

**UNIVERSIDADE FEDERAL DO PAMPA**

**LUCAS TRAVI RIBEIRO**

**USO DE MODELOS PREDITIVOS PARA ANÁLISE DA PRESENÇA DE SÓDIO  
NO SOLO NO MUNICÍPIO DE DOM PEDRITO-RS**

**Itaqui  
2024**

**LUCAS TRAVI RIBEIRO**

**USO DE MODELOS PREDITIVOS PARA ANÁLISE DA PRESENÇA DE SÓDIO  
NO SOLO NO MUNICÍPIO DE DOM PEDRITO-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 em Engenharia Cartográfica e de Agrimensura.

Orientador: 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).

R48471u Ribeiro, Lucas Travi

USO DE MODELOS PREDITIVOS PARA ANÁLISE DA PRESENÇA DE SÓDIO NO SOLO NO MUNICÍPIO DE DOM PEDRITO-RS / Lucas Travi Ribeiro.

24 p..

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Pampa, Engenharia Cartográfica e de Agrimensura, 2024.

“Orientação: Cristiano Galafassi”

1. Sensoriamento Remoto. 2. Geologia. 3. Modelo Preditivo. 4. Agricultura.

**LUCAS TRAVI RIBEIRO**

**USO DE MODELOS PREDITIVOS PARA ANÁLISE DA PRESENÇA DE SÓDIO  
NO SOLO NO MUNICÍPIO DE DOM PEDRITO-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 em Engenharia Cartográfica  
e de Agrimensura.  
Área de concentração:

Trabalho de Conclusão de Curso defendido e aprovado em: 17 de julho de 2024.

Banca examinadora:

 Documento assinado digitalmente  
**CRISTIANO GALAFASSI**  
Data: 16/08/2024 09:51:33-0300  
Verifique em <https://validar.iti.gov.br>

---

Prof. Dr. Cristiano Galafassi  
Orientador  
UNIPAMPA

 Documento assinado digitalmente  
**SIDNEI LUIS BOHN GASS**  
Data: 08/08/2024 10:08:58-0300  
Verifique em <https://validar.iti.gov.br>

---

Prof. Dr. Sidnei Luis Bohn Gass  
UNIPAMPA

 Documento assinado digitalmente  
**PAULO JORGE DE PINHO**  
Data: 17/08/2024 11:54:24-0300  
Verifique em <https://validar.iti.gov.br>

---

Prof. Dr. Paulo Jorge de Pinho  
UNIPAMPA

## **AGRADECIMENTO**

À minha família que sempre me apoiou em todas as minhas decisões tanto financeiramente quanto emocionalmente.

À UNIPAMPA pela existência do curso e todos os auxílios fornecidos.

Ao professor orientador Cristiano Galafassi por todo auxílio e por todas as conversas produtivas e improdutivas.

Aos professores que me ofereceram diálogos e debates os quais me trouxeram ensinamentos os quais levarei para a vida.

A todos os colegas de curso pelo apoio nas disciplinas, além das grandes amizades que cultivei com grande parte deles os quais terei laços para a vida toda, sem sombra de dúvidas.

"A ciência é muito mais que um corpo de conhecimentos. É uma maneira de pensar".

Carl Sagan

## RESUMO

A agricultura é de extrema importância pois é uma atividade que afeta a economia da comunidade como uma toda, e devido a isso, várias técnicas vêm sendo elaboradas ao longo dos anos para observar e indicar possíveis problemas nas lavouras. O objetivo foi utilizar técnicas de sensoriamento remoto aliadas a um modelo preditivo baseado em *Machine Learning* para detectar áreas salinas. A geologia foi uma grande aliada nas análises tendo em vista que estas áreas salinas são focos de sódio. Foi implementado um modelo preditivo com base de dados extraída de imagens de satélite do Sentinel-2A com 8 bandas. Cada pixel foi registrado contendo as 8 camadas do sensor MSI e assim foram criados dados de treinamento para duas hipóteses onde o modelo atribui “1” para áreas salinas e “0” para outros. Os resultados demonstraram que os 85% de precisão foram capazes de identificar alguns focos e pode ter utilidade no direcionamento de visitas a campo para validar a informação. Mais trabalhos precisam ser feitos para verificar se o método tradicional do sensoriamento remoto pode ser mais eficaz na detecção dos solos salinizados.

Palavras-Chave: Agricultura, Áreas Salinas, Sensoriamento Remoto, *Machine Learning*, Geologia, Sentinel-2A.

## **ABSTRACT**

Agriculture is of utmost importance as it is an activity that affects the economy of the community as a whole. Due to this, various techniques have been developed over the years to observe and indicate potential problems in crops. The objective was to use remote sensing techniques combined with a predictive model based on Machine Learning to detect saline areas. Geology was a great ally in the analyses considering that these saline areas are sodium hotspots. A predictive model was implemented using a dataset extracted from Sentinel-2A satellite images with 8 bands. Each pixel was recorded containing the 8 layers of the MSI sensor, thus creating training data for two hypotheses where the model assigns "1" to saline areas and "0" to others. The results showed that 85% accuracy was able to identify some hotspots and may be useful in directing field visits to validate the information. More work needs to be done to verify if the traditional remote sensing method can be more effective in detecting salinized soils.

