultados e discussão

Esta seção apresenta os resultados quantitativos e qualitativos da segmentação dos reservatórios em barragens utilizando o Segformer e o DeepLabV3+.. A Tabela 1 apresenta os resultados das métricas avaliadas para ambos os métodos de segmentação.

Figura 9 – Gráfico dos resultados das métricas de avaliação, em porcentagem




Método	IoU	Sensibilidade	Precisão	Acurácia	Pontuação F1
Segformer	88,36	89,91	98,09	89,91	93,82
DeepLabV3+	40,68	46,81	75,66	46,81	57,84

Fonte: Elaborada pela autora, 2024.

Na validação da classificação das imagens pelo método Segformer, o número de pixels do reservatório corretamente classificados, refletindo a sensibilidade do modelo, foi de 89,91%. O número de predições positivas corretamente classificadas, representando a precisão do modelo, foi de 98,09%. Obteve-se uma acurácia de 89,91% e uma pontuação F1 de 93,82%. Além disso, o Segformer alcançou um IoU de 88,36%, que quantifica a sobreposição entre a segmentação predita e a segmentação real. Para o DeepLabV3+, os resultados obtidos foram os seguintes: 40,68% de IoU, 46,81% de sensibilidade/recall, 75,66% de precisão, 46,81% de acurácia e 57,84% de pontuação F1. O baixo valor de recall para o DeepLabV3+ mostra que o modelo tem uma taxa de falsos negativos alta, ou seja, está deixando de mapear muitas áreas de reservatórios. Nota-se a discrepância entre os resultados do Segformer em relação ao DeepLab v3+. Os modelos baseados na arquitetura Transformer superaram os algoritmos convolucionais em termos de IoU, precisão, acurácia, recall e F-score.

A Figura 6 apresenta os resultados da segmentação obtidos pelos métodos aplicados, permitindo uma análise qualitativa comparativa dos resultados. Na imagem apresentada, as figuras superiores representam as imagens iniciais, que foram inseridas no modelo para teste.

As áreas em branco correspondem ao resultado da segmentação obtido pelo método Segformer, enquanto as áreas em laranja refletem o resultado da segmentação gerada pelo método DeepLabV3+.



Fonte: Elaborada pela autora, 2024.

Os exemplos demonstram uma visualização clara das diferenças no desempenho dos dois métodos, com o Segformer claramente mostrando uma segmentação mais precisa e alinhada com a realidade do reservatório. Na imagem (9a) é possível perceber que o modelo Segformer capturou de maneira mais eficaz os contornos e limites do reservatório, mesmo que a segmentação não tenha sido completamente precisa. Por outro lado, o método DeepLabV3+ apresentou falhas perceptíveis na segmentação, especialmente na imagem (a), onde o modelo falhou em capturar corretamente a extensão completa do reservatório. Na imagem (b), o DeepLabV3+ conseguiu identificar parte do reservatório, mas novamente com uma área segmentada menor em comparação ao Segformer, refletindo a precisão de 75,66% observada nos dados quantitativos.

Na imagem (c), o DeepLabV3+ teve um desempenho inferior, identificando erroneamente a borda direita da imagem como parte do reservatório, provavelmente devido à similaridade de coloração entre a cor da água do reservatório no momento de captura da imagem

e a borda da imagem. Embora tenha conseguido segmentar parte do reservatório, os resultados são menos precisos em comparação ao Segformer, que capturou os limites de forma mais consistente.

Embora o uso do Segformer tenha demonstrado alta eficiência na segmentação de reservatórios, fatores como a qualidade geométrica das imagens de satélite e a variabilidade em diferentes datas representam desafios importantes para a generalização dos resultados. A resolução espacial e o alinhamento das imagens são elementos críticos para garantir a consistência no monitoramento contínuo, especialmente quando se utiliza imagens do Google Earth, cuja qualidade pode variar de acordo com a localização geográfica. Essas limitações ressaltam a necessidade de considerar a adequação das fontes de dados ao aplicar os modelos em contextos práticos e em diferentes escalas temporais e espaciais.

2.4 Conclusão

Os resultados apresentados evidenciam que o modelo Segformer foi eficaz na tarefa de mapeamento de reservatórios de barragens utilizando imagens de sensoriamento remoto. As métricas quantitativas demonstraram sua superioridade na tarefa em comparação, ao DeepLabV3+.

A análise qualitativa das imagens segmentadas confirma que o Segformer foi capaz de capturar de forma mais precisa os contornos dos reservatórios, mesmo em cenários complexos, enquanto o DeepLabV3+ teve dificuldades, especialmente na delimitação correta das áreas de interesse. Esses resultados mostram o potencial das arquiteturas baseadas em Transformers para tarefas de segmentação em imagens de satélite, oferecendo uma alternativa mais robusta em comparação aos métodos convencionais.

