

UNIVERSIDADE FEDERAL DA FRONTEIRA SUL – UFFS
CAMPUS ERECHIM – RIO GRANDE DO SUL
COLEGIADO DE ENGENHARIA
CURSO: ENGENHARIA AMBIENTAL E SANITÁRIA

STEPHEN ORLLY ORELUS

**Evolução espaço-temporal do uso e cobertura da terra no município de Barão de
Cotegipe (RS)**

Erechim (RS)

2025

STEPHEN ORLLY ORELUS

**Evolução espaço-temporal do uso e cobertura da terra no município de Barão de
Cotegipe (RS)**

Trabalho de Conclusão de Curso apresentado ao Curso de Bacharelado em Engenharia Ambiental e Sanitária da Universidade Federal da Fronteira Sul – UFFS (Campus Erechim), como requisito para obtenção do título de Engenheiro Ambiental e Sanitarista.

Orientador: Prof. Dr. Roberto Valmir da Silva

Coorientador: Prof. José Mário Vincesi Grzybowski

Erechim (RS)

2025

Bibliotecas da Universidade Federal da Fronteira Sul - UFFS

'
Evolução espaço-temporal do uso e cobertura da terra
no município de Barão de Cotegipe (RS) / , Stephen
Orlly Orelus. -- 2025.
58 f.:il.

Orientador: Doutor Roberto Valmir da Silva
Co-orientador: Doutor José Mario Vicensi Grzybowski
Trabalho de Conclusão de Curso (Graduação) -
Universidade Federal da Fronteira Sul, Curso de
Bacharelado em Engenharia Ambiental e Sanitária,
Erechim,RS, 2025.

I. Orelus, Stephen Orlly II. Silva, Roberto Valmir
da, orient. III. Grzybowski, José Mario Vicensi,
co-orient. IV. Universidade Federal da Fronteira Sul. V.
Título.

Elaborada pelo sistema de Geração Automática de Ficha de Identificação da Obra pela UFFS
com os dados fornecidos pelo(a) autor(a).

Stephen Orllly Orelus

Evolução espaço-temporal do uso e cobertura da terra no município de Barão de Cotegipe (RS)

Trabalho de Conclusão de Curso apresentado ao Curso de Bacharelado em Engenharia Ambiental e Sanitária da Universidade Federal da Fronteira Sul – UFFS (Campus Erechim), como requisito para obtenção do título de **Engenheiro Ambiental e Sanitarista**.

Este trabalho foi defendido e aprovado pela banca em 17/11/2025.

BANCA EXAMINADORA

Prof. Dr. Roberto Valmir da Silva – UFFS
Orientador

Prof. Dr. José Mario Vicensi Grzybowski – UFFS
Coorientador

Prof.^a Dr.^a Deise Paludo – UFFS
Avaliador

Prof.^a Dr.^a Clarissa Dalla Rosa – UFFS
Avaliador

RESUMO

As transformações antrópicas na superfície terrestre, especialmente as mudanças no uso e cobertura da terra, exercem influência direta sobre a dinâmica ambiental. Este estudo analisou a evolução temporal da cobertura da terra no município de Barão de Cotegipe (RS) entre 2003 e 2023, com foco nas implicações para o planejamento ambiental. A metodologia baseou-se no processamento digital de imagens Landsat 7 e 8, utilizando o plugin Semi-Automatic Classification Plugin (SCP) no QGIS. Os algoritmos Random Forest (RF) e Support Vector Machine (SVM) foram empregados para a classificação supervisionada das classes Floresta, Agricultura, Solo Exposto e Água. A avaliação da acurácia demonstrou alta confiabilidade do classificador RF, com acurácia global acima de 98% e coeficiente Kappa em torno de 0,97. Os resultados indicam uma expressiva transformação da paisagem ao longo de duas décadas, marcada pela expansão agrícola e redução contínua das áreas florestais, destacando a necessidade de estratégias de gestão e planejamento voltadas ao uso sustentável do território.

Palavras-chave: Sensoriamento Remoto, Uso e Cobertura da Terra, Random Forest, Planejamento Ambiental.

