

UNIVERSIDADE FEDERAL DO PAMPA

DANILO VENTURINI DE MELO SANT'ANNA

**AVALIAÇÃO DA QUALIDADE DA SEGMENTAÇÃO DE IMAGEM DO CBERS 04A
ATRAVÉS DO MODELO U-NET NO CONTEXTO DO PLANEJAMENTO URBANO
NO MUNICÍPIO DE ITAQUI -RS**

**ITAQUI
2024**

DANILO VENTURINI DE MELO SANT'ANNA

**AVALIAÇÃO DA QUALIDADE DA SEGMENTAÇÃO DE IMAGENS DO CBERS
04A ATRAVÉS DO MODELO U-NET NO CONTEXTO DO PLANEJAMENTO
URBANO NO MUNICÍPIO DE ITAQUI - RS**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia Cartográfica e de Agrimensura da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Bacharel.

Orientador: Prof. Dr. Cristiano Galafassi

**ITAQUI
2024**

Ficha catalográfica elaborada automaticamente com os dados fornecidos pelo(a) autor(a) através do Módulo de Biblioteca do Sistema GURI (Gestão Unificada de Recursos Institucionais).

A481o Sant'anna, Danilo Venturini de Melo
Avaliação da Qualidade da Segmentação de Imagens do CBERS 04^a Através do Modelo U-Net no Contexto do Planejamento Urbano no Município de Itaqui – RS.
27 p.

Orientador: Cristiano Galafassi
Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Pampa, Engenharia Cartográfica e de Agrimensura, Campus Itaqui, 2013.

1. Sensoriamento Remoto. 2. Redes Neurais Convolutivas. 3. Segmentação de Imagens. 4. Planejamento Urbano.

DANILO VENTURINI DE MELO SANT'ANNA

**AVALIAÇÃO DA QUALIDADE DA SEGMENTAÇÃO DE IMAGENS DO CBERS
04A ATRAVÉS DO MODELO U-NET NO CONTEXTO DO PLANEJAMENTO
URBANO NO MUNICÍPIO DE ITAQUI -RS**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia Cartográfica e de Agrimensura da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Bacharel.

Trabalho de Conclusão de Curso defendido e aprovado em: dia, mês e ano.

Banca examinadora:

Documento assinado digitalmente
 **CRISTIANO GALAFASSI**
Data: 22/07/2024 10:05:28-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Cristiano Galafassi
Orientador
UNIPAMPA

Documento assinado digitalmente
 **SIDNEI LUIS BOHN GASS**
Data: 18/07/2024 14:31:34-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Sidnei Luís Bohn Gass
UNIPAMPA

Documento assinado digitalmente
 **IGOR SILVEIRA ELESBAO**
Data: 16/07/2024 19:11:29-0300
Verifique em <https://validar.iti.gov.br>

Prof. Igor Silveira Elesbão.
UNIPAMPA

AGRADECIMENTO

Gostaria de começar agradecendo minha mãe, Angela Maria de Melo, que partiu cedo, mas que tenho a certeza que olha por mim e por toda minha família.

À minha família, que mesmo distante sempre me apoiou como podiam, me deram forças para concluir este sonho que é a graduação. Este agradecimento que estendo a Keicy Cristiane e toda sua família, que hoje posso dizer que também são minha família.

À UNIPAMPA, que me deu a possibilidade de me formar em um curso superior de forma gratuita e com ensino de qualidade.

Ao Prof. Dr. Cristiano Galafassi, por aceitar ser meu orientador não só no trabalho de conclusão de curso, mas como em outros trabalhos realizados.

Aos demais membros da banca por disponibilizarem tempo para me auxiliar não só na graduação como também na avaliação deste trabalho.

E aos Professores que sempre deram o seu melhor para passar seus conhecimentos e experiências.

"Nunca ande por trilhas, pois assim só irá até onde outros já foram".

Alexander Graham Bell

RESUMO

O processo de segmentação é fundamental para extrair informações relevantes de imagens de sensoriamento remoto, como identificação de áreas urbanas, cobertura vegetal, corpos d'água e outros elementos geográficos. Porém a segmentação manual de imagens de satélite pode ser trabalhosa e lenta, e é propensa a erros humanos. As redes neurais convolucionais (CNNs) oferecem uma alternativa avançada e automatizada para a segmentação manual de imagens de satélite, permitindo uma análise mais precisa e eficiente das características espaciais e espectrais das imagens. Tendo isso em vista, o presente trabalho traz uma análise aprofundada do desenvolvimento e desempenho de um modelo de rede neural convolutiva U-Net, capaz de segmentar imagens provenientes do satélite CBERS 04A. A grande vantagem em usar uma CNN é sua capacidade de aprender automaticamente características complexas das imagens, proporcionando resultados precisos e eficientes em tarefas de segmentação e análise de dados de sensoriamento remoto. O modelo escolhido foi a U-Net que utiliza camadas de convolução para capturar detalhes em múltiplas escalas na entrada e saída, facilitando a segmentação precisa de imagens ao combinar informações de *downsampling* e *upsampling paths*. Como os dados de treinamento (máscaras) ainda precisam ser feitos manualmente, há grandes chances de haver erros sistemáticos, graças à baixa qualidade dos recortes da imagem da área urbana de Itaquí. O modelo é capaz de segmentar corretamente a maioria dos pixels, mas há espaço para melhorias, além disso imagens com uma melhor qualidade podem aumentar consideravelmente a acurácia do modelo. A segmentação resultando pode ser utilizada em conjunto com outros dados para auxiliar no planejamento urbano da cidade de Itaquí, principalmente no que diz respeito ao crescimento ordenado da cidade e prevenção em casos de enchentes que é um problema recorrente na região.

Palavras-Chave: Segmentação, Sensoriamento Remoto, CBERS 04A, inteligência artificial, Crescimento Urbano, U-Net.