Keywords: Agriculture, Salinized Soils, Remote Sensing, Machine Learning, Geology, Sentinel 2-A.

## **LISTA DE FIGURAS**

Figura 1 – Mapa de localização do município de Dom Pedrito.	13
Quadro 1 – Bandas espectrais do satélite Sentinel-2A.	16
Figura 2 – Máscara aplicada à imagem de satélite.	19
Figura 3 – Pontos que bateram com as áreas salinas esperadas.	20
Figura 4 – Pontos que tiveram proximidade às áreas salinas identificadas.	21

## **LISTA DE SIGLAS**

png- Portable Network Graphic

ESA - European Space Agency

MSI - Multispectral Instrument

IBGE - Instituto Brasileiro de Geografia e Estatística

QGIS- Quantum GIS

## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>12</b>
<b>2 APRESENTAÇÃO DA ÁREA DE ESTUDO.....</b>	<b>12</b>
<b>3 REFERENCIAL TEÓRICO.....</b>	<b>14</b>
<b>3.1 Geologia e fertilidade do solo.....</b>	<b>14</b>
<b>3.2 Sensoriamento Remoto.....</b>	<b>15</b>
<b>3.2 Modelos preditivos e Machine Learning.....</b>	<b>16</b>
<b>4 METODOLOGIA.....</b>	<b>17</b>
<b>5 APRESENTAÇÃO DA PESQUISA E ANÁLISE DOS RESULTADOS.....</b>	<b>18</b>
<b>6 CONSIDERAÇÕES FINAIS.....</b>	<b>21</b>
<b>REFERÊNCIAS.....</b>	<b>22</b>

## 1. INTRODUÇÃO

A análise e monitoramento do solo são atividades fundamentais para a agricultura, gestão ambiental e uso sustentável dos recursos naturais. Entre as diversas formações geológicas que podem ser observadas, os solos salinizados representam uma preocupação significativa devido à sua influência sobre a qualidade e a estrutura do solo. Essas formações, caracterizadas pela alta concentração de sódio, afetam negativamente a permeabilidade do solo, dificultando a retenção de água e a penetração das raízes, resultando em impactos adversos sobre a produtividade agrícola (Rengasamy, 1991).

Nos últimos anos, o avanço das tecnologias de sensoriamento remoto, como os satélites de observação da Terra, tem proporcionado novas possibilidades para o estudo detalhado do solo e a identificação de áreas específicas com precisão. Dentre esses satélites, destaca-se o Sentinel-2A, parte do programa Copernicus da Agência Espacial Europeia (ESA), que oferece imagens multiespectrais de 20 metros de resolução espacial, permitindo uma análise detalhada da superfície terrestre (ESA, 2024).

A utilização de técnicas de aprendizado de máquina e redes neurais profundas (*Deep Learning*) tem se mostrado promissora na análise de grandes volumes de dados geoespaciais. Essas técnicas permitem a criação de modelos preditivos capazes de detectar padrões complexos nas imagens de satélite, facilitando a identificação de solos salinizados e outras características específicas do solo (Goodfellow et al., 2016). Neste contexto, este trabalho visa desenvolver um modelo baseado em aprendizado profundo para detectar a presença de solos salinizados em imagens do satélite Sentinel-2A, contribuindo para a gestão e monitoramento desses solos.

