

**UNIVERSIDADE FEDERAL DO PAMPA**

**IGOR SILVEIRA ELESBÃO**

**USO DE REDES NEURAS ARTIFICIAIS PARA DETERMINAÇÃO DE PIXELS  
INDICANDO ÁGUA EM UMA IMAGEM DE SATÉLITE**

**Itaqui  
2023**

**IGOR SILVEIRA ELESBÃO**

**USO DE REDES NEURAS ARTIFICIAIS PARA DETERMINAÇÃO DE PIXELS  
INDICANDO ÁGUA EM UMA IMAGEM DE SATÉLITE**

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  
2023**

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 Elesbão, Igor Silveira

Uso de Redes Neurais Artificiais para determinação de pixels indicando água em  
uma imagem de satélite.

32 p.

Orientador: Cristiano Galafassi

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

1. Programação. 2. Redes Neurais. 3. Sensoriamento Remoto. 4. Inteligência  
Artificial.

**IGOR SILVEIRA ELESBÃO**

**USO DE REDES NEURAS ARTIFICIAIS PARA DETERMINAÇÃO DE PIXELS  
INDICANDO ÁGUA EM UMA IMAGEM DE SATÉLITE**

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 apresentado e aprovado em: 02 de fevereiro de 2023.

Banca examinadora:

Documento assinado digitalmente



CRISTIANO GALAFASSI

Data: 08/02/2023 14:23:11-0300

Verifique em <https://verificador.iti.br>

---

**Prof. Dr. Cristiano Galafassi**

**Orientador(a)**

**UNIPAMPA**

Documento assinado digitalmente



CHARLES QUEVEDO CARPES

Data: 08/02/2023 14:31:00-0300

Verifique em <https://verificador.iti.br>

---

**Prof. Dr. Charles Quevedo Carpes**

**UNIPAMPA**

Documento assinado digitalmente



SIDNEI LUIS BOHN GASS

Data: 08/02/2023 16:53:50-0300

Verifique em <https://verificador.iti.br>

---

**Prof. Dr. Sidnei Luis Bohn Gass**

**UNIPAMPA**

## **AGRADECIMENTO**

Primeiramente gostaria de agradecer a Deus, pela oportunidade e capacidade a mim concedidas para chegar até este momento.

À minha família pelo apoio em não só no Trabalho de Conclusão, como em toda minha graduação.

À UNIPAMPA, por dar oportunidade não só a mim, mas a diversos jovens da cidade e região, que talvez não tivessem oportunidade de realizar uma graduação fora de sua região.

Ao Prof. Dr. Cristiano Galafassi, pelo aceite de orientação neste trabalho e demais trabalhos realizados em conjunto.

Aos professores que com todo o momento que passamos nos últimos anos não deixaram de dar o seu melhor, para fornecer a nós alunos conhecimento com muita qualidade.

A todos os colegas de curso pelo apoio nas atividades, em especial aos colegas da Turma de 2016 (minha turma do curso) e 2017, que sempre estiveram presentes.

“Ouça conselhos e aceite instruções e  
acabará sendo sábio”.

Provérbios 19:20

## LISTA DE SIGLAS

AG- Algoritmos Genéticos

ANA- Agência Nacional de Águas

IA - Inteligência Artificial

MLP - *Multilayer Perceptron*

NDVI - *Normalized Difference Vegetation Index*

NDWI - *Normalized Difference Water Index*

OLI - *Operational Land Imager*

RNA - Rede Neural Artificial

SOM - Mapas Auto Organizáveis

TIRS - *Thermal Infrared Sensor*

## RESUMO

As enchentes são problemas enfrentados por inúmeras pessoas, em diversas localidades. Pode-se definir enchente como uma grande quantidade de água que flui devido ao excesso de chuva. O processo de mensuração e predição de áreas afetadas é um processo muitas vezes custoso, seja de conhecimento, ou hardware para processamento de mapas, através de métodos clássicos de sensoriamento remoto. Sabendo disto, este trabalho traz uma alternativa ao uso dos métodos clássicos, onde é proposto para classificar e identificar as áreas alagadas, um modelo baseado em Rede Neural Artificial (RNA). O uso de Redes Neurais Artificiais hoje em dia está sendo difundido e a grande vantagem no uso de RNAs está em sua grande adaptabilidade. Ao usar um modelo baseado em RNA pode-se, por exemplo, treinar a RNA para detecção de pixels que indiquem água na Bacia Hidrográfica de um determinado rio, conforme proposto neste trabalho, e posteriormente adaptar e treinar este modelo para outras Bacias Hidrográficas. Portanto, ao se utilizar um modelo de RNA baseado em um Multi Layer Perceptron (MLP), que é um modelo especializado em classificação de dados, pode-se concluir que a segmentação de imagens pode ser realizada através deste, mas que há limites. Foram implementados quatro modelos baseados em MLP, os quais receberam treinamento com base em dados extraídos de 7 bandas do sensor OLI do satélite Landsat 8. Após treinamento, os quatro modelos geraram mascaras em preto e branco, indicando quando em preto que o pixel fora classificado como sendo “água”, caso contrário como “não água”.

Palavras-Chave: Aprendizagem de Máquina, Processamento de Imagens, *Backpropagation*, Butuí, Bacia Hidrográfica, *tensorflow*, Sensoriamento Remoto.

## **ABSTRACT**

Floods are problems faced by countless people in different locations. Flooding can be defined as a large amount of water flowing due to excessive rainfall. The process of measuring and predicting verified areas is often a costly process, whether in terms of knowledge or hardware for map processing, using classic methods of remote sensing. Knowing this, this work brings an alternative to the use of classical methods, where it is proposed to classify and identify the flooded areas, a model based on Artificial Neural Network (ANN). The use of Artificial Neural Networks today is being widespread and the great advantage of using ANNs is their great adaptability. By using an ANN-based model, it is possible, for example, to train an ANN to detect pixels that indicate water in the Hydrographic Basin of a certain river, as the standard in this work, and later adapt and train this model for other Hydrographic Basins. Therefore, when using an ANN model based on a Multi-Layer Perceptron (MLP), which is a model specialized in data classification, it can be concluded that image segmentation can be performed through it, but that there are limits. Four models based on MLP were implemented, which received training based on extracted data of 7 bands of the OLI sensor of the Landsat 8 satellite. After training, the four models generated masks in black and white, indicating when in black that the pixel was classified as being "water", otherwise as "not water".

**Keywords:** Machine Learning, Image Processing, Backpropagation, Butuí, Watershed, tensorflow, Remote Sensing.

## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>10</b>
<b>2 JUSTIFICATIVA.....</b>	<b>10</b>
<b>3 OBJETIVOS.....</b>	<b>11</b>
<b>4 REFERENCIAL TEÓRICO .....</b>	<b>11</b>
<b>4.1 BACIA HIDROGRÁFICA DO RIO BUTUÍ(U110).....</b>	<b>11</b>
<b>4.2 LANDSAT 8 SENSOR, BANDAS E COMPOSIÇÕES .....</b>	<b>12</b>
<b>4.3 REDES NEURAIAS ARTIFICIAIS.....</b>	<b>15</b>
<b>4.4 IMPLEMENTAÇÃO DE RNAS.....</b>	<b>18</b>
<b>5 MATERIAL E MÉTODOS .....</b>	<b>18</b>
<b>6 RESULTADOS E DISCUSSÕES.....</b>	<b>20</b>
<b>7 CONCLUSÃO.....</b>	<b>28</b>
<b>REFERÊNCIAS.....</b>	<b>30</b>

## 1 INTRODUÇÃO

As enchentes são problemas enfrentados em diversas cidades do Brasil, isso se dá, pois, várias cidades tiveram sua criação nas áreas mais próximas das margens de rios. Diversas vezes estas margens são áreas alagadas durante as cheias dos rios, o que acaba aumentando a chance de inundação em áreas urbanas nos dias de hoje. Relatório Agência Nacional de Águas (ANA) aponta que, para o período de 2015 a 2017, foram registradas 1.424 ocorrências de alagamentos, enxurradas e enchentes, sendo o Sul do país o mais afetado, com 57% desses eventos.

Como tentativa de identificar os efeitos e comportamentos das enchentes, muitos pesquisadores buscam utilizar técnicas de sensoriamento remoto para coleta de dados e modelagem destes fenômenos, como Azevedo (2019), Freddo et al. (2018), Andrade (2008) e Pinto (2001).