ABSTRACT

Human-induced transformations on the Earth's surface, particularly land use and land cover changes, directly influence environmental dynamics. This study analyzed the temporal evolution of land cover in the municipality of Barão de Cotegipe (RS), Brazil, between 2003 and 2023, focusing on implications for environmental planning. The methodology was based on digital processing of Landsat 7 and 8 imagery using the Semi-Automatic Classification Plugin (SCP) in QGIS. Machine learning algorithms Random Forest (RF) and Support Vector Machine (SVM) were applied for supervised classification, with thematic classes defined as Forest, Agriculture, Bare Soil, and Water. Accuracy assessment indicated high reliability of the RF classifier, with overall accuracy above 98% and Kappa coefficient around 0.97. The results reveal a significant landscape transformation over two decades, marked by the expansion of agricultural areas and the continuous reduction of forest cover, emphasizing the need for management and planning strategies aimed at sustainable land use.

Keywords: Land use and land cover, Remote sensing, Random Forest, QGIS, Environmental planning.

AGRADECIMENTOS

Agradeço primeiramente a Deus pela inteligência, saúde e coragem que me concedeu para realizar este sonho. Agradeço à minha família, especialmente à minha mãe Venette Gerome e ao meu pai Pierre Arnoux Orelus, que desde a minha infância sempre me apoiaram e me ensinaram o valor da educação.

Eu não teria conseguido alcançar esta etapa sem o apoio da minha companheira, Rose Cernie Pierre, que sempre esteve ao meu lado, oferecendo apoio e encorajamento desde o início. Agradeço também à Universidade Federal da Fronteira Sul, pela implantação do Programa PROHAITI, que me permitiu concluir mais um capítulo da minha trajetória de vida, e a todo o corpo docente competente que tive ao longo desses cinco anos, sempre dedicados a oferecer o melhor para a nossa formação.

E, por fim, agradeço aos amigos e colegas que sempre me apoiaram durante essa caminhada.

LISTA DE ILUSTRAÇÕES

Figura 1: Classificador utilizando o método RF.....	16
Figura 2: Classificador utilizando o método SVM.....	17
Figura 3: Localização do município de Barão de Cotegipe -RS.....	19
Figura 3a. Mapa Geomorfológico do Rio Grande do Sul.....	20
Figura 3b. Hidrologia de Barão de Cotegipe.....	22
Figura 3C. Interface do plugin SCP automatic classification.....	23
Figura 3D. Diagrama dos procedimentos desenvolvidos para fazer a classificação.....	24
Mapa 1a: Classificações realizadas com os algoritmos SVM.....	28
Gráfico 1 – Classes de uso e cobertura da terra (Floresta, Agricultura, Água e Solo Exposto) - Random Forest.....	28
Mapa 1b: Classificações realizadas com os algoritmos SVM.....	29
Gráfico 2 – Classes de uso e cobertura da terra (Floresta, Agricultura, Água e Solo Exposto) - Support Machine Vector.....	29
Mapa 2 : Mudanças nas características da bacia hidrográfica.....	33
Gráfico 3 – Classes de uso e cobertura da terra na Bacia.....	34
Mapa 2.0 : Dinâmica da mata ciliar na bacia urbana.....	35
Gráfico 3.0 – Classes de uso e cobertura da terra na APP.....	36
Mapa 3 : Uso da terra na Sub-bacia 1.....	37
Gráfico 4 – Classes de uso e cobertura da terra na Sub-Bacia 1.....	38
Mapa 4 : Uso da terra na Sub-bacia 2.....	39
Gráfico 5 – Classes de uso e cobertura da terra na Sub-Bacia 2.....	40
Mapa 5 : Uso da terra na Sub-bacia 3.....	41
Gráfico 6 – Classes de uso e cobertura da terra na Sub-Bacia 3.....	42
Mapa 6 : Uso da terra na Sub-bacia 4.....	43
Gráfico 7 – Classes de uso e cobertura da terra na Sub-Bacia 4.....	44
Mapa 7 : Uso da terra na Sub-bacia 5.....	45
Gráfico 8 – Classes de uso e cobertura da terra na Sub-Bacia 5.....	46
Mapa 8 : Uso da terra na Sub-bacia 6.....	47
Gráfico 9 – Classes de uso e cobertura da terra na Sub-Bacia 6.....	48