## 2. APRESENTAÇÃO DA ÁREA DE ESTUDO

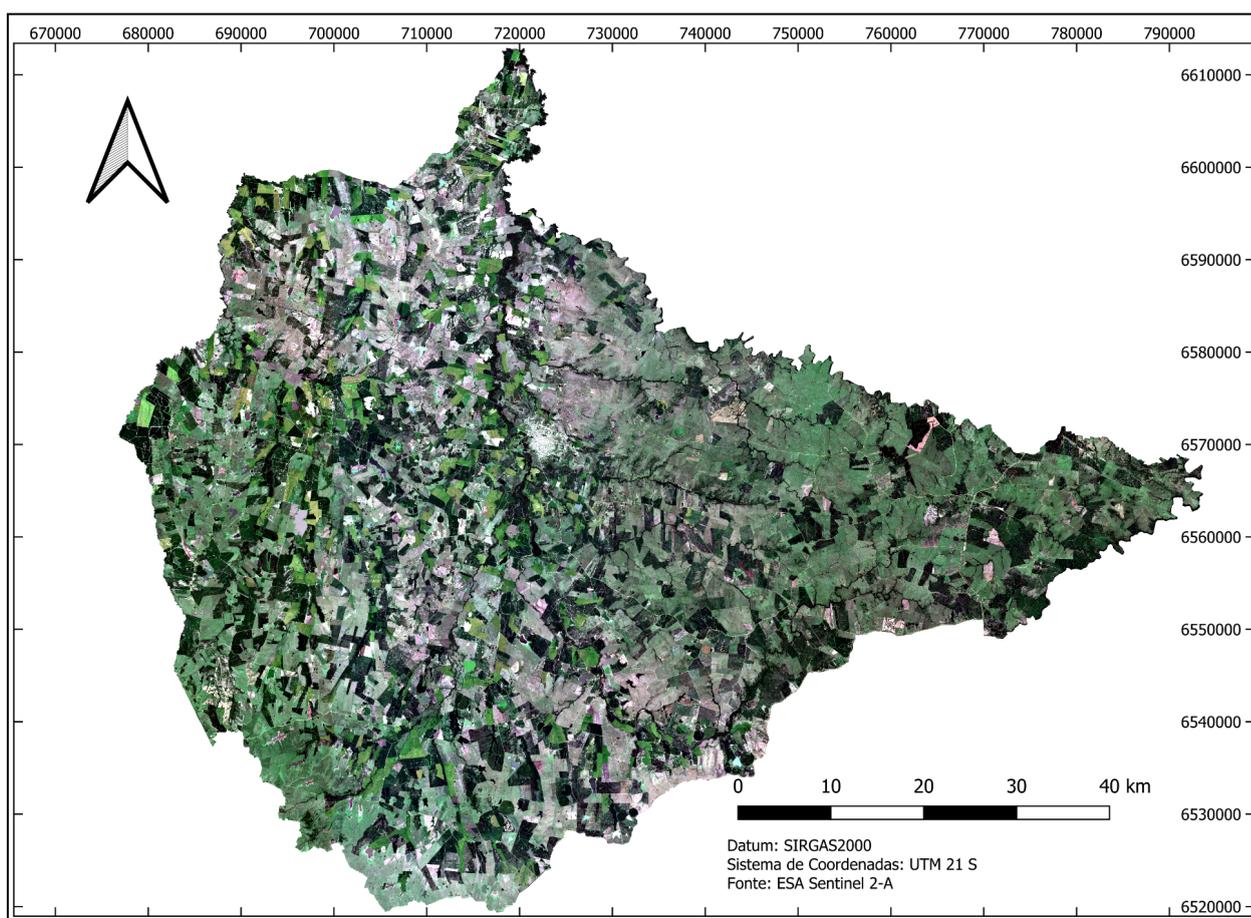
A área de estudo se refere a toda a extensão do município de Dom Pedrito. De acordo com o último censo do IBGE (2021), o município conta com 38.222 habitantes e com extensão territorial de 5.194,051 km<sup>2</sup>. Vale ressaltar que a atividade agrícola é, atualmente, a principal atividade econômica do local.

De acordo com Barreto (2011) o município de Dom Pedrito tinha uma base muito forte em pecuária, principalmente sendo a produção de charque. Após a

segunda grande modernização nos anos 70 que os campos tiveram no Brasil, o agronegócio começou a se mostrar como uma opção viável para os moradores da área, assim, sendo uma atividade de vital importância. Qualquer impacto no agronegócio afetará diretamente questões econômicas e sociais, tendo em vista que tais atividades geram empregos para a população local.

Conforme Verdum (2012), Quanto à formação geológica, o município fica na região do escudo sul-riograndense, uma das áreas geológicas mais antigas do mundo por conta do material do escudo, sendo esse rochas ígneas graníticas que datam do período pré-cambriano. De acordo com Ozório (2019), a região possui depósitos de minerais como o sulfeto de metais-base.

Figura 1 - Mapa de localização do município de Dom Pedrito do dia 01/03/2023 em composição colorida de bandas 04/03/02 do sensor MSI.



Fonte: Sentinel 2A (ESA) e adaptações do autor.

### 3. REFERENCIAL TEÓRICO

Neste trabalho, o referencial teórico aborda conceitos e técnicas relacionados às eras geológicas, com ênfase no uso de imagens de satélite e técnicas de sensoriamento remoto para a detecção de solos salinizados. Serão explorados modelos preditivos baseados em inteligência artificial que têm como objetivo identificar a presença de branquizaís no solo, proporcionando uma ferramenta inovadora para o estudo e monitoramento dessas formações.

#### 3.1 Geologia e fertilidade do solo

Lyell (1830) aponta que as mudanças geológicas ocorrem ao longo do tempo devido a processos naturais constantes, sugerindo que algumas áreas estiveram sob os oceanos devido a essas transformações ao longo de períodos extensos.

No estudo de Rengasamy (1991), é abordada a fixação do sódio (Na) no solo, destacando como altas concentrações de Na podem impactar negativamente a estrutura do solo. O autor discute a substituição de cátions essenciais, como cálcio (Ca) e magnésio (Mg), pelo Na, levando à formação de agregados dispersos e prejudicando a qualidade física do solo. Esse fenômeno é uma preocupação significativa em solos sódicos, afetando a permeabilidade, a capacidade do solo de reter água, dificulta a penetração das raízes o que pode gerar uma diminuição da colheita, entre outros.

A presença de Na no solo, especialmente com grandes concentrações, pode desencadear problemas de salinização e sodicidade, afetando a estrutura e a fertilidade do solo. De acordo com Gheyi (2022), a sodicidade do solo pode resultar em dispersão de argila, redução da infiltração de água e limitação no desenvolvimento das raízes das plantas, impactando diretamente na produtividade agrícola. Além disso, a presença excessiva de Na pode levar a degradação do solo, tornando-o menos propício para o cultivo de diversas culturas.