ABSTRACT

The segmentation process is crucial to extracting relevant information from remote sensing images, such as identification of urban areas, plant cover, water bodies and other geographical elements. However, the manual segmentation of satellite images can be laborious and slow, and is prone to human errors. Convolutional neural networks (CNNs) offer an advanced and automated alternative to the manual segmentation of satellite images, allowing for more accurate and efficient analysis of the spatial and spectral characteristics of the images. With this in mind, the present work brings an in-depth analysis of the development and performance of a U-Net convolutive neural network model, able to segment images from the CBERS 04A satellite. The great advantage of using a CNN is its ability to automatically learn complex characteristics of images, providing accurate and efficient results in targeting and remote sensing data analysis tasks. The model chosen was the U-Net that uses convolutionary layers to capture details on multiple scales on input and output, facilitating precise segmentation of images by combining downsampling and upsampling path information. As the training data (masks) still need to be done manually, there is a great chance of there being systematic errors, thanks to the poor quality of the cuts of the image of the urban area of Itaquí. The model is able to correctly segment most pixels, but there is room for improvements, besides better quality images can significantly increase the accuracy of the model. The resulting segmentation can be used in conjunction with other data to assist the urban planning of the city of Itaquí, especially with regard to the orderly growth of the town and prevention in cases of flooding which is a recurring problem in the region.

Keywords: Segmentation, Remote Sensing, CBERS 04A, Artificial Intelligence, Urban Growth, Space Resolution.

LISTA DE FIGURAS

Figura 1 – Arquitetura da U-Net	17
Figura 2 – Composição Colorida da área Urbana de Itaqui.	20
Figura 3 – Exemplo de Recortes e suas respectivas máscaras.	21
Figura 4 – Mascara de Previsão	22
Figura 5 – Área Urbana de Itaqui Segmentada	23

LISTA DE SIGLAS

IA - Inteligência Artificial

CBERS - China-Brazil Earth Resources Satellite

MUX - Câmera Multiespectral

WFI - Câmera imageadora de Campo Largo

WPM - Câmera Multiespectral e Pancromática de Ampla Varredura

CNN - Redes Neurais Convolucionais

SUMÁRIO

1 INTRODUÇÃO	12
2 JUSTIFICATIVA	12
3 OBJETIVOS	13
3.1 Geral	13
3.2 Específicos.....	13
4 REFERENCIAL TEÓRICO	13
4.1 Sensoriamento Remoto.....	13
4.2 CBERS 04A.....	14
4.3 Inteligência Artificial e Segmentação de Imagens	16
4.3.1 Redes Neurais Convolucionais e a U-Net.	16
4.3.2 Implementação de CNNs.....	18
5 MATERIAL E MÉTODOS	19
6 RESULTADOS E DISCUSSÕES.....	22
7 CONSIDERAÇÕES FINAIS.....	24
REFERÊNCIAS.....	26

1 INTRODUÇÃO

O sensoriamento remoto é uma técnica essencial na coleta de informações sobre a Terra sem a necessidade de contato físico direto. Através do uso de sensores instalados em satélites, aeronaves ou outras plataformas, é possível adquirir dados sobre a superfície terrestre, contribuindo para uma compreensão abrangente do ambiente. (JENSEN, 2015)

Apesar disso, o sensoriamento remoto enfrenta diversos desafios em relação à análise de imagens, como por exemplo a classificação precisa de objetos complexos, como edifícios, estradas e corpos d'água, pode ser desafiadora. A segmentação de imagens com o uso de Inteligência Artificial (IA), surge como uma abordagem promissora para superar essas dificuldades.

A IA pode ser treinada para detectar e classificar uma variedade de objetos complexos, como edifícios, veículos, corpos d'água, pistas de pouso, pontes e outras estruturas. A precisão na identificação desses elementos é crucial para diversas aplicações, incluindo planejamento urbano, monitoramento ambiental e segurança. Além disso, o modelo pode ser configurado para adaptar-se a diferentes resoluções espaciais das imagens de satélite, garantindo que a classificação seja robusta e precisa independentemente das características específicas de cada sensor.

Visto isso a combinação do sensoriamento remoto e da Inteligência Artificial representa uma convergência poderosa, impulsionando avanços significativos na análise de imagens e no entendimento de nosso ambiente terrestre.

2 JUSTIFICATIVA

Levando em consideração a persistente problemática das enchentes em Itaqui, este estudo assume uma relevância crucial para a pesquisa, justificando-se pela necessidade imediata de abordagens inovadoras e eficazes para lidar com os desafios urbanos e ambientais enfrentados pela cidade. Os resultados deste trabalho têm o potencial de não apenas subsidiar a formulação de políticas públicas e orientar o planejamento urbano, mas também de embasar as decisões dos órgãos responsáveis, proporcionando uma base sólida para a implementação de medidas mitigadoras.

3 OBJETIVOS

3.1 Geral

Desenvolver, implementar e avaliar um modelo de inteligência artificial destinado à segmentação de imagens adquiridas pelo satélite CBERS 04A, com ênfase na segmentação entre áreas de construção e vias urbanas na cidade de Itaquí-RS.

3.2 Específicos

- Desenvolver e aplicar um modelo de inteligência artificial especializado em segmentação de imagens.
- Avaliar a precisão do modelo, considerando seu processo de treinamento, e discutir os resultados alcançados na segmentação de imagens de diferentes datas.

4 REFERENCIAL TEÓRICO

A investigação do crescimento urbano, por meio da análise de imagens de satélite, está intrinsecamente ligada a áreas da engenharia, notadamente à computação, sensoriamento remoto e geoprocessamento, as quais se complementam harmoniosamente. Nesse contexto, esta abordagem teórica se propõe a elucidar conceitos fundamentais que delineiam um contexto conciso sobre o tema, especialmente quando aplicado à segmentação de imagens de satélite em diversas resoluções, empregando técnicas de IA.

4.1 Sensoriamento Remoto

Os avanços no sensoriamento remoto têm sido significativos, especialmente na obtenção de imagens por meio de diversos tipos de sensores. Esses avanços têm permitido a coleta de dados mais precisos, frequência de revisitação mais rápida e uma gama mais ampla de aplicações (CAMPBELL, 2015).

Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2023) o sensoriamento remoto constitui uma técnica de obtenção de informações relativas a um objeto, área ou fenômeno terrestre sem a necessidade de contato físico direto. Essas informações são adquiridas por meio da captação de radiação eletromagnética, originada tanto de fontes naturais (sensores passivos), como o Sol, quanto de fontes artificiais (sensores ativos), exemplificadas pelo radar. Estas informações são apresentadas sob a forma de imagens, sendo as mais prevalentes aquelas adquiridas por sensores óticos em satélites orbitais (RICHARDS, 2013).

Atualmente, o campo do sensoriamento é composto por uma extensa constelação de satélites, fornecendo imagens para atender às diversas necessidades de uma ampla gama de usuários. Para aqueles que demandam uma observação minuciosa, tanto em termos de tamanho quanto de formas dos objetos, estão disponíveis sensores capazes de detectar áreas unitárias inferiores a 1 metro. Esses dispositivos ainda possibilitam a visualização estereoscópica 3D, revelando-se particularmente valiosos para levantamentos cadastrais multifinalitários, aplicações urbanas e cartografia digital (LILLESAND; KIEFER; CHIPMAN, 2015).

Por outro lado, para os interessados na monitoração contínua da evolução e das mudanças na paisagem, há sensores com alta taxa de revisita à área. Por fim, aqueles que buscam determinar a composição ou constituição de minerais ou rochas podem encontrar nos sensores equipados com um extenso número de bandas espectrais a solução adequada para suas necessidades específicas (TURNER; SPARROW; BARRETT, 2008).

4.2 CBERS 04A

Através de um acordo que envolveu uma parceria entre o Instituto Nacional de Pesquisas Espaciais (INPE) e a Academia Chinesa de Tecnologia Espacial (CAST), o desenvolvimento conjunto de um programa voltado à construção de dois satélites avançados de sensoriamento remoto foi formado. Este programa ficou conhecido como Programa CBERS, uma abreviação para "China-Brazil Earth Resources Satellite" (Satélite Sino-Brasileiro de Recursos Terrestres). O sexto membro da família CBERS, o satélite CBERS 04A, foi lançado e inserido com êxito em órbita nas primeiras horas da madrugada de 20 de dezembro de 2019. Este lançamento ocorreu

a partir do Centro de Lançamento de Satélites de Taiyuan (TSLC), localizado na China.

Segundo o Instituto Nacional de Pesquisas Espaciais (INPE, 2019) o satélite CBERS 04A possui uma câmera multiespectral e Pancromática de Ampla Varredura (WPM), uma Câmera Multiespectral (MUX) e uma câmera imageadora de Campo Largo (WFI) que tem suas especificações explicadas no quadro abaixo. Sendo a WPM a principal delas, e seu objetivo é fornecer imagens com resolução panorâmica de 2m e resolução multiespectral de 8m simultaneamente na órbita do satélite.

Quadro: Características das Câmeras do CBERS 04A.

Características das câmeras do CBERS 04A			
Característica	WPM	MUX	WFI
Bandas Espectrais	0,45-0,52 μ m (B) 0,52-0,59 μ m (G) 0,63-0,69 μ m (R) 0,77-0,89 μ m (NIR) 0,45-0,90 μ m (PAN)	0,45-0,52 μ m (B) 0,52-0,59 μ m (G) 0,63-0,69 μ m (R) 0,77-0,89 μ m (NIR)	0,45-0,52 μ m (B) 0,52-0,59 μ m (G) 0,63-0,69 μ m (R) 0,77-0,89 μ m (NIR)
Resolução	2 m 8 m	16,5 m	55 m
Largura da Faixa Imageada	92 km	95 km	684 km
Visada Lateral de Espelho	não	não	não
Revisita	31 dias	31 dias	5 dias
Quantização	10 bits	8 bits	10 bits
Taxa de Dados Bruta	1800.8 Mbps 450.2 Mbps	65 Mbps	50 Mbps

Fonte: INPE (2019) (Adaptado pelo Autor).

4.3 Inteligência Artificial e Segmentação de Imagens

O uso de inteligência artificial, tem revolucionado a análise de imagens em diversos campos. Essa abordagem tem se destacado pela capacidade de extrair informações complexas e padrões sutis a partir de grandes conjuntos de dados visuais.

De acordo com Marvin Minsky (1968), a inteligência artificial é a ciência de fazer com que as máquinas façam coisas que exigiriam inteligência se feitas por um ser humano. Pensando dessa forma, a IA pode ser aplicada nas mais diversas áreas, uma delas é a segmentação de imagens. Segmentar, no contexto do processamento digital de imagens, refere-se à ação de subdividir uma imagem em suas partes ou elementos constituintes. Existem abordagens variadas que de acordo com Richards e Jia (2006), incluem métodos baseados em intensidade de pixels, texturas, cores, contornos ou mesmo técnicas avançadas de aprendizado de máquina, como redes neurais, para realizar essa subdivisão de maneira precisa e automatizada.

Na esfera da visão computacional, o termo "segmentação" descreve o procedimento de desagregar uma imagem digital em diversos segmentos ou regiões, identificando as partes constituintes (Jain, 1989). No contexto do processamento digital de imagens provenientes de sensores remotos, a segmentação de imagem assume um papel crucial na análise, focalizando na delimitação de objetos geográficos específicos ou na identificação de regiões distintas dentro da imagem (Moik, 1980).

Em termos amplos, de acordo com Gonzales e Woods (2000), funções de processamento que englobam reconhecimento e interpretação estão vinculadas a aplicações de análise de imagens, nas quais o propósito consiste na extração automática, ou mesmo parcialmente automática, de informações a partir de uma imagem.