Com o avanço da tecnologia, avançaram também os estudos referentes à Inteligência artificial (IA), onde pode-se, com dados clássicos, realizar treinamentos de Redes Neurais Artificiais (RNA), para identificar o comportamento e padrões em qualquer área que se possa imaginar. A RNA, é uma forma artificial de simulação de uma rede neural biológica, ou seja, possui a estrutura baseada em uma rede biológica, possuindo neurônios e ligações entre eles.

As Redes Neurais Artificiais (RNA) são métodos de *Deep Learning* com capacidade de reconhecimento de padrões complexos ou numerosos e com função de aprendizado dentro da própria rede. As RNA baseiam-se na arquitetura dos neurônios humanos e destinam-se a reproduzir o aprendizado por meio do desenvolvimento de sistemas que aprendem com exemplos de treinamento. (ALVES, 2020)

Diante do exposto, ao combinar as técnicas clássicas de sensoriamento remoto com o uso de redes neurais, pode-se identificar o comportamento de forma confiável e com menor complexidade de hardware.

## 2 JUSTIFICATIVA

O tema é de extrema relevância por causa dos danos econômicos que são causados frequentemente pela ocorrência de enchentes e pela falta de métodos adequados para previsão dos efeitos desses fenômenos. Por se tratar de um método que pode ser utilizado para a facilitação de processos, justifica-se o uso de Redes

Neurais Artificiais, o que facilitará o processamento futuro e até mesmo a adequação do modelo a novas áreas.

### 3 OBJETIVOS

O objetivo geral do presente trabalho é propor modelos de segmentação de imagem baseados em redes neurais artificiais para reconhecer padrões que indiquem água, em uma imagem de satélite, gerada através de técnicas clássicas do sensoriamento remoto, para a área da Bacia Hidrográfica do Rio Butuí.

Como objetivos específicos o presente trabalho visa:

- Criar um modelo baseado em RNA, utilizando *tensorflow* para identificação de padrões que indiquem massas d'água, através de uma imagem.
- Identificar áreas alagadas da Bacia Hidrográfica, através do uso de Rede Neural Artificial, o que pode ajudar na previsão dos efeitos e impactos das enchentes.
- Analisar o comportamento do modelo ao utilizar uma imagem com múltiplas bandas espectrais.

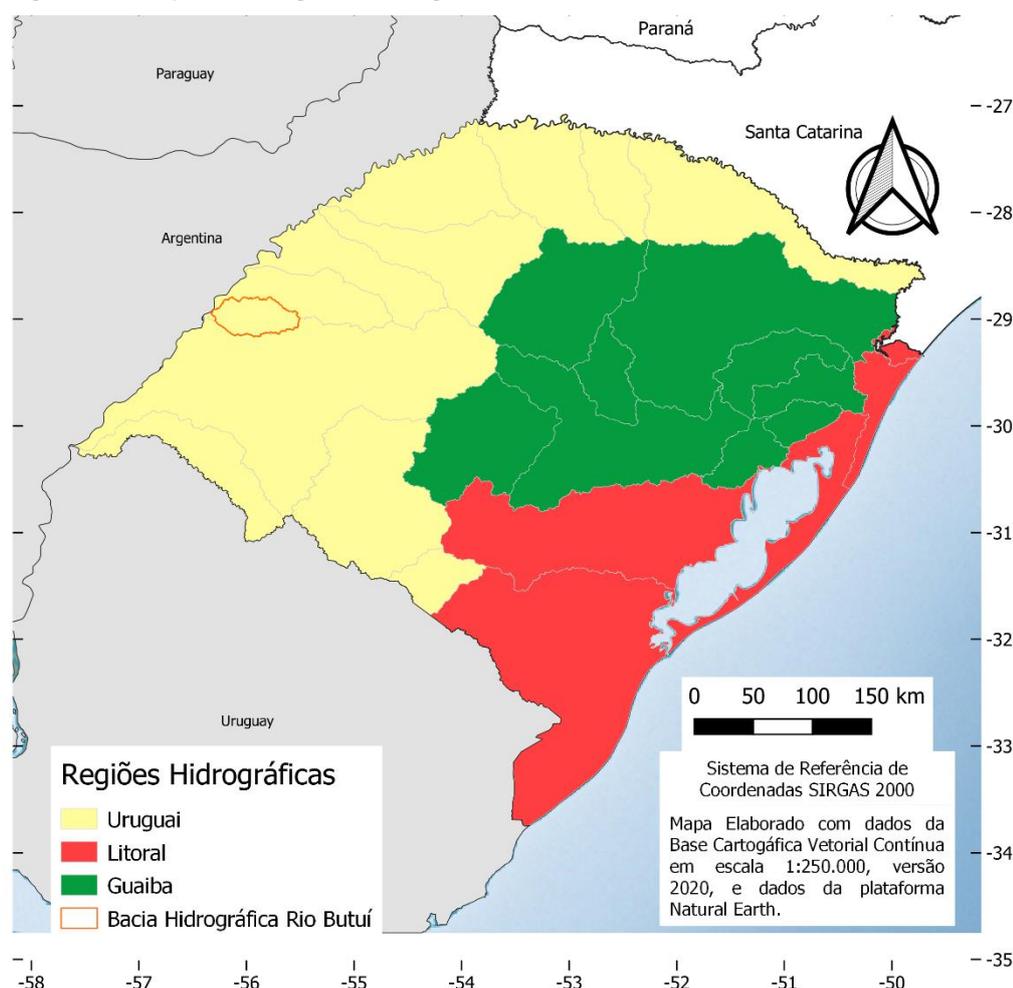
### 4 REFERENCIAL TEÓRICO

Segundo Cervo e Bervian (2002), a ciência pode ser definida como um modo de compreensão do mundo empírico, que envolve um conjunto de procedimentos e a busca por conhecimento científico. Portanto, este trabalho abordará tópicos como Bacia Hidrográfica do Rio Butuí; Satélite Landsat 8 e suas bandas espectrais; Redes Neurais Artificiais; Bibliotecas *Tensorflow*, *Pytorch* e *Scikit-Learn* na linguagem *Phyton*.

#### 4.1 Bacia Hidrográfica do Rio Butuí

Para a realização deste trabalho, a região de estudo será a Bacia Hidrográfica do Rio Butuí, sendo escolhida o uso de uma Bacia Hidrográfica inteira, para que se haja coerência hidrológica nos dados apresentados. Segundo SCHUSTER et al. (2021), o estado do Rio Grande do Sul possui 25 bacias, divididas em três regiões, chamadas regiões de gerenciamento, sendo que a Bacia do Rio Butuí, faz parte da região da bacia hidrográfica do Rio Uruguai, localizada na fronteira Oeste do Rio Grande do Sul, conforme a Figura 1.

Figura 1 – Mapa das Regiões Hidrográficas do Rio Grande do Sul e suas bacias.



Fonte: Base cartográfica vetorial (adaptado pelo autor).

#### 4.2 Landsat 8 Sensor, bandas e composições

O programa *Landsat* teve início na década de 60, em um programa da Agência Espacial Americana, onde a *National Aeronautics and Space Administration* (NASA) gerenciou a maior parte da missão. O satélite *Landsat 8* é um dos satélites mais novos da série *Landsat*, tendo sido lançado em fevereiro de 2013.

Segundo a NASA (2021), o satélite *Landsat 8*, possui a bordo um sensor *Operational Land Imager* (OLI), que coleta imagens da Terra em luz visível, infravermelho próximo, infravermelho de ondas curtas e um sensor *Thermal Infrared Sensor* (TIRS), que mede a temperatura das superfícies terrestres.

O sensor OLI possui 9 bandas, sendo 8 delas com resolução espacial de 30 metros e uma banda pancromática com resolução espacial de 15m. A Tabela 1 mostra as informações disponibilizadas pela NASA para cada uma das bandas.