A pedologia foca no estudo da formação, classificação e distribuição dos solos. Este campo de estudos abrange tanto a composição física quanto química do solo, bem como os processos que influenciam sua formação e evolução ao longo do tempo. Segundo Schaetzl e Thompson (2015), a interação desses cinco fatores principais, sendo eles: material parental, clima, organismos, topografia e tempo,

atuam juntos para decompor e alterar o material original, resultando na criação de horizontes de solo distintos.

### **3.2 Sensoriamento Remoto**

O Sensoriamento Remoto é uma forma muito eficaz de analisar dados coletados em campo e utilizar estes dados como aliado ou oponente da teoria inicial. Clark (1984), por exemplo, explora técnicas de análise espectral para sensoriamento remoto. Ele abrange princípios fundamentais da espectroscopia de reflectância e fornece métodos quantitativos para interpretar dados espectrais. O livro inclui informações sobre análise de minerais, discutindo como interpretar assinaturas espectrais para identificação de componentes minerais em diferentes contextos geológicos.

Os satélites, por sua vez, desempenham um papel crucial no avanço do sensoriamento remoto, fornecendo dados consistentes e abrangentes para diversas aplicações. O Sentinel-2A é parte do programa Copernicus da Agência Espacial Europeia (ESA) e oferece uma combinação de bandas 13 espectrais que permitem a análise detalhada da superfície terrestre. Suas capacidades de captura de imagens multiespectrais com resoluções espaciais entre 10 a 60 metros, o que tornam o Sentinel-2A uma ferramenta valiosa para monitoramento ambiental, agricultura, gestão de recursos naturais e outros estudos geoespaciais.

Tais bandas têm intervalos de comprimento de onda que compreendem a cada tipo de onda eletromagnética que o MSI, sensor espectrométrico do Sentinel-2A, consegue captar. A resolução espectral varia de 442 nm até 2202 nm. Vale ressaltar que nem todas as bandas têm a mesma resolução espacial, todavia, apenas as bandas 2, 3, 4 e 8 têm resolução espacial de 10 metros, assim, a ESA disponibiliza as imagens de 10 metros adaptadas a 20 metros, o que propicia trabalhar com as bandas unidas. No quadro 1 poderão ser vistas as bandas espectrais do satélite Sentinel-2A.

Quadro 1: Bandas espectrais do satélite Sentinel-2A.

Resolução	N° Banda	Nome da banda	Comprimento de onda central (nanômetro)	Combinações de banda
10m	B02	Blue (Azul)	490	Cor Verdadeira 04/03/02 Falsa-cor 1 e 2 RGB 08/04/03 e 04/08/03
	B03	Green (Verde)	560	
	B04	Red (Vermelho)	665	
	B08	NIR (Infravermelho Próximo)	842	
20 m	B05	Red Edge 1	705	Swir 1 RGB 12/11/8A
	B06	Red Edge 2	740	
	B07	Red Edge 3	783	
	B08A	Red Edge 4	865	
	B11	SWIR 1	1610	
	B12	SWIR 2	2190	
60 m	B01	Aersossol	443	-
	B09	Water Vapor	940	
	B10	Cirrus	1375	

Fonte: ESA.

### 3.2 Modelos preditivos e Machine Learning

De acordo com Goodfellow et al. (2016), as bases teóricas das redes neurais giravam em torno de ideias simples. Os neurônios e as redes neurais são comparados a peças fundamentais de um quebra-cabeça. O treinamento, onde a rede aprende ajustando suas conexões, é o ponto central. São mencionadas funções que ajudam a tornar a rede mais inteligente. Também se fala sobre maneiras de evitar o *overfitting*, que ocorre quando a rede "aprende demais" a partir dos exemplos. Técnicas que a fazem aprender sem precisar de muitos exemplos prontos também são discutidas. O aprendizado de máquina é uma técnica que permite que os computadores aprendam a partir de dados. Essa técnica tem sido amplamente utilizada em diversas áreas, incluindo a análise de dados geológicos e

ambientais. Em relação à análise mineralógica do solo, o aprendizado de máquina pode ser utilizado para identificar padrões nos dados coletados por meio de técnicas de sensoriamento remoto. Além disso, o aprendizado de máquina pode ser utilizado para desenvolver modelos preditivos capazes de detectar teores de minerais no solo a partir de imagens de satélite. (CAMPOREALE, 2018)

#### **4. METODOLOGIA**

Para a realização deste trabalho, foram utilizadas imagens de satélite do Sentinel 2A, que possuem uma resolução espacial de 20 metros e são compostas por 8 bandas espectrais. Tais bandas foram da B01 até a B08, precisou-se trabalhar com as imagens de 20 metros pois nem todas as bandas necessárias para a análise tinham a resolução espacial de 10 metros, tendo em vista que apenas as bandas 2m 3, 4 e 8 contam com esta resolução. A metodologia empregada envolveu a utilização de uma rede neural artificial profunda configurada de maneira específica para a detecção de solos salinizados.

A escolha das imagens de satélite foi baseada considerando um período de baixa cobertura vegetal e de pouca ou quase nenhuma incidência de nuvens, sendo essa a data de 01/03/2023, o que facilita a visualização direta do solo e, conseqüentemente, a identificação dos solos salinizados.