Para futuras pesquisas, recomenda-se ampliar o escopo das análises, incorporando outras infraestruturas no processo de segmentação, como estradas e edificações, o que pode aumentar a aplicabilidade dos modelos em diferentes contextos geográficos. Essa abordagem pode ampliar o uso dos modelos em diversos cenários de monitoramento ambiental e segurança de barragens, tornando-os ainda mais eficazes na gestão dessas estruturas.

2.5 Referências

Band, S.S., Chandra Pal, S., Bateni, S.M., Jun, C., Saha, A., Chowdhuri, I., Tiefenbacher, J.P. & Janizadeh, S. (2022). Using computational-intelligence algorithms and remote sensing data to optimize the locations of check dams to control sediment and runoff in Kandolus watershed, Mazandaran, Iran. *Geocarto International* Taylor and Francis Ltd. 37, 12966–12988.

Brasil. (2010). Lei n. 12.334, de 20 de setembro de 2010. Diário Oficial da União, 21 set 2010, p. 1. Disponível em: <https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2010/lei/112334.htm>. Acesso em: 2 set. 2024.

CNRH. (2012). Resolução CNRH n. 143, de 10 de julho de 2012. Diário Oficial da União, 04 set 2012, Seção 1, p. 149, .

Li, M., Dai, W., Fan, M., Qian, W., Yang, X., Tao, Y. & Zhao, C. (2023). Combining Deep Learning and Hydrological Analysis for Identifying Check Dam Systems from Remote Sensing Images and DEMs in the Yellow River Basin. *International Journal of Environmental Research and Public Health* MDPI 20,.

Li, S., Xiong, L., Hu, G., Dang, W., Tang, G. & Strobl, J. (2021). Extracting check dam areas from high-resolution imagery based on the integration of object-based image analysis and deep learning. *Land Degradation and Development* John Wiley and Sons Ltd 32, 2303–2317.

Marques, E. (2023). *Segurança em barragens de terra: orientações gerais e práticas recomendadas*. Curitiba: Appris.

Petry, A., Laus, F., Anderáos, A. & Bomfim, M. (2018). *Classificação de barragens quanto ao Dano Potencial Associado: a experiência da Agência Nacional de Águas*. Foz do Iguaçu.

Rolo, R.M., Marodin, F.A., Carrard, G.P., Cardone, L.B. & da Silveira, C.J.S. (2022). A Python implementation for the simplified dam-break flood model. *Revista Brasileira de Recursos Hídricos Brazilian Journal of Water Resources* 27.

Salgado, S.R.T. & Silva Carvalho, E.M. da. (2023). Recommendations for the process of classification of dams in Brazil. *U.Porto Journal of Engineering Universidade do Porto - Faculdade de Engenharia* 9, 223–239.

Semagro. (2021) *Resolução Semagro n. 757, de 03 de agosto de 2021*. Diário Oficial do Estado de Mato Grosso do Sul, 04 ago. 2021, p. 22-32.

Sun, L., Guo, H., Chen, Z., Yin, Z., Feng, H., Wu, S. & Siddique, K.H.M. (2023a). Check dam extraction from remote sensing images using deep learning and geospatial analysis: A case study in the Yanhe River Basin of the Loess Plateau, China. *Journal of Arid Land Science* Press 15, 34–51.

Sun, L., Guo, H., Wang, H., Zhang, B., Feng, H., Wu, S. & Siddique, K.H.M. (2023b). Deep learning for check dam area extraction with optical images and digital elevation model: A case study in the hilly and gully regions of the Loess Plateau, China. *Earth Surface Processes and Landforms* Wiley.

CONSIDERAÇÕES FINAIS

Este estudo enfatizou a relevância da gestão de segurança de barragens no contexto estadual, bem como o uso de novas tecnologias para aprimorar o monitoramento dessas estruturas. Foi analisada a atuação do Imasul no SNISB, evidenciando como o órgão segue as diretrizes da PNSB para garantir a segurança das barragens no Mato Grosso do Sul. A implementação de sistemas de informação e a adoção de resoluções específicas, como a Resolução Semagro nº 757, têm desempenhado um papel fundamental na fiscalização dessas estruturas e na prevenção de desastres relacionados à sua operação.

A aplicação de modelos de segmentação, como o Segformer e o DeepLabV3+, foi avaliada na tarefa de mapeamento de reservatórios de barragens em imagens orbitais. O Segformer apresentou desempenho superior, tanto em métricas quantitativas quanto qualitativas, sendo mais eficiente na identificação e delimitação dos reservatórios. Esses resultados destacam o potencial da inteligência artificial e do sensoriamento remoto para aprimorar o monitoramento das barragens, proporcionando maior precisão e confiabilidade para os órgãos fiscalizadores, como o Imasul.