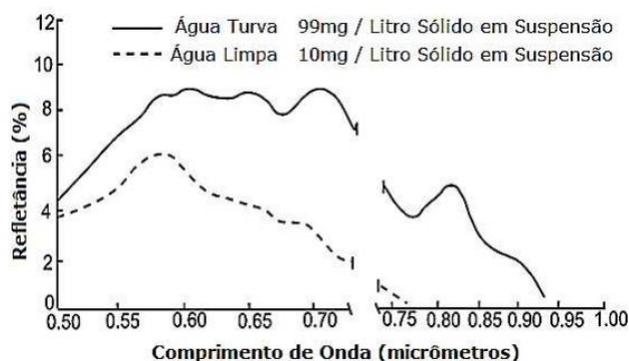
Tabela 1 - Propriedades das Bandas do Sensor OLI do satélite Landsat 8.

Bandas Espectrais	Resolução Espectral	Resolução Espacial	Resolução Temporal	Área Imageada	Resolução Radiométrica
(B1) Azul Costeiro	0.43 - 0.45 $\mu$ m	30m	16 dias	170 x 183 km	16 bits
(B2) Azul	0.45 - 0.51 $\mu$ m				
(B3) Verde	0.53 - 0.59 $\mu$ m				
(B4) Vermelho	0.64 - 0.67 $\mu$ m	30m	16 dias	170 x 183 km	16 bits
(B5) Infravermelho Próximo	0.85 - 0.88 $\mu$ m				
(B6) Infravermelho Médio	1.57 - 1.65 $\mu$ m				
(B7) Infravermelho Médio	2.11 - 2.29 $\mu$ m				
(B8) Pancromática	0.50 - 0.68 $\mu$ m	15m			
(B9) Cirrus	1.36 - 1.38 $\mu$ m	30m			

Fonte: ENGESAT (2013) (Adaptado pelo Autor).

Deve-se ressaltar, que cada uma das bandas do satélite realiza medições da energia refletida pelos objetos em diferentes comprimentos de ondas do espectro eletromagnético, conforme observado na coluna Resolução Espectral da Tabela 1. Sabendo disto, as bandas 5, 6 e 7, do sensor OLI do Satélite Landsat-8, por se tratarem de bandas do infravermelho, possuem valores medidos próximos a 0, ao imagear corpos d'água, pois como apresentado na Figura 2, a água possui refletância quase nula quando é imageada por bandas com Resolução Espectral a partir de 0,75 micrômetros.

Figura 2 – Características Espectrais de águas segundo o comprimento de onda.



Fonte: Adaptado de Bartolucci et al., 1977.

Quando combinadas, as bandas formam composições diferentes, também com diferentes finalidades. Ao combinar as bandas do Azul (B2), Verde (B3) e Vermelho (B4), pode-se gerar uma composição de cores naturais. Porém, há ainda a possibilidade de utilizar as bandas espectrais do satélite, com a colaboração de índices que podem destacar determinados elementos de interesse, como por exemplo o *Normalized Difference Vegetation Index* (NDVI), proposto por Rouse et al. (1974) e o *Normalized Difference Water Index* (NDWI), desenvolvido por Gao (1996).

O NDVI é o índice que mede a reflectância das folhas, destacando quanto mais verde for, já o NDWI, diminui a refletância da vegetação e do solo e aumenta a reflectância da água, dando um realce na visualização, sendo de fácil identificação na imagem.

O NDWI pode ser calculado através da equação 1, utilizando as bandas B3 (Verde) e B5 (Infravermelho Próximo, NIR).

$$NDWI = \frac{(VERDE - NIR)}{(VERDE + NIR)} \quad (1)$$

### 4.3 Redes Neurais Artificiais

De acordo com Haykin (2001), uma rede neural artificial é como um processador maciçamente e paralelamente distribuído de unidades de processamento simples com a propensão natural de armazenar informações e conhecimentos experimentais de forma que estejam disponíveis para o uso.

Atualmente, RNAs possuem 6 principais propriedades, segundo Haykin (2001) sendo elas:

- Não linearidade, que discorre de a rede ter a capacidade de resolver problemas não lineares;
- Mapeamento de entrada e saída da rede, que consiste no método que a rede se forma, sendo baseada em exemplos ou dados de treinamento;
- Adaptabilidade, uma rede criada para uma determinada finalidade, e para uma determinada população, poderá ser treinada, desde que com dados suficientes, para utilização em uma nova população;
- Resposta a evidências, onde uma rede neural aprende um padrão, sendo capaz de classificar objetos através deste, e ainda calcular o grau de confiança desta classificação;
- Informação contextual, que se refere ao conhecimento fica armazenado na própria rede, onde a mesma é capaz de entender o contexto de uma amostra e determinar os padrões em que deverá trabalhar;
- Tolerância a falhas, onde quando implementadas em um hardware se um ou mais neurônios falharem, a mesma não deixará de funcionar e se adapta à sua nova realidade.

Cybenko (1989) apontou que uma RNA baseada em um *Multi Layer Perceptron* (MLP), com apenas três camadas pode resolver qualquer problema, essas três camadas são: a camada de entrada, a qual possui o tipo de neurônio chamado neurônio de entrada, camada oculta, que possui os neurônios ocultos, onde são tratadas as informações da camada de entrada, e a camada de saída com os neurônios de saída.

Existe um tipo de neurônio muito utilizado atualmente, que é chamado de *perceptron*, que pode ser definido como um modelo matemático de um neurônio biológico. Em neurônios biológicos, os neurônios recebem informações através de impulsos elétricos que saem dos axônios de outros neurônios e entram pelo dendrito.

No *perceptron*, estes impulsos são representados por valores numéricos, e assim como no neurônio biológico as sinapses são diferenciadas pela quantidade de energia liberada, no *perceptron* esses valores são simulados ao multiplicar cada valor recebido por um peso em cada uma das ligações.

Existem algumas regras básicas para cada tipo de neurônio, porém não são aplicáveis a todos os modelos. De forma genérica, estas regras básicas são:

- Neurônios de entrada, recebem as informações e só podem enviá-las a neurônios da camada de saída ou de uma camada oculta;
- Neurônios de uma camada oculta, só poderão enviar informações para a próxima camada oculta ou camada de saída.
- Neurônios de uma camada, são totalmente ligados à próxima camada, ou seja, cada neurônio de uma camada é ligado a todos os da próxima camada.

Ao receber estas informações, o neurônio as processa, e pode ser ativado quando o resultado de uma função de ativação for comparado a um limiar previamente estabelecido. Essa função de ativação varia, e podem ser escolhidas para determinados tipos de dados de acordo com o comportamento dos mesmos.

A função de ativação mais utilizada, para redes neurais que possuam valores positivos como saída, é a função sigmoide, onde tem como principal vantagem, a sua não-linearidade. Porém existem diversas funções de ativação que podem ser utilizadas em RNAs, como por exemplo *Binary Step Function*, ou Função de Etapa Binária, que classifica dados em apenas uma classe, de forma binária, sendo caso ativado tendo saída  $f(x) = 1$ , caso contrário,  $f(x) = 0$ . Ainda pode-se encontrar as funções Linear, ReLU, *Softmax*, entre outras que podem ser encontradas no *Tensorflow* (*TENSORFLOW*, 2015), conforme será mostrado na seção 4.4.

Existem diversas arquiteturas de rede neural, algumas delas são mais utilizadas, como as redes neurais convolutivas (ConvNet), que são redes neurais de Aprendizagem Profunda, que podem receber imagens na camada de entrada e atribuir pesos e importância a cada um dos pixels ou objetos desta imagem. A ConvNet pode diferenciar uns dos outros, sendo necessário um menor pré-processamento para o

tratamento deste dado, pois a ConvNet, aprende os filtros que são utilizados para classificação.

Diferente da ConvNet, há ainda as redes Neurais Recorrentes, que ainda possuem dimensão temporal, e diferente do que normalmente é visto, as redes neurais recorrentes, não levam em consideração apenas os valores de entrada, mas também o que foi aprendido em tempos anteriores. Sendo assim, redes neurais recorrentes possuem duas fontes de alimentação, presente e passado.

Problemas não linearmente separáveis (aqueles quais quando dispostos no eixo cartesiano bidimensional, não podem ser separados em duas classes por uma reta) são normalmente resolvidos por redes multicamadas, uma arquitetura muito utilizada é a *Multilayer Perceptron*. A MLP possui uma comunicação densa entre os neurônios, portanto necessita de um maior poder computacional para que seja viável seu uso, sendo que em cada conexão entre os neurônios possuem um peso específico.