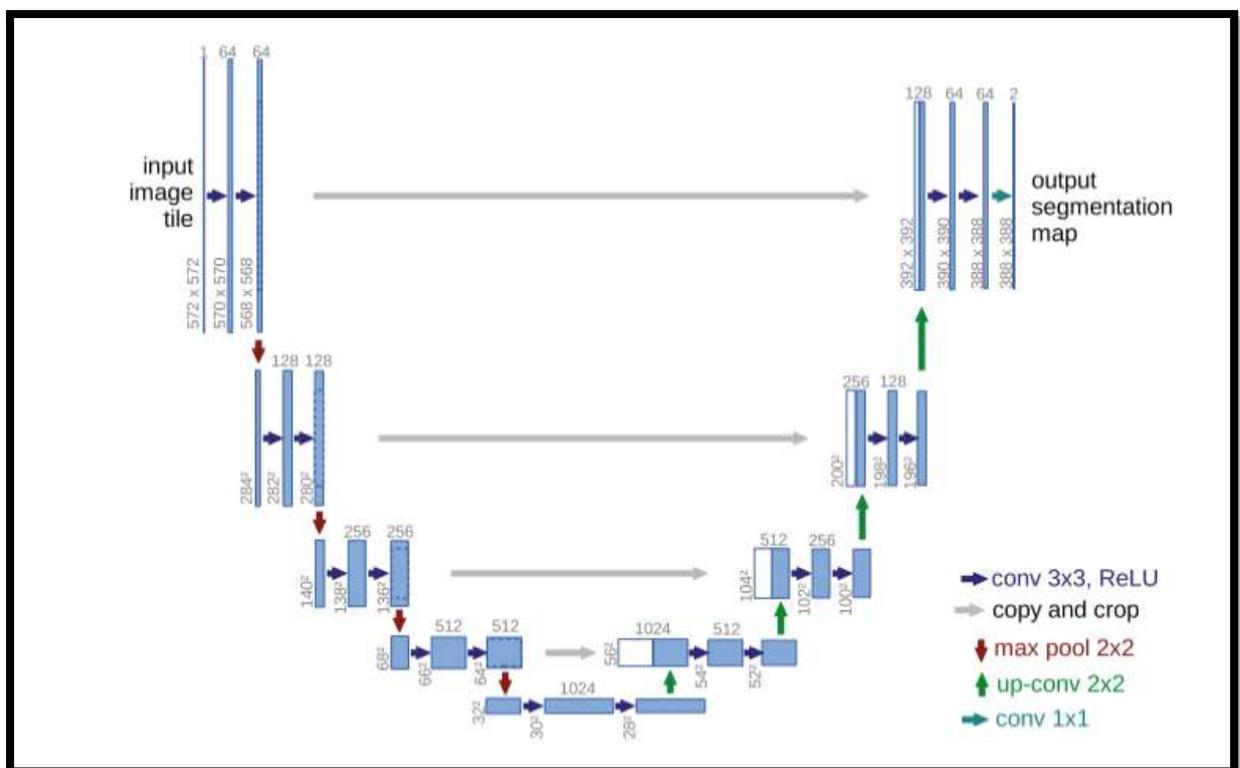
4.3.1 Redes Neurais Convolucionais e a U-Net.

Segundo O'shea e Nash (2015), as Redes Neurais Convolucionais são usadas principalmente no campo do reconhecimento de padrões em imagens porque permitem incorporar características específicas de imagens na arquitetura do modelo. Essa abordagem especializada reduz o número de parâmetros necessários durante a

configuração do modelo, tornando as CNNs ideais para atividades que exigem análise detalhada de conteúdo visual.

A U-Net é um tipo de rede neural convolucional que foi desenvolvida principalmente para tarefas de segmentação de imagens. Sua aplicação inicial era na área médica, segmentando, por exemplo, tecidos em imagens de ressonância magnética. A arquitetura "U" da U-Net combina redes de codificação e decodificação, permitindo uma segmentação precisa. Essa estrutura em U pode ser vista na figura 1 é da seguinte forma:

Figura 1: Arquitetura da U-Net.



Fonte: RONNEBERGER, FISCHER E BROX, 2015.

- *Encoder* (Codificador)

O codificador é composto por uma série de camadas convolucionais seguidas por operações de *pooling* (geralmente *max pooling*). Cada camada convolucional aplica filtros à imagem de entrada, extraindo características importantes. A operação de *pooling* reduz a dimensão espacial da imagem, mantendo as características mais relevantes.

Cada etapa do codificador diminui a resolução espacial da imagem enquanto aumenta o número de filtros, capturando informações mais abstratas e de nível superior.

- *Bottleneck* (Gargalo)

A parte mais estreita da U-Net conecta o codificador e o decodificador. Nesta etapa, as características extraídas são mais condensadas e representam a informação mais essencial da imagem de entrada.

- *Decoder* (Decodificador)

O decodificador é simétrico ao codificador, composto por camadas de convolução transposta (ou *upsampling*) que aumentam a resolução espacial da imagem, revertendo o processo de *pooling* realizado no codificador. Cada etapa do decodificador aumenta a resolução da imagem enquanto reduz o número de filtros, reconstruindo a imagem de saída com a mesma dimensão da imagem de entrada.

- *Skip Connections* (Conexões de Atalho)

Uma característica chave da U-Net são as conexões de atalho que ligam diretamente cada camada do codificador a uma camada correspondente no decodificador com a mesma resolução. Essas conexões permitem que a rede recupere detalhes espaciais finos que podem ter sido perdidos durante o processo de codificação.

As características extraídas no codificador são concatenadas com as características correspondentes no decodificador, proporcionando informações ricas e detalhadas para a reconstrução da imagem segmentada.

4.3.2 Implementação de CNNs

A implementação de Redes Neurais Convolucionais envolve várias etapas cruciais para configurar e treinar o modelo, adaptando-o às necessidades específicas da aplicação. Inicialmente, é necessário preparar os dados de entrada, que geralmente consistem em conjuntos de imagens rotuladas. Estes dados são divididos em conjuntos de treinamento, validação e teste, garantindo uma avaliação robusta do desempenho do modelo. De acordo com Géron (2019), esses passos são fundamentais para o desenvolvimento e aplicação eficaz de CNNs.