Para a construção do banco de dados necessário ao treinamento da rede neural, foram selecionados 21 pontos onde se esperava encontrar solos salinos. Esses pontos foram escolhidos com base em conhecimento prévio de perfis analisados e uma visita de campo, onde foram escolhidos os pontos onde, na análise de solo, foi identificada a incidência em camadas superficiais. A partir das imagens de satélite processadas no software QGIS, foram coletados os pixels correspondentes a esses pontos, bem como os 9 pixels ao redor de cada ponto, tanto em áreas com solos salinizados quanto em áreas sem essa característica. Essa abordagem garantiu uma amostra representativa e diversificada dos diferentes tipos de solos presentes na área de estudo.

A rede neural foi configurada com uma camada de entrada composta por 8 neurônios, cada um correspondente a uma das bandas espectrais das imagens do Sentinel 2A. Em seguida, foram implementadas duas camadas ocultas, cada uma contendo 128 neurônios, para processar e extrair características complexas dos

dados. Por fim, a rede neural possui uma camada de saída com um único neurônio, responsável pela classificação binária, indicando a presença (1) ou ausência (0) de solos salinizados. Vale ressaltar que o modelo resultará em um valor entre 0 e 1, indicando o grau de confiança da rede em indicar se há ou não a presença de um solo salino.

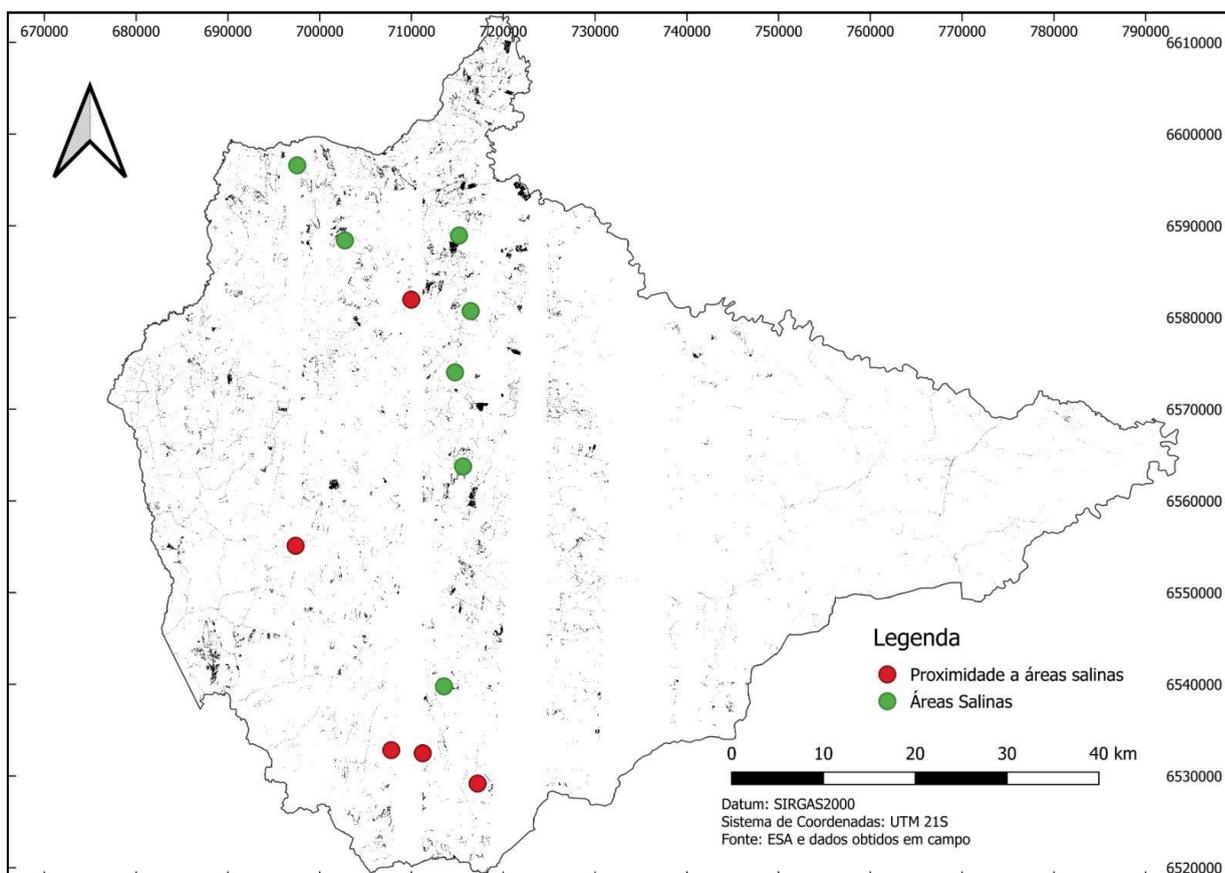
Com os bancos de dados preparados e os dados de treinamento devidamente coletados, o modelo foi treinado para gerar uma máscara de classificação. Esta máscara, representando as áreas identificadas como solos salinizados, será analisada na próxima seção permitindo uma avaliação da eficácia do modelo e a validação dos resultados obtidos.