Outra arquitetura possível de RNA, são os Mapas Auto Organizáveis, ou SOM, propostos por Malsburg (1973) e Grossberg (1987), que é basicamente baseado no córtex cerebral, onde cada neurônio possui valor próximo ao seu neurônio vizinho, e são redes neurais com aprendizagem não supervisionada. Os SOMs possuem camadas competitivas bidimensionais ou até mesmo unidimensionais.

O método consiste em duas etapas, a primeira onde são inseridos os valores da uma amostra de treinamento, e observado os resultados na camada de saída da rede, sendo esta a chamada etapa de propagação. Após a primeira etapa, entra em ação a segunda etapa, a etapa de retropropagação, onde de acordo com o resultado do erro obtido através dos resultados da etapa anterior, são corrigidos os parâmetros, reajustando os valores de cada peso e dos *bias*.

Há ainda outros métodos, como por exemplo os algoritmos genéticos, que partem de um conjunto inicial de soluções e através de operadores genéticos como seleção, cruzamento e mutação corrigem o conjunto solução, até que uma das soluções esteja segundo a tolerância, ou seja, apresente erro menor que uma tolerância exigida ou até que o algoritmo ultrapasse o número de iterações, este modelo foi proposto por John Henry Holland, para representação uma classe particular de algoritmos evolutivos (HOLLAND, 1975).

#### 4.4 Implementação de RNAs

Atualmente, as redes neurais artificiais podem ser desenvolvidas em diversas linguagens de programação. Existem bibliotecas, as quais trazem funções pré carregadas, para assim facilitar na implementação das RNAs.

A plataforma *Tensorflow*, foi criada pela equipe do Google Brain, possuindo código aberto e é desenvolvido para as linguagens *Python* e *JavaScript*, auxiliando no desenvolvimento de soluções com aprendizagem de máquina. Com ela, é possível agilizar e facilitar o processo de obtenção de dados, treinar modelos, realizar previsões e refinar resultados futuros (*Tensorflow*, 2019).

No *Tensorflow*, existe a possibilidade de adicionar funções através de novas bibliotecas, desta forma a biblioteca Keras. A biblioteca Keras é uma biblioteca de aprendizagem profunda, com desenvolvimento em Python, executada na plataforma de aprendizado de máquina *Tensorflow*. O foco desta biblioteca está em permitir a experimentação rápida, de um modo que permita a confluência do resultado de uma forma mais rápida.

Assim como o *Tensorflow*, o *Pytorch* é uma biblioteca de tensores otimizada para aprendizado profundo usando GPUs e CPUs, que está disponível para as linguagens C++, Java e *Python*.

## 5 MATERIAL E MÉTODOS

Sabe-se que a bacia do rio Butuí faz parte da Região Hidrográfica do Uruguai, sendo assim, pode-se verificar o histórico de enchentes que ocorreram na Região Hidrográfica para que seja possível a definição de um cenário.

Righi (2010), destaca em seu artigo os principais eventos ocorridos entre 1980 e 2005, no Rio Uruguai, destacando o ano de 1983, onde a cheia atingiu diversos municípios que margeiam o Rio, tendo como prováveis fatores o acúmulo de chuvas em toda a bacia hidrográfica.

Segundo Silveira (2019), o volume de precipitações ocorrido em maio de 2017 no oeste e norte do RS, causou transtornos para a população em decorrência da elevação do nível dos rios, ocorrendo enchentes.

Tendo como base este cenário, foram utilizadas imagens do satélite Landsat 8, órbita 224, ponto 080 (cena 224/080), capturadas no dia 11 de junho de 2017. Foi realizado o download de 7 das 9 bandas espectrais disponíveis do sensor OLI, do satélite, sendo das bandas 1 a 7.

Estas imagens foram obtidas no site *LandViewer*, site este gerenciado pela *EOS Data Analytics* (EOS, 2014), que é uma das fornecedoras de imagens de satélite processadas ou não, possuindo imagens gratuitas e pagas.

As imagens utilizadas, do Satélite Landsat 8, capturadas a partir do sensor OLI, possuem 30m de resolução espacial, e estas foram processadas inicialmente através do software QGIS. Foi realizado o procedimento de criação de uma composição colorida, RGB, uma composição contendo as bandas de cores naturais simuladas, utilizando as bandas 6, 5 e 4, uma composição com as sete bandas espectrais e também um mapa de NDWI.

Destas imagens, ainda foram desenvolvidos, para fins de treinamento da rede neural, recortes da imagem e máscaras nos pixels destes recortes onde sabe-se ser composto por água, ou não.

Utilizando o Google Colaboratory (Colab), foi desenvolvido um modelo baseado em rede neural, através das bibliotecas *tensorflow*, *Sklearn* e *keras*. Esse modelo acessou o banco de dados com as composições e NDWI, os quais possuem os dados de treinamento, as quais foram convertidas em vetores, contendo os valores de cada pixel e sua classificação.

Foram então desenvolvidos os modelos visando a simplificação da rede, para que com uma menor sobrecarga, o modelo atingisse uma precisão razoável, sem que fosse necessária uma métrica para dimensionamento do modelo. O modelo de maior complexidade é um MLP que contém uma camada de entrada com 3 neurônios, seguido de oito camadas ocultas, contendo 8, 16, 32, 64, 128, 64, 32 e 8 neurônios respectivamente, seguido de uma camada de saída com apenas 1 neurônio. Este modelo foi utilizado para processar os dados contendo os valores dos pixels nas bandas 4, 3 e 2 (composição colorida RGB).

O modelo recebeu em sua camada de entrada, os dados dos pixels, para cada uma das camadas, portanto, no modelo citado acima, o número de neurônios na camada de entrada é igual ao número de bandas utilizadas na composição.

Após o treinamento então, ao se analisar a matriz de confusão gerada pelo método, tendo os modelos atingindo uma acurácia aceitável, o modelo classificou o vetor de pixels da entrada e gerou uma saída equivalente de valores zeros e uns correspondendo aos pixels de entrada. Esse vetor de pixels resultantes irá compor uma máscara que irá segmentar “água” e “não água” na imagem.

A matriz de confusão é uma tabela na qual, com sua construção é possível extrair métricas de avaliação de modelos, onde a mesma contém a quantidade de dados classificados nas diferentes classes, conforme Quadro 1, tendo como uma das principais e mais utilizadas métricas de análise a acurácia.

Quadro 1 – Modelo de Matriz de Confusão.

		Valor Predito	
		Positivo	Negativo
Valor Real	Positivo	Verdadeiro Positivo	Falso Negativo
	Negativo	Falso Positivo	Verdadeiro Negativo

Fonte: Autor.

A acurácia é uma métrica que pode ser calculada levando em consideração a soma de Verdadeiros Positivos (VP), em que nos modelos desenvolvidos neste trabalho, são dados preditos como “água”, e que correspondem aos dados classificados previamente como “água”, a taxa de Verdadeiros Negativos (VN), os quais são dados preditos como “não água”, que correspondem aos assim classificados previamente, divididos pelo total de dados analisados ( $n$ ), conforme exposto na equação 2.

$$acurácia = \frac{VP+VN}{n} \quad (2)$$

Por fim, como validação, a máscara gerada pelo modelo, foi comparada em relação ao mapa do índice NDWI gerado no software QGIS.

## 6 RESULTADOS E DISCUSSÕES

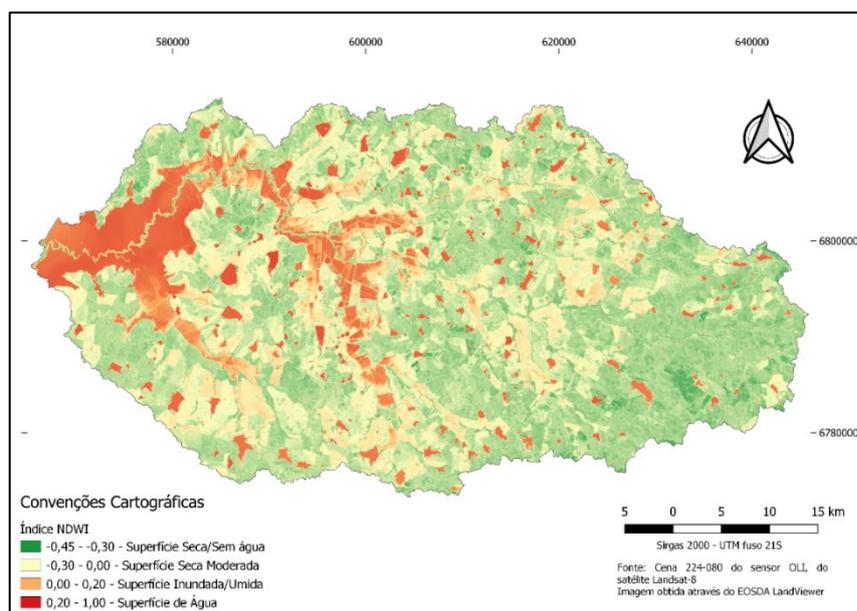
Os dados de treinamento fornecidos aos modelos desenvolvidos, foram classificados previamente de forma manual, no *software* QGIS, estes dados podem conter um erro sistemático, devido esta classificação manual, mesmo que tenha se tido o cuidado de minimizar a ocorrência deste.