Estas implementações podem ser feitas usando bibliotecas de *deep learning* como Keras e TensorFlow, que são fáceis de usar para treinar modelos de redes

neurais. TensorFlow é uma ferramenta poderosa e adaptável para *deep learning* e *machine learning*, adequada tanto para especialistas quanto para iniciantes. Ele é popular entre desenvolvedores e pesquisadores porque pode ser aplicado a sistemas de produção em larga escala. TensorFlow permanece uma das plataformas mais populares no campo da inteligência artificial graças à sua comunidade ativa e à sua evolução constante (Google Brain Team, 2024).

5 MATERIAL E MÉTODOS

A cidade de Itaqui que tem 35.768 habitantes segundo o censo de 2022, e por se localizar às margens do Rio Uruguai, sofre com constantes enchentes que causam problemas a toda a população. O planejamento urbano é essencial para cidades desse porte, especialmente aquelas que lidam com enchentes frequentes.

Um planejamento bem estruturado garante a segurança e o bem-estar da população, reduzindo os efeitos negativos das inundações. Isso inclui a construção de infraestrutura adequada, como sistemas de drenagem e reservatórios de contenção eficientes, bem como políticas de uso do solo que impeçam construções em áreas de risco. Para proteger as pessoas durante enchentes, o planejamento urbano também deve incluir planos de emergência e evacuação. Investir em planejamento urbano resiliente não apenas evita danos físicos e perdas financeiras, mas também melhora a qualidade de vida e a sustentabilidade ambiental nas cidades.

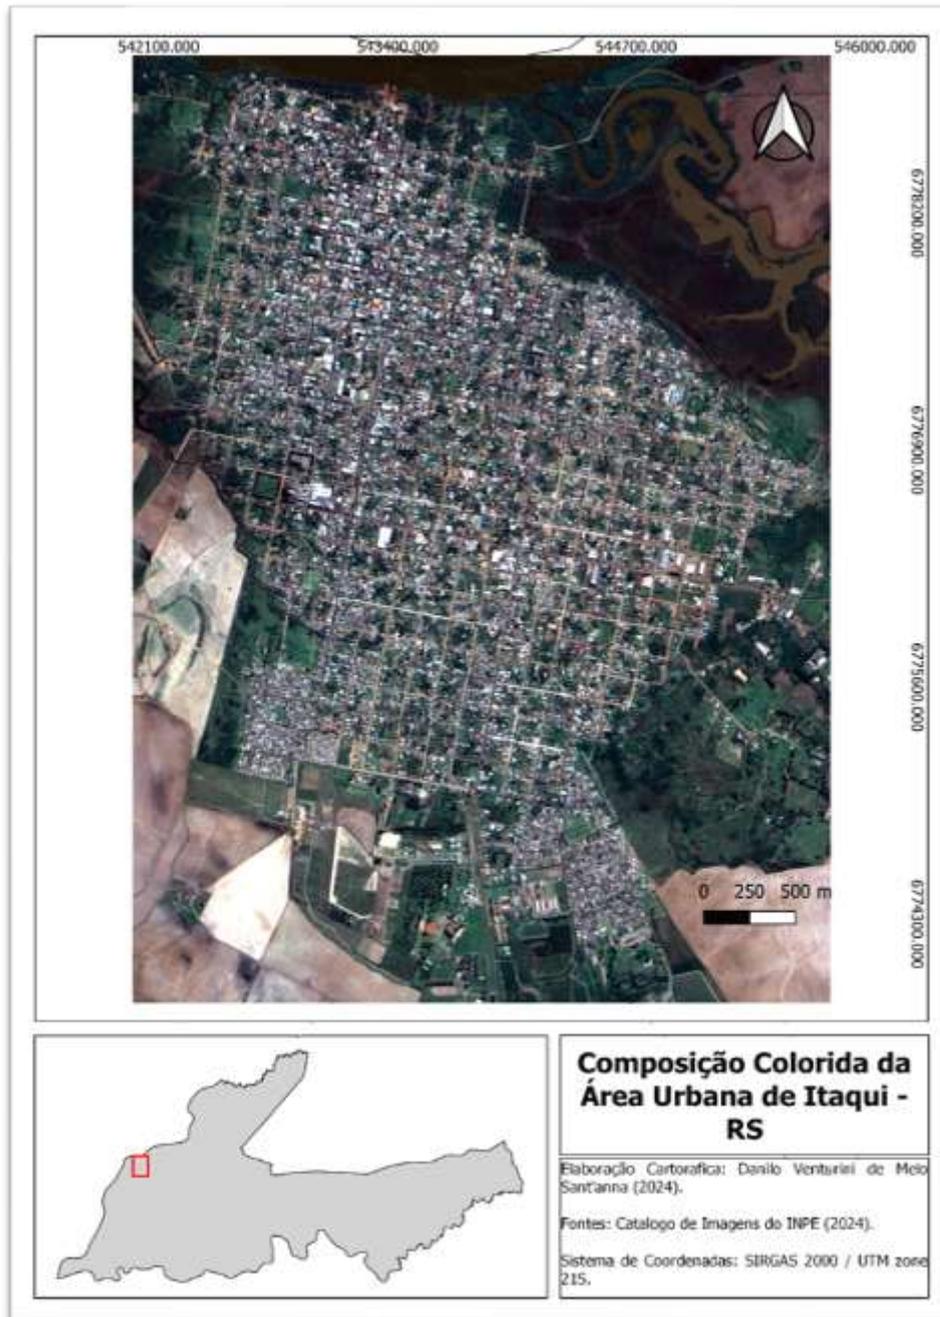
Partindo desse ponto, os instrumentos provenientes das geotecnologias ampliam a visão do planejador, e evidenciam fenômenos que acontecem nos centros urbanos, tornando mais clara as atitudes que devem ser tomadas em benefício da sociedade. (DO CARMO, AZEVEDO, MATIAS, 2023)

Tendo em vista o cenário descrito, foram utilizadas imagens do satélite CBERS 04A, órbita 213, ponto 150 cena (213/150), capturadas no dia 03 de outubro de 2023. Foi realizado o download de todas as bandas disponíveis do sensor (WPM) do satélite. Estas imagens estão disponíveis no catálogo de imagens do Instituto nacional de pesquisas espaciais, que disponibiliza imagens de forma gratuita.