## **5. APRESENTAÇÃO DA PESQUISA E ANÁLISE DOS RESULTADOS**

Este trabalho concentrou-se na identificação de solos salinos a partir de imagens do satélite Sentinel 2A, utilizando técnicas avançadas de processamento de imagens e análise de dados. Inicialmente, foi identificada a área de estudo e coletados dados espectrais de 20 pontos conhecidos de presença de solos salinos, resultando em mais de 140 pixels, além de 500 pixels adicionais selecionados manualmente em áreas sem solos salinos. Com esses dados, foi possível realizar uma análise detalhada e abrangente da presença de solos salinos. A análise dos dados indicou uma precisão média de classificação superior a 85%, demonstrando a eficácia da metodologia empregada na distinção de áreas com e sem solos salinos.

A figura 2 representa a máscara gerada pelo modelo com base na imagem de satélite da região. No mapa, estes pontos pretos indicam os pixels onde o modelo atribuiu o valor 1, ou seja, onde foi identificada a ocorrência de solos salinos. O resto da imagem representada com a cor branca foi atribuído o valor 0, ou seja, sem áreas salinas detectadas.

Figura 2 - Máscara gerada pelo modelo preditivo aplicada à imagem de satélite do município de Dom Pedrito-RS, dia 01/03/2023.

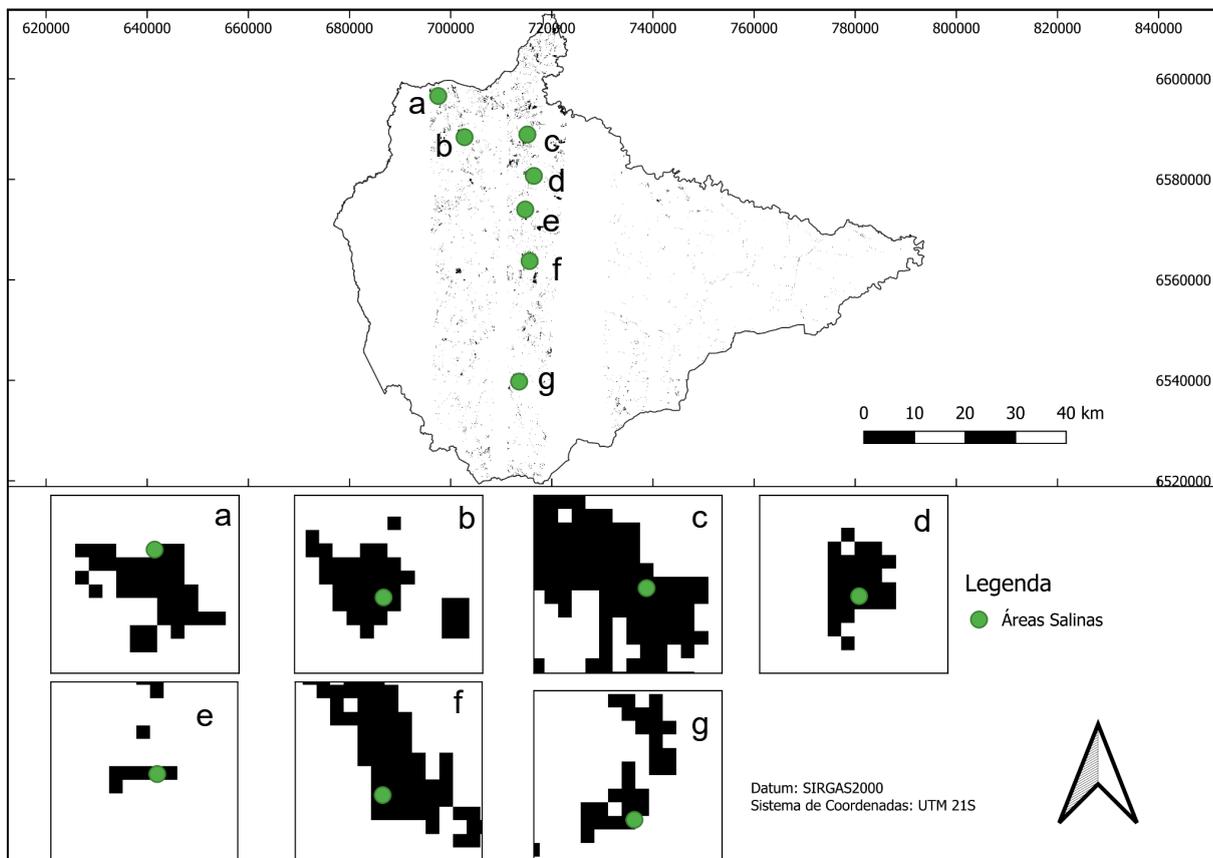


Fonte: Sentinel 2A (ESA), IBGE, Dados obtidos em campo e adaptações do autor.

A figura 2 demonstra a possível presença destes solos salinos. A máscara foi aplicada na imagem de satélite trazida na figura 1 e a figura 2 pode ser de grande valia para guiar expedições em locais ainda não confirmados como áreas salinas, porém, reconhecidos como “1”, ou seja, solos salinizados.

Também, pôde-se observar que boa parte dos locais identificados como solos salinos estão localizados na parte centro-oeste do município, isso se dá possivelmente por conta do relevo na parte leste do município que é mais atenuado devido a presença do escudo sul-riograndense, uma das formações mais antigas do mundo. Apesar dos pontos serem pequenos e de difícil visualização, na figura 3 é aplicado um zoom de escala 1:6.000 onde pode-se observar melhor essas incidências.