Os modelos foram criados em etapas diferentes, sendo inicialmente criado o modelo baseado em MLP, para dados que continham informações de todas as bandas utilizadas (banco de dados completo); em uma segunda etapa foi desenvolvido o modelo para aprendizagem com as bandas 4, 3 e 2.

Após desenvolvidos os modelos citados, em uma terceira etapa foi desenvolvido o modelo baseado em MLP, para aprendizagem e treinamento com os dados dos pixels das camadas 6, 5 e 4, e por fim em uma quarta etapa, o modelo a ser treinado com os dados dos pixels de um índice NDWI calculado no software QGIS.

Ao final do desenvolvimento dos modelos, os mesmos receberam a imagem completa da Bacia Hidrográfica do Rio Butuí, a qual foi classificada pelos modelos, para que as mascarás geradas na classificação sejam comparadas ao mapa do índice NDWI conforme Figura 3.

Figura 3 – Mapa NDWI gerado no Software QGIS da área da Bacia Hidrográfica do Rio Butuí com imagens do sensor OLI do satélite Landsat-8



Fonte: adaptado pelo autor.

O modelo desenvolvido, baseado em um MLP, aplicado ao banco de dados completo, ou seja, aquele cujos dados são os valores individuais dos pixels para as 7 bandas espectrais disponíveis na composição das bandas, inicialmente, era composto de uma camada de entrada, com 7 neurônios, uma camada oculta, com 16 neurônios, seguido de uma camada de saída com um neurônio. Porém, durante o processo de treinamento, observou-se que a acurácia do método atingia 100%, o que normalmente caracterizaria um *overfitting*.

O *overfitting* é um supertreinamento dos dados fornecidos, podendo indicar que a rede não seria capaz de generalizar adequadamente os dados, gerando inconsistências quando apresentada a dados desconhecidos (não treinados).

Portanto, o modelo necessitou de ajustes, passando a ter uma estrutura composta por 7 neurônios na camada de entrada e 1 neurônio na camada de saída, sem camadas ocultas. Mesmo assim, o modelo obteve uma acurácia no treinamento de 99,9966%, apresentando uma matriz de confusão conforme visto na Quadro 2.

Quadro 2- Matriz de confusão, de um modelo baseado em MLP, para dados dos pixels de uma composição colorida com 7 bandas.

		Valor Predito	
		Positivo	Negativo
Valor Real	Positivo	56166	6
	Negativo	0	120524

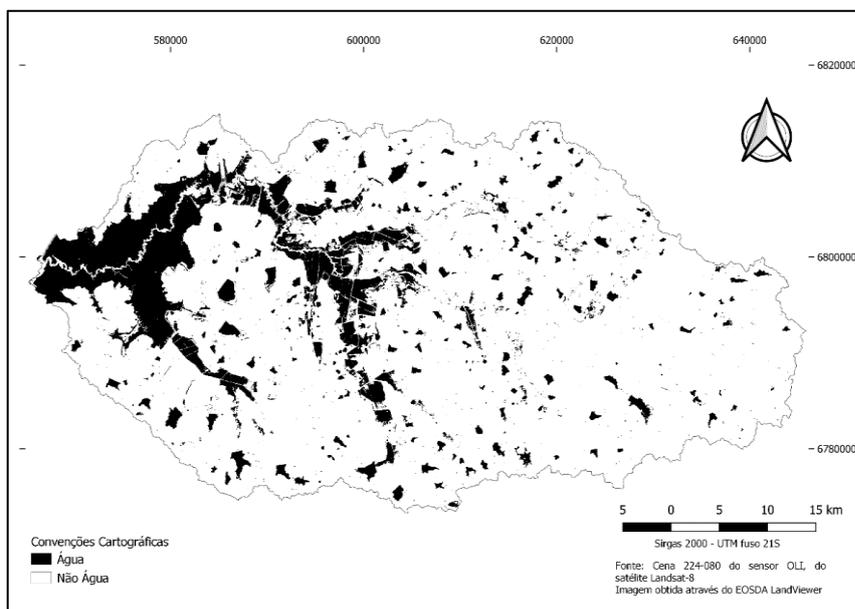
Fonte: Autor.

Conforme pode-se analisar na Quadro 2, o modelo, realizou a classificação dos dados fornecidos com acurácia de 99,9966%, isto se deve, por ao adicionarmos todas as bandas, em três delas, nas bandas 5, 6 e 7, a água possui refletância baixa, conforme podemos ver na Figura 2 disponível na seção 4.2.

Como as bandas do sensor OLI na faixa do infravermelho possuem uma resolução espectral com comprimento de onda entre 0,85 e 2.29 $\mu$ m, a água, quando considerada limpa, absorve toda a energia, gerando assim um retorno nulo. Portanto ao visualizar a imagem gerada, a água tem coloração totalmente preta, facilitando assim ao modelo desenvolvido a sua identificação.

Com o modelo já treinado, ao carregar a imagem de satélite com as 7 bandas espectrais disponíveis, a rede neural realizou a predição para cada pixel da imagem, gerando como produto final, uma máscara com as cores preto para “água” e branco para não água, conforme pode-se observar na Figura 4.

Figura 4 – Máscara de classificação gerada por uma rede neural com dados das 7 bandas do sensor OLI do satélite Landsat-8 da área da Bacia Hidrográfica do Rio Butuí.



Fonte: adaptado pelo autor.

Tendo gerado os resultados para o banco de dados completo, deu-se início ao desenvolvimento do modelo responsável pela análise das informações disponíveis nas bandas 4,3,2.

Deve-se lembrar que a aprendizagem de dados dos pixels referentes as camadas 4, 3 e 2, ou seja, um banco de dados de uma composição colorida em cores naturais (RGB), possui uma maior complexidade, pois sabe-se que há uma sobreposição de cores grande. Dependendo do contexto, a mesma cor pode significar tanto “água” (Positivo), como “não água” (Negativo).

Portanto por haver uma complexidade muito maior, o modelo desenvolvido, que pode ser considerado grande, é composto por uma camada de entrada com 3 neurônios (por se tratarem de dados de três bandas), seguido de oito camadas ocultas, contendo 8, 16, 32, 64, 128, 64, 32 e 8 neurônios respectivamente, seguido de uma camada de saída com apenas 1 neurônio.

Mesmo com uma rede mais densa, com múltiplas camadas ocultas, o modelo teve dificuldade no aprendizado das classes. Isso pode ser observado em diferentes testes onde algumas vezes o modelo apresentou uma acurácia inferior a 70% e classificando todos os dados como sendo de uma só classe.