As imagens utilizadas, do satélite CBERS 04A, capturadas a partir do sensor WPM, terão nas bandas B, G, R, 8 metros de resolução espacial, já na banda PAN 2 metros de resolução. Todas as imagens foram processadas inicialmente no software QGIS. Foi feito um recorte de todas as bandas deixando em evidência a área urbana

de Itaqui conforme mostrado na figura 1. Em seguida foi criado um mosaico que uniu as bandas 1 (Azul), 2 (Verde) e 3 (Vermelha), formando assim uma composição colorida com 8 metros de resolução (Figura 2). Para obter essa composição com 2 metros, foi utilizado a ferramenta de pansharpning, que funde a composição com a banda PAN.

Figura 2: Composição Colorida da área Urbana de Itaqui.



Fonte: INPE, 2023.

Da composição colorida que tem 1856 x 2560 (Pixels) foram gerados 336 recortes com 125 x 125 utilizando uma grade quadriculada como máscara. Destes recortes foram escolhidas 15 para a criação das máscaras (filtro). As máscaras foram feitas colorindo os pixels dividindo-os em 3 categorias, Área Construída (Cinza), Área aberta ou vegetação (Verde) e Ruas (Preto), exemplos de imagens e suas respectivas máscaras podem ser vistas na figura 3.

Figura 3: Exemplo de Recortes e suas respectivas máscaras.



Fonte: Adaptado pelo autor

Na plataforma do Google Collaboratory (Colab), foi desenvolvido um modelo baseado em rede neural convolutiva importando as bibliotecas tensorflow e keras. Com base nessas imagens de 125 x 125, foram geradas imagens de treinamento de tamanho 64 x 64 x 3, totalizando 60 imagens de treinamento juntamente com as suas respectivas máscaras. O modelo acessou o banco de dados onde estavam os dados para o treinamento (Imagens e máscaras correspondentes), e normalizou as imagens dividindo-as por 255, dessa forma encaixando-a no intervalo [0,1].

No *Encoder* foi definido o tamanho das imagens de entrada como 64 x 64 x 3, indicando uma imagem de 64x64 pixels com 3 canais (RGB). Foram aplicadas convoluções com filtros 3x3, função de ativação ReLU e *padding* 'same' para preservar a dimensão espacial. Nesse passo a resolução é reduzida pela metade para aumentar a percepção do contexto.

A camada *bottleneck* aumenta ainda mais o número de filtros para capturar características complexas. Então o *decoder* reconstrói a imagem original a partir das características extraídas, aumentando a resolução. A camada de saída utiliza filtros 1x1 para reduzir o número de canais ao número de classes desejadas (neste caso, 3 classes) com ativação softmax para obter probabilidades de classe.

O modelo gerou uma máscara de predição, que para validação, foi comparada com a imagem que tem 2 metros de resolução espacial gerada no software QGIS.

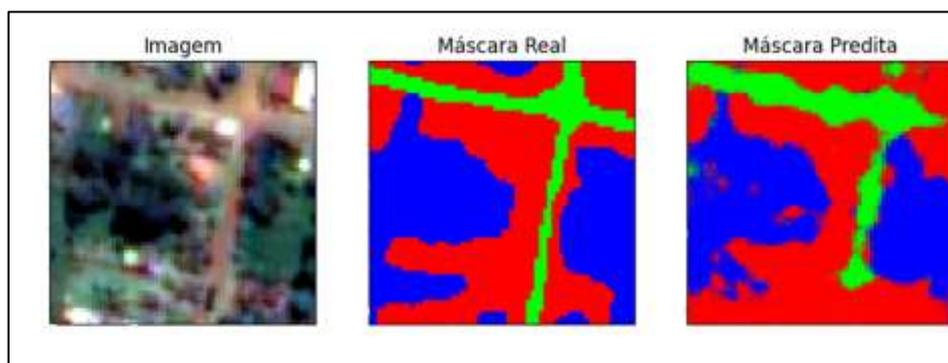
6 RESULTADOS E DISCUSSÕES

Os dados de treinamento fornecidos ao modelo U-Net foram classificados previamente de forma manual no Paint 3D com a utilização da caneta de pixel, isso, somado a degradação da qualidade da imagem devido aos recortes, faz com que se possa ter erros sistemáticos nos dados, mesmo que se tenha tido um cuidado em minimiza-los.

No *Downsampling Path*, que foi dividido em 5 blocos, a imagem que teve como tamanho de entrada 64 x 64 teve sua qualidade reduzida a cada bloco chegando a ficar 4 x 4 no quinto bloco (*bottleneck*). Ao mesmo tempo, filtros foram aplicados extraíndo informações importantes para a segmentação.

Em seguida no *Upsampling Path* a imagem volta a ter o tamanho original da entrada, mas combinando as informações adquiridas no *Downsampling Path*, gerando uma máscara de previsão (Figura 4), o modelo trabalha com cores diferentes das escolhidas para as categorias, sendo a cor verde para as ruas, vermelho para as áreas construídas e azul áreas abertas ou de vegetação, mas isso é só de forma visual, não interferindo no treinamento do modelo.