Com base nos achados desta pesquisa, conclui-se que o aprimoramento de métodos de segmentação e o uso de tecnologias avançadas podem representar um avanço significativo na gestão de barragens, especialmente no que tange à identificação e controle de áreas de risco. Recomenda-se que futuras pesquisas expandam o uso dessas ferramentas, integrando-as ao monitoramento de outras infraestruturas, como estradas e edificações, e a diferentes contextos geográficos, visando fortalecer a segurança de barragens e outras estruturas críticas, tanto no estado de Mato Grosso do Sul quanto em outras regiões do Brasil.

REFERÊNCIAS

Band, S.S., Chandra Pal, S., Bateni, S.M., Jun, C., Saha, A., Chowdhuri, I., Tiefenbacher, J.P. & Janizadeh, S. (2022). Using computational-intelligence algorithms and remote sensing data to optimize the locations of check dams to control sediment and runoff in Kandolus watershed, Mazandaran, Iran. *Geocarto International* Taylor and Francis Ltd. 37, 12966–12988.

Brasil. (2010). Lei n. 12.334, de 20 de setembro de 2010. Diário Oficial da União, 21 set 2010, p. 1. Disponível em: <https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2010/lei/112334.htm>. Acesso em: 2 set. 2024.

Brasil. *Relatório de Segurança de Barragens 2023*. Agência Nacional de Águas e Saneamento Básico. Brasília: ANA, 2024. Disponível em: <https://www.snisb.gov.br/portal-snisb/api/file/download/714/4/rsb_2023_2024_06_27_11_01_28.pdf>. Acesso em: 4 set. 2024.

Brasil. (2024) *Sistema Nacional de Informações sobre Segurança de Barragens (SNISB)*. Agência Nacional de Águas e Saneamento Básico. Brasília: ANA, 2024. Disponível em: <<https://www.snisb.gov.br/portal-snisb/inicio>>. Acesso em: 3 set. 2024.

CNRH. (2012). Resolução CNRH n. 143, de 10 de julho de 2012. Diário Oficial da União, 04 set 2012, Seção 1, p. 149, .

IMASUL. *Segurança de Barragem*. Instituto de Meio Ambiente de Mato Grosso do Sul. Campo Grande: Imasul, 2024. Disponível em: <<https://www.imasul.ms.gov.br/seguranca-de-barragem-2/>>. Acesso em: 4 abr. 2023.

Li, M., Dai, W., Fan, M., Qian, W., Yang, X., Tao, Y. & Zhao, C. (2023). Combining Deep Learning and Hydrological Analysis for Identifying Check Dam Systems from Remote Sensing Images and DEMs in the Yellow River Basin. *International Journal of Environmental Research and Public Health* MDPI 20,.

Li, S., Xiong, L., Hu, G., Dang, W., Tang, G. & Strobl, J. (2021). Extracting check dam areas from high-resolution imagery based on the integration of object-based image analysis and deep learning. *Land Degradation and Development* John Wiley and Sons Ltd 32, 2303–2317.

Marques, E. (2023). *Segurança em barragens de terra: orientações gerais e práticas recomendadas*. Curitiba: Appris.

Petry, A., Laus, F., Anderáos, A. & Bomfim, M. (2018). *Classificação de barragens quanto ao Dano Potencial Associado: a experiência da Agência Nacional de Águas*. Foz do Iguaçu.

Rolo, R.M., Marodin, F.A., Carrard, G.P., Cardone, L.B. & da Silveira, C.J.S. (2022). A Python implementation for the simplified dam-break flood model. *Revista Brasileira de Recursos Hídricos* Brazilian Journal of Water Resources 27.

Salgado, S.R.T. & Silva Carvalho, E.M. da. (2023). Recommendations for the process of classification of dams in Brazil. *U.Porto Journal of Engineering* Universidade do Porto - Faculdade de Engenharia 9, 223–239.

Semagro. (2021) *Resolução Semagro n. 757, de 03 de agosto de 2021*. Diário Oficial do Estado de Mato Grosso do Sul, 04 ago. 2021, p. 22-32.

Sun, L., Guo, H., Chen, Z., Yin, Z., Feng, H., Wu, S. & Siddique, K.H.M. (2023a). Check dam extraction from remote sensing images using deep learning and geospatial analysis: A case study in the Yanhe River Basin of the Loess Plateau, China. *Journal of Arid Land Science* Press 15, 34–51.

Sun, L., Guo, H., Wang, H., Zhang, B., Feng, H., Wu, S. & Siddique, K.H.M. (2023b). Deep learning for check dam area extraction with optical images and digital elevation model: A case study in the hilly and gully regions of the Loess Plateau, China. *Earth Surface Processes and Landforms* Wiley.