Em outras palavras, o modelo não conseguiu aprender as características dos dados de treinamento. No melhor caso, foi possível observar uma acurácia de 86,25%, os dados utilizados para gerar a acurácia podem ser observados na matriz de

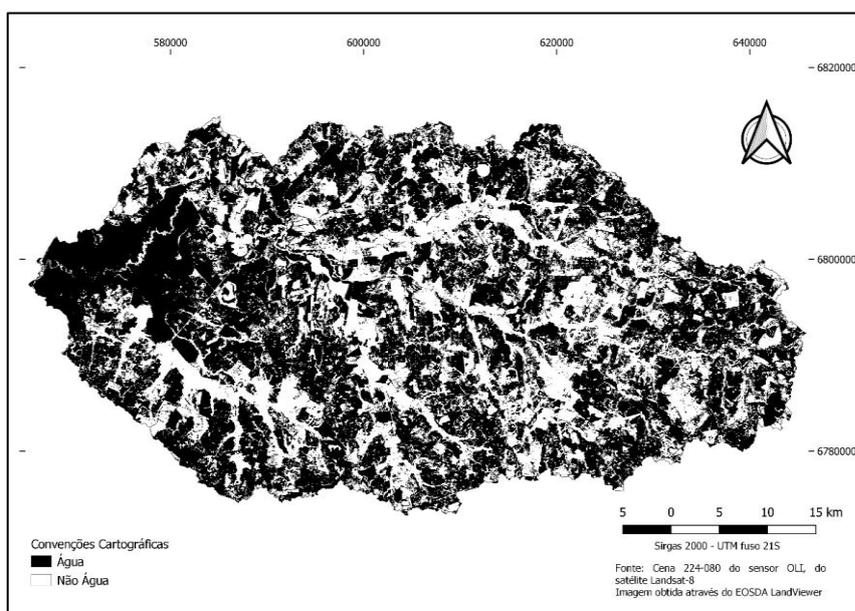
confusão da Quadro 3, máscara gerada pelo modelo na Figura 5 e composição colorida disponível na Figura 6.

Quadro 3 - Matriz de confusão, de um modelo baseado em MLP, para dados dos pixels de uma composição colorida de bandas 4, 3, 2.

		Valor Predito	
		Positivo	Negativo
Valor Real	Positivo	41848	14285
	Negativo	9999	110564

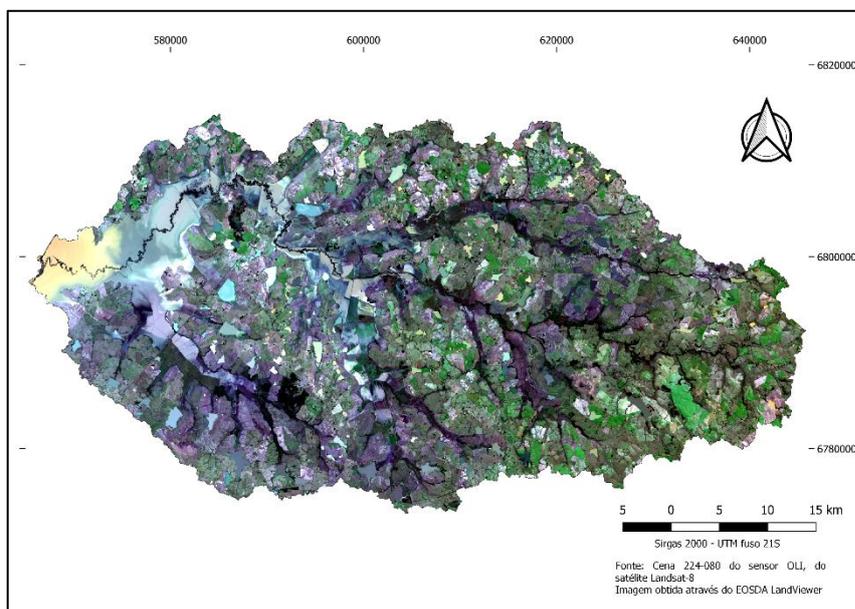
Fonte: Autor.

Figura 5 – Máscara de classificação gerada por uma rede neural com dados de uma composição colorida de bandas 4, 3, 2, do sensor OLI do satélite Landsat-8 da área da Bacia Hidrográfica do Rio Butuí



Fonte: adaptado pelo autor.

Figura 6 – Composição colorida de bandas 4, 3, 2, do sensor OLI do satélite Landsat-8 da área da Bacia Hidrográfica do Rio Butuí



Fonte: adaptado pelo autor.

Analisando o banco de dados e o resultado da classificação, conforme Figura 5, observou-se que visualmente alguns dados possuem valores similares, com pouca ou nenhuma variação. Em outras palavras, o pixel possui os mesmos valores para as bandas R, G e B.

Uma vez que estamos trabalhando com redes projetadas para classificação de dados, e não especificamente imagens, pode-se considerar que a rede a rede obteve uma acurácia aceitável. Sendo assim, para que tivéssemos uma acurácia melhor, utilizando as bandas 4, 3 e 2, seria necessário testar um tipo de rede que busca trabalhar com imagens, por exemplo, as redes neurais convolutivas.

Na terceira etapa de desenvolvimento e experimentação, ao desenvolver um modelo baseado em MLP, para as bandas 6, 5, 4, com 3 camadas, sendo a primeira camada de entrada, com 3 neurônios, seguida de uma camada oculta com 8 neurônios seguida de uma camada de saída com apenas um neurônio, onde será gerada a predição da classificação.

O modelo obteve uma precisão consideravelmente alta, com uma acurácia de 99,9949%, conforme matriz de confusão da Quadro 4 gerando uma máscara de classificação conforme Figura 7, que pode ser comparada a composição colorida 6,5,4 disponível na Figura 8.

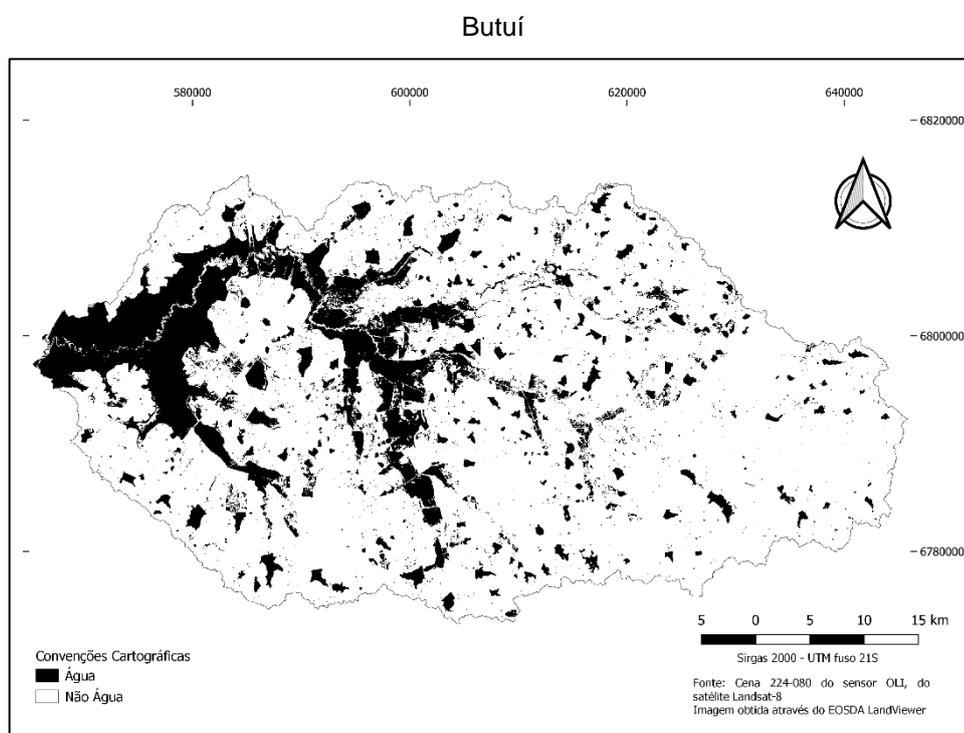
Quadro 4 - Matriz de confusão, de um modelo baseado em MLP, para dados dos pixels de uma composição colorida de bandas 6, 5, 4.

		Valor Predito	
		Positivo	Negativo
Valor Real	Positivo	56286	7
	Negativo	2	120401

Fonte: Autor.