Figura 3 - Focos de solos salinizados em pontos de coleta.



Fonte: Sentinel 2A (ESA), IBGE, Dados obtidos em campo e adaptações do autor.

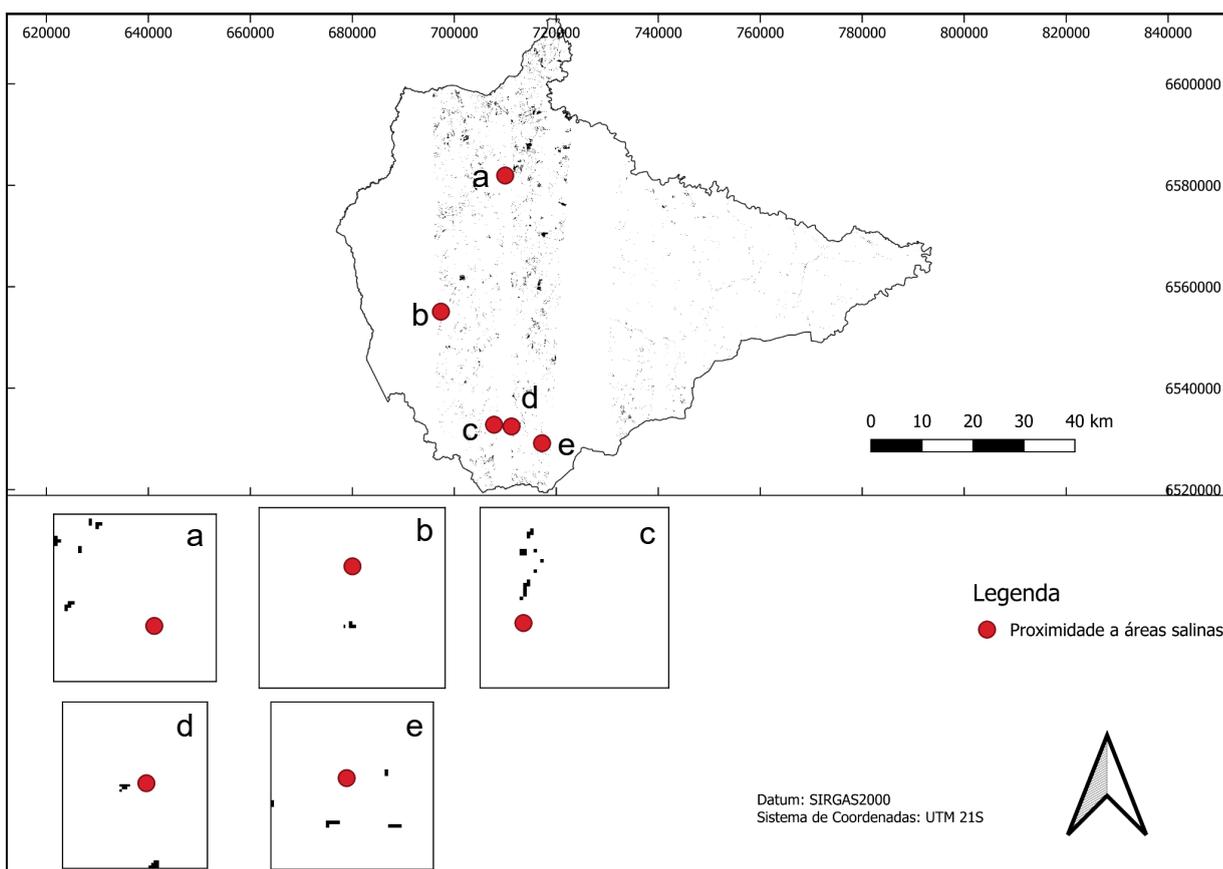
Os pontos coletados nestes locais mostrados na figura 3 confirmaram a presença de solos salinos, alinhando-se com as expectativas iniciais. A análise detalhada desses locais revelou padrões consistentes, contribuindo para a compreensão das características dessas formações.

Com escala de 1:6.000, os zooms da imagem demonstram com mais nitidez como o modelo identificou os pontos e nestes 7 foram encontrados incidências, o que leva a crer que existem solos salinos nessas áreas. O modelo identificou com 85% de acurácia a incidência de solos salinizados, porém, o mesmo não conseguiu diferenciar de os solos salinizados de estradas, o que foi de grande valia para realizar o georreferenciamento da imagem, tendo em vista que o modelo não gera o resultado final georreferenciado e sim em png. Apesar de não ser uma porcentagem tão satisfatória, conseguiu identificar algumas das áreas de incidência.

Foram utilizadas 1000 épocas para chegar neste valor, o que é um valor atenuado em comparação a outros trabalhos que seguem a linha de modelos preditivos, isso pode vir a indicar que pela sutileza da diferença dos pixels que

representam somente areia e áreas salinizadas, que este método apenas ajude a dar uma ideia de onde as incidências principais estão. Na figura 4 estão representados os pontos que, apesar de não haver áreas salinas exatamente no local, existem as mesmas nas proximidades.

Figura 4 - Pontos que tiveram proximidade a áreas salinas.



Fonte: Sentinel 2A (ESA), IBGE, Dados obtidos em campo e adaptações do autor.