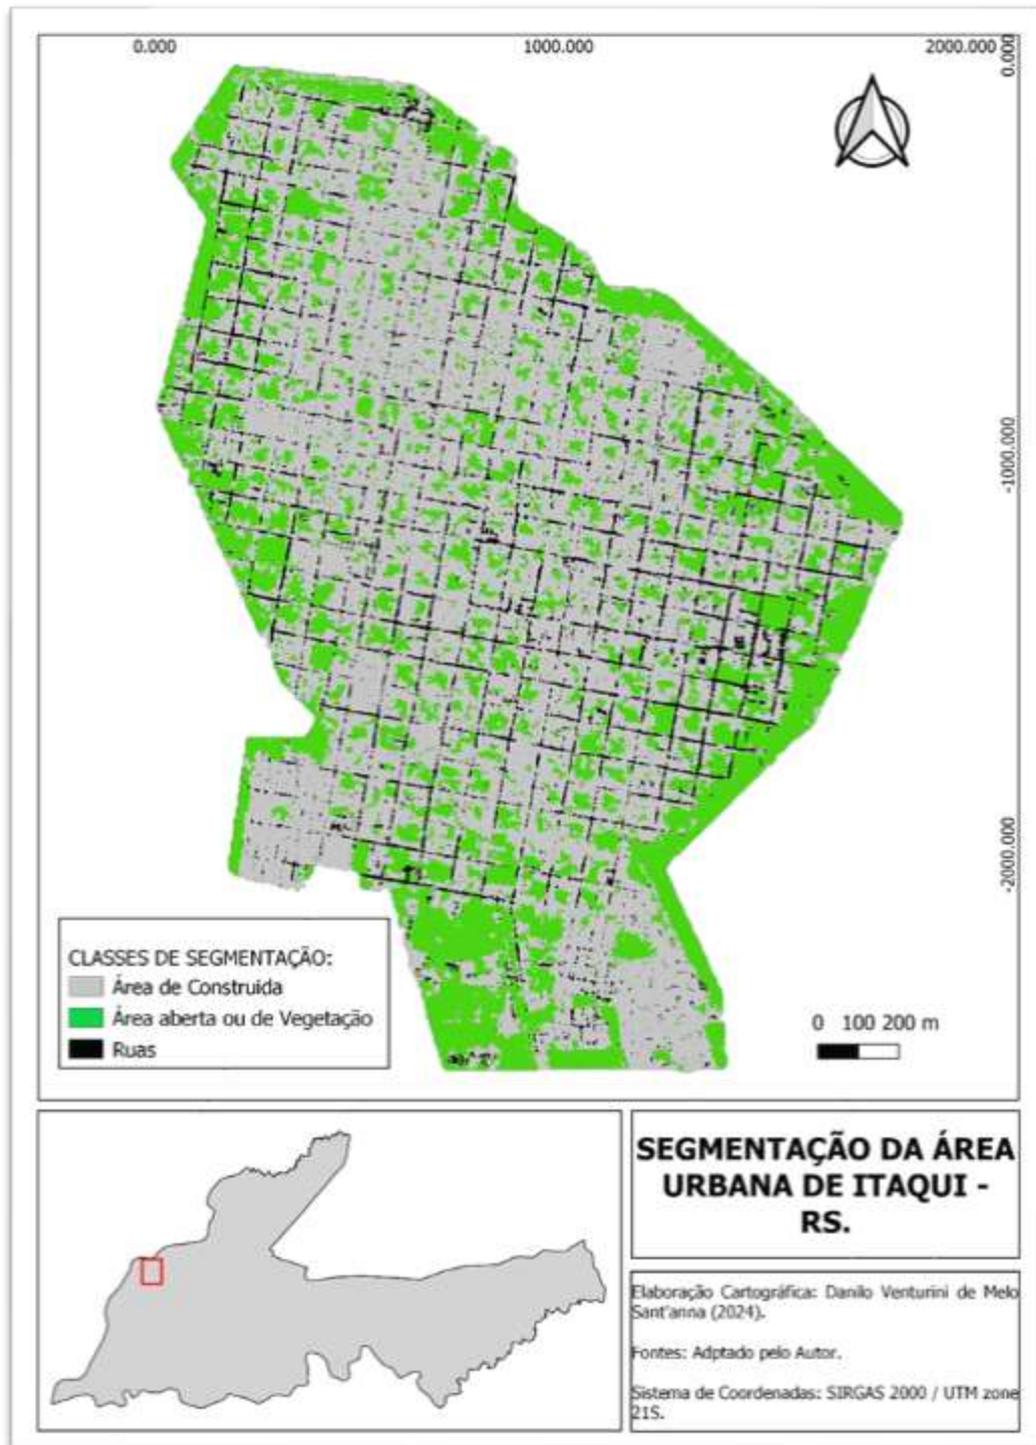
Figura 4: Mascara de Previsão.



Fonte: Adaptado pelo autor.

Com o modelo treinado, ao carregar a imagem da área urbana de Itaqui com 2 metros de resolução espacial, foi gerada uma imagem com a previsão do modelo (Figura 5), com uma acurácia por volta de 80%. Essa acurácia pode ser considerada mediana, o que pode ter sido causada pela baixa qualidade das máscaras, proveniente da baixa qualidade dos recortes da imagem.

Figura 5: Área Urbana de Itaqui Segmentada.



Fonte: Adaptado pelo Autor.

As imagens capturadas pelo satélite CBERS 04A são reconhecidas por sua boa qualidade geral, oferecendo uma resolução adequada para diversas aplicações de monitoramento e análise ambiental. No entanto, para o tipo específico de análise realizada neste trabalho, onde foi necessário criar máscaras a partir de recortes das imagens, observou-se uma degradação na qualidade. Esse processo de recorte compromete a nitidez e a precisão das informações nas imagens, impactando a eficácia das máscaras geradas e, conseqüentemente, a acurácia dos resultados obtidos na segmentação e análise urbana.

A acurácia do modelo possivelmente poderia ser aumentada com a utilização de técnicas de aumento de dados que pode aumentar a diversidade do conjunto de treinamento, melhorando a capacidade do modelo de generalizar para novos dados. Além disso, o treinamento com um conjunto de dados maior e mais variado pode ajudar a capturar uma gama mais ampla de variações nas imagens de satélite.