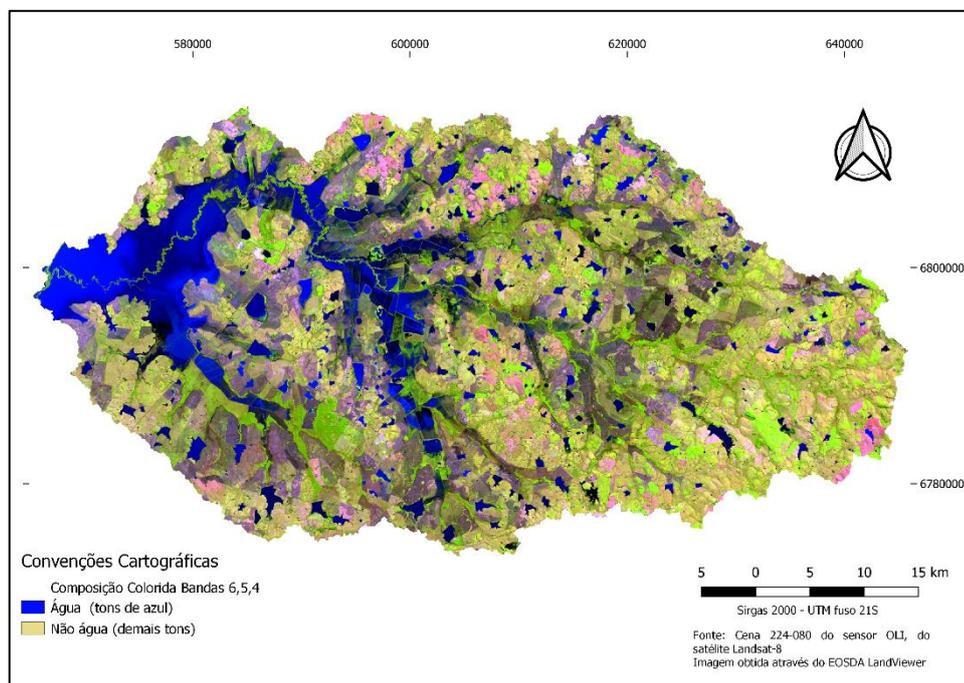
A acurácia atingida pelo modelo treinado com as bandas 6,5,4, se dá, pois assim como ocorre com o banco de dados analisado com as 7, o banco de dados com as bandas 6, 5, 4, possui as bandas 6 e 5. Lembrando que estas bandas são do espectro do infravermelho, conforme visto na Figura 2 (seção 4.2). Portanto as bandas 6 e 5 são bandas onde a água possui uma menor reflectância, facilitando na identificação dos corpos d'água, pois os dados se tornam disjuntos para as classes "água" (Positivo) e "não água" (Negativo).

Figura 7 – Máscara de classificação gerada por uma rede neural com dados de uma composição colorida de bandas 6, 5, 4, do sensor OLI do satélite Landsat-8 da área da Bacia Hidrográfica do Rio



Fonte: adaptado pelo autor.

Figura 8 – Composição colorida de bandas 6, 5, 4, do sensor OLI do satélite Landsat-8 da área da Bacia Hidrográfica do Rio Butuí



Fonte: adaptado pelo autor.

Por fim, na quarta etapa de desenvolvimento e experimentos, foi desenvolvido o modelo para aprendizagem com os dados fornecidos pelo índice NDWI. Lembrando que pôr o NDWI ser um valor obtido através de um cálculo entre camadas, seus dados possuem apenas 1 valor.

O modelo foi desenvolvido contendo uma camada de entrada com 1 neurônio, pois os dados fornecidos pelo banco de dados, são de apenas um valor resultante da operação com camadas no software QGIS, seguida a esta camada possuem três camadas ocultas, com 16 ,32 e 64 neurônios respectivamente, seguidas de uma camada de saída com 1 neurônio.

O modelo obteve acurácia de 98,8381%, a qual foi calculada através da equação 01. Deve-se lembrar que fora realizado no software QGIS, uma operação com as camadas para obtenção do valor do índice NDWI, portanto já se considera um conhecimento implícito em sua classificação.

Quadro 5 - Matriz de confusão, de um modelo baseado em MLP, para dados dos pixels de uma composição com dados NDWI.

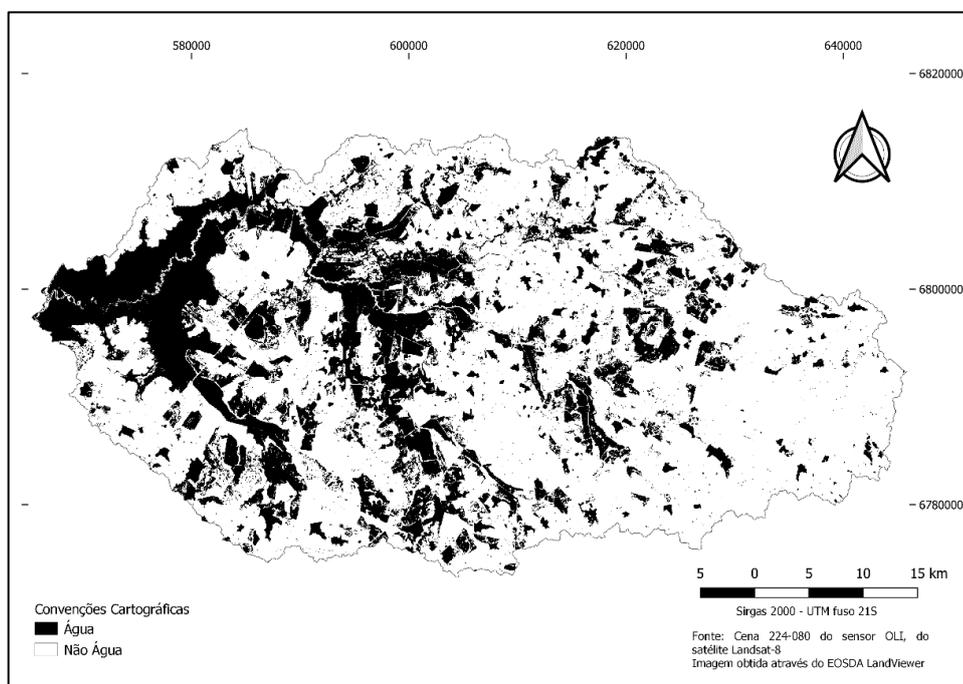
		Valor Predito	
		Positivo	Negativo
Valor Real	Positivo	56216	0
	Negativo	2053	118427

Fonte: Autor.

É importante lembrar que os dados do índice NDWI variam de -1 a 1, onde quanto menor o valor (mais próximo a -1) mais seco estará a região classificada e quanto mais próximo à 1, maior será o índice de unidade.

Portanto no modelo desenvolvido para classificação dos dados do índice NDWI, todos os dados maiores o modelo classificou como “água” (Positivo), e modelos menores ou iguais a zero, forem classificados como “não água” (Negativo), gerando assim a máscara conforme mapa da Figura 9, e mapa do índice NDWI conforme Figura 3.

Figura 9 – Máscara de classificação gerada por uma rede neural com dados de treinamento do índice NDWI, do sensor OLI do satélite Landsat-8 da área da Bacia Hidrográfica do Rio Butuí



Fonte: adaptado pelo autor.

## 7 CONCLUSÃO

Este trabalho teve como objetivo desenvolver um modelo baseado em RNA para segmentação de imagens, de forma que o modelo aprendesse a identificar pixels de uma imagem de satélite que indicassem “água”.

Percebeu-se que os modelos desenvolvidos, utilizando os modelos em MLP, quatro ao todo, quando aplicados às diferentes composições coloridas, obtiveram boa acurácia. Acurácia esta que pode ser atingida tanto no treinamento quanto ao compararmos as máscaras geradas com o mapa do índice NDWI (gerado no software QGIS).

Ao avaliar o comportamento treinando o método utilizando uma imagem com todas as bandas disponibilizadas pelo sensor OLI do satélite Landsat-8, obteve-se uma acurácia de 99,9966%. O método gerou uma máscara que possui classificação muito próxima aos dados classificados através do índice NDWI, da imagem processada no software QGIS.

Pode-se concluir a partir dos resultados e máscaras geradas, que mesmo utilizando uma rede neural especializada em classificar dados para realizar a segmentação de uma imagem, há a possibilidade de se atingir resultados com uma boa acurácia. Portanto conclui-se que se pode utilizar este modelo de rede neural para identificação de água em imagens de satélite, desde que o modelo seja devidamente testado e treinado para as bases de dados a serem trabalhadas.

Deve-se destacar que o modelo que fora aplicado à composição colorida composta pelas bandas 4,3,2, que forma a composição RGB natural, foi o modelo que atingiu menor acurácia, devido à complexidade dos dados da composição colorida, onde por diversas vezes, cores iguais ou até mesmo próximas, dependendo do contexto podem significar tanto “água” (Positivo), como “não água” (Negativo) conforme dados disponíveis na Quadro 4 e conforme máscara gerada, disponível na Figura 6.