LISTA DE TABELAS

Tabela 1: Propriedades do Satélite Landsat 7 ETM+ com o seu sensor, resolução espacial, resolução espectral, banda espectrais e o comprimento da onda central....	25
Tabela 2: Propriedades do Satélite Landsat 8 com o seu sensor, resolução espacial, resolução espectral, banda espectrais e o comprimento da onda central.....	25
Tabela 3: Avaliação da precisão das classificações multitemporais.....	29
Tabela 4: Medidas de Concordância para Dados Categóricos.....	30
Tabela 5: Avaliação da precisão das classificações multitemporais.....	31
Tabela 6: Síntese geral dos resultados de uso e cobertura da terra (2003,2013 e 2023).....	48

LISTA DE ABREVIATURAS E SIGLAS

APP	Área de Preservação Permanente
CART	Classification and Regression Trees
DN	Número Digital (Digital Number)
IBGE	Instituto Brasileiro de Geografia e Estatística
Km	Quilômetro
M	Metros
MLP	Perceptron Multicamadas (Multi-Layer Perceptron)
RF	Random Forest
RGB	Vermelho, Verde e Azul (Red, Green, Blue)
ROI	Região de Interesse (Region of Interest)
RS	Rio Grande do Sul
SCP	Semi-Automatic Classification Plugin
SIG	Sistema de Informação Geográfica
SVM	Support Vector Machine
USGS	United States Geological Survey
UTM	Universal Transversa de Mercator

SUMÁRIO

1 INTRODUÇÃO.....	13
2 OBJETIVOS.....	15
2.1 Objetivo Geral.....	15
2.2 Objetivos Específicos.....	15
3 REVISÃO BIBLIOGRÁFICA.....	16
3.1 Classificação semiautomática da cobertura da terra.....	16
3.1.1 Aprendizagem de máquina.....	16
3.1.1.0 Random Forest.....	16
3.1.1.1 Multi-Layer Perceptron.....	18
3.1.1.2 Support Vector Machine.....	18
3.2 Resposta Hidrológica, Uso da Terra e Implicações para Áreas Suscetíveis a Inundações.....	20
4 MATERIAS E MÉTODOS.....	21
4.1 Características gerais da área de estudo.....	21
4.2 Semi-Automatic Classification Plugin (SCP).....	24
4.3 Imagens de satélite multiespectrais e processamento de dados no QGIS.....	26
5 RESULTADOS E DISCUSSÃO.....	28
5.1 Análise Multitemporal do Uso e Cobertura da Terra de Barão de Cotegipe-RS.....	28
5.2 Análise espaço-temporal do uso e cobertura da terra na bacia urbana.....	35
5.2.0 Uso e Cobertura das Terras na área restrita legalmente.....	38
5.2.1 Análise das sub-bacias componentes da bacia urbana.....	40
6 CONSIDERAÇÕES FINAIS.....	54
7 REFERÊNCIAS.....	56

1 INTRODUÇÃO

O homem ao interferir na natureza contribui para a quebra do equilíbrio ecológico e, consequentemente, para a alteração dos seus fluxos naturais, e na dinâmica de milhares de seres vivos, vegetais e animais. Por isso, a Conservação Internacional (IUCN) destaca as transformações dos ecossistemas por meio de atividades humanas como a principal causa da degradação ambiental no mundo. Estas transformações têm promovido, por exemplo, a conversão de paisagens naturais em paisagens artificiais, alteração das práticas de uso e manejo do solo, desmatamento de áreas florestadas, intensificação produtiva e expansão urbana, configurando mudanças que ao atender às demandas da sociedade frequentemente comprometem a qualidade ambiental (FOLEY et al. 2005).