Com o resultado da segmentação é possível identificar diversas áreas para possíveis novas construções, principalmente as margens da região urbana. Combinando esses dados com as informações que a prefeitura de Itaqui e os responsáveis pelo planejamento urbano já possuem, é possível que a cidade continue a se desenvolver, evitando áreas conhecidas por sofrer com as enchentes que sempre causam grandes problemas na cidade e a seus habitantes.

As segmentações ajudam a identificar locais disponíveis e apropriados para novas construções, evitando áreas de preservação ambiental ou regiões já saturadas. Com a delimitação precisa das áreas urbanas, é possível planejar o crescimento da cidade de forma ordenada, integrando novas habitações e serviços de maneira eficiente. Além disso, as informações geradas podem ser disponibilizadas para a população, promovendo a transparência e a participação cidadã no planejamento urbano. Isso pode fomentar uma maior cooperação entre os moradores e as autoridades locais na busca por soluções para os problemas urbanos.

7 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo explorar a segmentação de imagens do satélite CBERS 04A utilizando a arquitetura de rede neural convolutiva U-Net para auxiliar no planejamento urbano da cidade de Itaqui. Através de um processo detalhado de treinamento e validação do modelo, foi alcançada uma acurácia de aproximadamente 80%, um resultado bom, mesmo com a baixa qualidade das

máscaras utilizadas no treinamento, causada pela baixa resolução dos recortes da imagem.

O modelo é capaz de segmentar corretamente a maioria dos pixels nas imagens de entrada em suas respectivas classes. Essa precisão sugere que o modelo aprendeu, de modo geral, as características e padrões presentes nos dados de treinamento, mas ainda há espaço para melhorias, especialmente em casos de bordas ou classes menos representadas. Uma precisão de 80% é um bom ponto de partida, demonstrando que a U-Net é eficaz para a tarefa de segmentação proposta, mas a otimização adicional do modelo e ajustes nos hiperparâmetros, além do uso de mais dados de treinamento, podem ajudar a melhorar ainda mais o desempenho.

A aplicação prática dos resultados pode ser vastamente benéfica para o planejamento urbano. As segmentações podem ser usadas para melhorar a infraestrutura existente, planejar novas construções de maneira ordenada, e monitorar áreas de risco, como regiões propensas a enchentes. Além disso, o uso contínuo dessa tecnologia pode assegurar a atualização constante dos planos urbanos, refletindo as mudanças dinâmicas na cidade e permitindo uma gestão mais eficiente dos recursos municipais.

Para futuros trabalhos, recomenda-se a implementação de modelos mais avançados, como U-Net++ ou DeepLab, para aumentar ainda mais a precisão das segmentações. A integração de dados de outras fontes, como drones e outros satélites, pode enriquecer a análise e fornecer uma visão mais completa da área urbana. Além disso, a adaptação do modelo para outras áreas geográficas pode ajudar a validar e generalizar os resultados obtidos, ampliando o impacto desta pesquisa.

Em suma, este trabalho contribui para o campo do planejamento urbano, demonstrando como a combinação de imagens de satélite e técnicas avançadas de segmentação pode fornecer informações valiosas para o desenvolvimento sustentável e ordenado de cidades de, especialmente em regiões que enfrentam desafios específicos como as enchentes, que é o caso da área de estudo deste trabalho. As metodologias e resultados apresentados neste estudo estabelecem uma base sólida para futuras pesquisas e aplicações práticas, promovendo um planejamento urbano mais eficiente e informado.

REFERÊNCIAS

CAMPBELL, J. B. ***Introduction to Remote Sensing***. 5th ed. New York: Guilford Press, 2015

DO CARMO, B. A.; AZEVEDO, T.; MATIAS, L. F. **As imagens de sensoriamento remoto no planejamento urbano de cidades pequenas: A necessidade da adoção de imagens aéreas**. 2023.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. O'Reilly Media, 2019.

GOOGLE BRAIN TEAM. **TensorFlow: Open-Source Machine Learning Framework for Everyone**. Disponível em: <https://www.tensorflow.org/>. Acesso em: 03 jul. 2024.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. São Paulo: Editora Blucher, 2000.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Atlas Geográfico **Escolar na Internet**. In: **O que é cartografia? sensoriamento remoto**. [S. l.], 2022.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (Brasil). **Câmeras Imageadoras CBERS 04A**. Disponível em: <http://www.cbbers.inpe.br/sobre/cameras/cbers04a.php#topo>. Acesso em: 14 nov. 2023.

JAIN, A. K. **Fundamentals of digital image processing**. Prentice-Hall, Inc., 1989.

JENSEN, J. R. **Introductory Digital Image Processing: A Remote Sensing Perspective**. 4th ed. Upper Saddle River: Pearson, 2015.

LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. **Remote sensing and image interpretation**. 7th ed. John Wiley & Sons, 2015.

MINSKY, M. (ed). **Semantic Information Processing**. Cambridge, Mass.: The MIT Press, 1968.

MOIK, J. G. **Digital processing of remotely sensed images**. Scientific and Technical Information Branch, National Aeronautics and Space Administration, 1980.

O'SHEA, K.; NASH, R. **An introduction to convolutional neural networks**. arXiv preprint arXiv:1511.08458, 2015.

RONNEBERGER, O.; FISCHER, P.; BROX, T. **U-net: Convolutional networks for biomedical image segmentation**. In: **Medical image computing and computer-assisted intervention—MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18**. Springer International Publishing, 2015. p. 234-241.

RICHARDS, J. A.; JIA, X. **Remote Sensing Digital Image Analysis: An Introduction**. Springer Remote Sensing/Photogrammetry Series, 3rd ed., 2006.

RICHARDS, J. A. **Remote Sensing Digital Image Analysis**. 5th ed. Springer, 2013.

TURNER, W; SPARROW, B; BARRETT, B. **Remote Sensing for Natural Resource Management and Environmental Monitoring**. *Progress in Physical Geography*, v. 32, n. 4, p. 473-491, 2008.