Para que haja uma solução o problema encontrado para os dados das bandas 4,3,2, deve-se utilizar outro tipo de rede especializado em segmentação de imagens. Pode-se, portanto, utilizar um modelo especializado em segmentação de imagens como Redes Neurais Convolutivas, UNet, YOLO, etc., onde estas irão analisar não somente o “dado bruto” do pixel, como também o contexto em que este pixel está inserido na imagem, podendo assim gerar um melhor resultado.

## REFERÊNCIAS

ALBUQUERQUE, E. M. de, Andrade, S. C. de P., Morais, H. F. de, Diniz, J. M. T., & Santos, C. A. C. dos. (2014). **Análise do comportamento do NDVI e NDWI sob diferentes intensidades pluviométricas no município de Sousa-PB**. Revista Estudos Geoambientais, 1(1). Recuperado de Disponível em: <<https://periodicos.ufpb.br/index.php/geo/article/view/17986>>. Acesso em: 22 de Junho de 2022.

ALVES, Priscila Mello. **Inteligência Artificial e Redes Neurais**. 2020. Disponível em: <<https://www.ipea.gov.br/cts/pt/central-de-conteudo/artigos/artigos/106-inteligencia-artificial-e-redes-neurais>>. Acesso em: 22 de Junho de 2022.

ANDRADE, ISMAR RENAN ALVES DE. **O uso de técnicas de sensoriamento remoto na identificação de formas na planície de inundação do alto rio Paraná, região de Porto Rico, MS/PR**. Orientador: Edvard Elias de Souza Filho. 2008. 71p. Dissertação de Mestrado (Programa de Pós-Graduação em Geografia UEM) - Universidade Estadual de Maringá, Maringá, 2008. Disponível em: <<http://repositorio.uem.br:8080/jspui/handle/1/2844>>. Acesso em: 22 de Junho de 2022.

AZEVEDO, Marcela Nishina de. **Determinação da área efetivamente inundada durante o evento extremo de 2017, no município de Itaqui, RS, através de técnicas de sensoriamento remoto**. Orientador: Sidnei Luís Bohn Gass. 2019. 34p. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Cartográfica e de Agrimensura) - Universidade Federal do Pampa, Itaqui, 2019. Disponível em: <<https://repositorio.unipampa.edu.br/jspui/handle/rii/6819>>. Acesso em: 22 de Junho de 2022.

BARTOLUCCI, L. A.; ROBINSON, B.F.; SILVA, L.F. **Field measurements of the spectral response of natural waters**. Photogrammetric Engineering and Remote Sensing, West Lafayette, v. 43, n. 5, p. 595-598, May. 1977.

CYBENKO, G. **Approximation by superpositions of a sigmoidal function**. Math. Control Signal Systems 2, 303–314 (1989). Disponível em: <<https://doi.org/10.1007/BF02551274>>. Acesso em: 22 de Junho de 2022.

DATA SCIENCE ACADEMY. Deep Learning Book, 2022. Disponível em: <<https://www.deeplearningbook.com.br/>>. Acesso em: 22 de Junho de 2022.

ENGESAT. **"Landsat - 8"**. ENGESAT, 2013. Disponível em: <[http://www.engesat.com.br/imagem-de-satelite/Landsat 8/](http://www.engesat.com.br/imagem-de-satelite/Landsat%208/)>. Acesso em: 22 de Junho de 2022.

FREDDO, RICARDO; AMORIM, NATÁLIA; VARGAS, ROGÉRIO; SILVA, ROBERT; E LOPES, ALEXANDRE. **"Utilização De Sensoriamento Remoto Como Ferramenta De Apoio Para Detecção De Áreas De Risco"** COBRAC - Congresso de Cadastro Multifinalitário e Gestão Territorial (2018). Acesso em: 19 de Junho de 2022.

GAO, B.-C. NDWI- **A Normalized difference water index for remote sensing of vegetation liquid water from space**. Remote Sensing of Environment, v. 58, p.257-266, 1996.

GROSSBERG, S. (1987). **Competitive learning: From interactive activation to adaptive resonance**. Cognitive Science, 11, 23-63. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1551-6708.1987.tb00862.x>> Acesso em: 22 de Junho de 2022.

HAYKIN, Simon. **Redes Neurais: Princípios e prática**. Porto Alegre RS:Bookman, 2001.

HERNANDEZ, L. C.; SZIGETHY, L. **Controle de Enchentes- Exemplos do uso da tecnologia e inovação para o controle de enchentes**. IPEA, 2020. Disponível em: <[https://www.ipea.gov.br/cts/pt/central-de-conteudo/artigos/artigos/231-controle-deenchentes#\\_ftnref5](https://www.ipea.gov.br/cts/pt/central-de-conteudo/artigos/artigos/231-controle-deenchentes#_ftnref5)>. Acesso em: 25 jun. 2022

HOLLAND, John Henry. **Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence**. [S. l.]: University of Michigan Press, 1975. 183 p. ISBN 0472084607, 9780472084609. Disponível em: <<https://mitpress.mit.edu/books/adaptation-natural-and-artificial-systems>>

MATTIUZI, Camila Dalla Porta. **Relatório de Atividades Departamento de Hidrologia: Sistema de Alerta Hidrológico da Bacia do Rio Uruguai: relatório técnico de operação 2021**. / Camila Dalla Porta Mattiuzi; Artur José Soares Matos. – Porto Alegre: CPRM, 2021. 1 recurso eletrônico: PDF ; il. ISBN 978-65-5664-179-9

MEDEIROS, Luciano Frontino de. **Inteligência artificial aplicada: Uma abordagem introdutória**. 1. ed. São Paulo: InterSaberes, 2018

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION (NASA). Landsat 8. Disponível em: <[http://www.nasa.gov/mission\\_pages/landsat/spacecraft/index.html#.UieDrzY3s0M](http://www.nasa.gov/mission_pages/landsat/spacecraft/index.html#.UieDrzY3s0M)>. Acesso em: 22 de Junho de 2022.

PINTO, D. F. **A Utilização do Sensoriamento Remoto e o Geoprocessamento como Ferramentas Aplicadas às Ciências da Terra e do Mar**. Universidade Federal de Santa Catarina (UFSC), 2001. Disponível em: <<http://www.inf.ufsc.br/~j.barreto/trabaluno/Pinto00.pdf>>. Acesso em: 22 de Junho de 2022.

RIGHI, Eléia and ROBAINA, Luis Eduardo de Souza. **Enchentes do Rio Uruguai no Rio Grande do Sul entre 1980 e 2005: uma análise geográfica**. Soc. nat. (Online) [online]. 2010, vol.22, n.1, pp.35-54. ISSN 1982-4513. <https://doi.org/10.1590/S1982-45132010000100004>.

ROUSE, J. W.; Haas, R. H.; Schell, J. A.; D. W. Deering. **Monitoring Vegetation systems in the Great Plains with ERTS, Proceedings**. Third Earth Resources Technology Satellite-1 Symposium, Greenbelt: NASA SP-351,3010-3017. 1974.

SCHUSTER, R. ; SCOTTÁ, F. C. ; PARANHOS, R. . **Inserção de Municípios e Bacias Hidrográficas no Estado do Rio Grande do Sul**. BOLETIM GEOGRÁFICO DO RIO GRANDE DO SUL, v. 36, p. 138, 2021.

SILVEIRA, Greice Vieira. **Análise das enchentes no médio curso do rio Uruguai - RS**. Orientador: Laurindo Antônio Guasselli. 2019. 50 p. Tese (Doutorado) - Universidade Federal do Rio Grande do Sul - Campus do Vale, 2019. Disponível em: <http://hdl.handle.net/10183/202060>. Acesso em: 27 jul. 2022.

*TENSORFLOW*. “**Tensors**”. 2019. Disponível em: <<https://www.tensorflow.org/>> . Acesso em: 22 de junho de 2022

VON DER MALSBERG, C (1973) **Self-Organization of Orientation Sensitive Cells in the Striate Cortex**. *Kybernetik*, 14, 85-100. Disponível em: <<https://doi.org/10.1007/BF00288907>> Acesso em: 22 de Junho de 2022.