Diferentemente da figura 3, esses pontos apresentados na figura 4 não estão em locais identificados como áreas salinas pela máscara aplicada pelo modelo preditivo. Vale ressaltar que na imagem de satélite alguns desses pontos estão em locais claramente esbranquiçados, o que pode levar a crer que por algum motivo o modelo não foi muito eficaz nesses locais.

A imagem originalmente foi dividida em 9 partes, para facilitar na hora do modelo conseguir gerar as máscaras, assim é possível apontar que os pontos considerados próximos às áreas salinas e também os locais identificados como tal, estão localizados na parte leste do município. Esta área leste corresponde apenas a 3 partes da imagem, porém, como já trazido anteriormente, isso se dá possivelmente

por conta das formações graníticas do escudo sul-riograndense que compreende boa parte do oeste de Dom Pedrito. É de extrema importância mencionar que as imagens aproximadas da figura 4 tem escala de 24.000, para facilitar a visualização.

## **6. CONSIDERAÇÕES FINAIS**

Os mapas gerados corroboraram com as identificações manuais, validando a abordagem e sugerindo que o método utilizado pode ser uma ferramenta valiosa para estudos futuros. Os mapas gerados a partir dos dados processados mostraram uma correspondência significativa com as áreas de solos salinos identificadas manualmente. Essa correspondência valida a abordagem utilizada e sugere que as imagens de satélite, juntamente com um processamento adequado, podem ser ferramentas eficazes na identificação de solos salinos.

Durante a análise, foi observado que a precisão na identificação de solos salinos variou conforme as características específicas das áreas estudadas. Em regiões com solo exposto e pouca vegetação, a detecção foi mais eficaz. Isso confirma a importância da escolha do período de baixa cobertura vegetal para a obtenção das imagens de satélite, facilitando a visualização direta do solo. Em contrapartida, em áreas com vegetação densa ou outras interferências, a precisão foi menor, sugerindo que a cobertura vegetal pode dificultar a detecção precisa de solos salinos.

Os resultados deste estudo são encorajadores e indicam que a metodologia utilizada pode ser um trampolim para futuros trabalhos. Estudos adicionais podem se beneficiar da combinação desta técnica com outras abordagens de sensoriamento remoto e a utilização de dados adicionais para aumentar a precisão e robustez dos modelos. A integração de diferentes fontes de dados e a contínua adaptação dos parâmetros de análise são caminhos promissores para aprimorar a detecção de solos salinos e outras características do solo, contribuindo para um melhor entendimento e gestão dos recursos naturais.

## REFERÊNCIAS

BARRETO, V. A. V. Dom Pedrito, cidade e campo : a modernização agrícola e a cidade local. Programa de pós-graduação em geografia, UFRGS. Porto Alegre, 2011.

CAMPOREALE, E.; WING, S.; JOHNSON, J. (EDS.). Machine learning techniques for space weather. Filadélfia, PA, USA: Elsevier Science Publishing, 2018.

CLARK, R. N.; ROUSH, T. L. Reflectance spectroscopy: Quantitative analysis techniques for remote sensing applications. Journal of geophysical research, v. 89, n. B7, p. 6329–6340, 1984.

European Space Agency. Sentinel-2 User Handbook. Disponível em: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/user-handbook>. Acesso em: 22 de Junho de 2024.

GHEYI, H. R. et al. Management and reclamation of salt-affected soils: general assessment and experiences in the Brazilian semiarid region. Ciência Agronômica, v. 53, 2022.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. Deep Learning. 1ª ed. Cambridge: MIT Press, 2016.

LACERDA, C. F. DE et al. Evidence of nitrogen and potassium losses in soil columns cultivated with maize under salt stress. Revista Brasileira de Engenharia Agrícola e Ambiental/Brazilian Journal of Agricultural and Environmental Engineering, v. 22, n. 8, p. 553–557, 2018.

LYELL, Charles. Principles of Geology. 1ª ed. London: John Murray, 1830.

OZORIO, A. G. A FORMAÇÃO DO PLATÔ DO TAQUAREMBÓ, DOM PEDRITO, RS: UMA PROPOSTA DE REGIONALIZAÇÃO DO ESTUDO DO COMPONENTE FORMAÇÃO E ESTRUTURA DA VIDA NA TERRA. 2019.

PHILIPPSEN, Adriana Strieder. Abordagem clássica e bayesiana para modelos de séries temporais da família GARMA com aplicações para dados de contagem. 2011. 89 f. Dissertação (Mestrado em Ciências - Ciências de Computação e Matemática Computacional) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2011.

RENGASAMY, P., & Olsson, K. A. (1991). Sodicity and soil structure. *Australian Journal of Soil Research*, 29(6), 935-952. doi: 10.1071/SR9910935

SALAS, E. A. L.; KUMARAN, S. S. Hyperspectral Bare Soil Index (HBSI): Mapping soil using an ensemble of spectral indices in machine learning environment. *Land*, v. 12, n. 7, p. 1375, 2023.

Schaetzl, R., & Thompson, M. (2015). *Soils: Genesis and Geomorphology*. Cambridge University Press.

VERDUM, R. et al. Rio Grande do Sul: Paisagens e Territórios em Transformação. 2. ed. Porto Alegre: Editora da UFRGS, 2012.