A intensificação das mudanças nos contextos do uso e ocupação da terra, associadas sobretudo à ocupação desordenada das terras e à supressão da vegetação, está diretamente relacionada ao agravamento de eventos globais extremos, fenômeno conhecido como Mudanças Globais. Entende-se por ‘Mudanças Globais’ o conjunto de mudanças recentes pelas quais o Mundo tem passado, sendo caracterizado sobretudo pela aceleração das alterações à escala global (comparativamente ao passado), e ao agravamento cada vez maior dos impactos advindos destas transformações. Tais processos têm afetado outros processos no âmbito do funcionalismo de vários tipos de ambientes, e em variadas escalas, como, por exemplo, o equilíbrio ambiental e a elevação dos riscos socioambientais a partir da redução da infiltração de água no solo, combinado a ampliação do escoamento superficial, o que tem sido verificado em diversas regiões do planeta. Esta problemática em questão tem se tornado uma expressão evidente da vulnerabilidade dos territórios diante das mudanças globais (BATONI et al. 2024). Nesse sentido, investigações no âmbito das alterações no uso e ocupação da terra, e a avaliação de seus impactos sobre os ecossistemas e a qualidade de vida das populações, tem se constituído em instrumentos essenciais para o planejamento dos territórios. (JAVIER et al. 2023).

Métodos eficientes de mapeamento e monitoramento ambiental estão se tornando essenciais devido à crescente pressão sobre os ecossistemas, caracterizada pelo desmatamento e pela expansão agrícola. Desenvolver e aplicar técnicas que combinem acessibilidade, rapidez e precisão no processamento de grandes quantidades de dados espaciais é crucial para apoiar atividades de controle e planejamento territorial (Yuh et al. 2022).

Nesse cenário, os sistemas de informação geográfica (SIGs) e outras ferramentas tecnológicas desempenham um papel estratégico na análise dos fatores que impulsionam as mudanças ambientais. Os SIGs integram e cruzam dados espaciais e temporais, permitindo o monitoramento detalhado da dinâmica da paisagem. Eles permitem o mapeamento e a análise sistemática de variações em parâmetros como precipitação, temperatura superficial da terra e cobertura vegetal ao longo do tempo. Essas capacidades fornecem suporte para a identificação de áreas vulneráveis, planejamento territorial e formulação de estratégias voltadas à mitigação da degradação ambiental.

No campo do processamento digital de imagens satelitais, destacam-se modelos baseados em aprendizado de máquina que podem ser integrados tanto em plataformas de computação em nuvem quanto em sistemas SIG de desktop. Um exemplo é o Semi-Automatic Classification Plugin (SCP), utilizado no ambiente QGIS, que oferece um conjunto de ferramentas interligadas para o processamento de imagens raster, permitindo um fluxo de trabalho automatizado e simplificado na classificação da cobertura da terra (Congedo, 2020).

Técnicas recentes e eficazes vêm sendo utilizadas na classificação do uso e cobertura da terra, como o caso do algoritmo *Random Forest* (RF), um método de aprendizado de máquina baseado em conjuntos de árvores de decisão. Esse algoritmo funciona ao combinar múltiplas árvores construídas a partir de diferentes subconjuntos de dados, o que resulta em maior precisão e robustez na classificação (TIKUYE et al., 2023). E o *Support Vector Machine* (SVM) que é um algoritmo supervisionado de classificação baseado na definição de hiperplanos que separam os dados de entrada em classes distintas (Congedo, 2020).

De acordo com o Relatório da Visita de Trabalho da REDESCA ao Brasil (OEA, 2025), ao longo de dezessete anos (2003-2021), o Rio Grande do Sul contabilizou 4.230 ocorrências de desastres naturais, os quais, em função de sua intensidade, acarretaram danos materiais e humanos substanciais. A abrangência desses eventos é evidenciada pelo fato de que, apenas no quadriênio 2017-2021, cerca de 4,44 milhões de pessoas em 482 municípios distintos foram impactadas por estiagens, alagamentos, inundações e chuvas intensas. Especificamente em relação às inundações, foram registrados 256 casos, que demandaram a emissão de decretos de emergência em 133 municípios.

Diante desse contexto, o presente estudo propõe analisar a evolução histórica do uso e cobertura da terra no município de Barão de Cotegipe (RS) ao longo de um período de 20 anos, enfatizando como essas transformações se relacionam com áreas afetadas por eventos hidrológicos extremos. A pesquisa utiliza métodos de aprendizado de máquina, com destaque

para os algoritmos *Random Forest* e *Support Vector Machine*, aplicado por meio do *plugin Semi-Automatic Classification* (SCP) no ambiente QGIS. A proposta combina dados multitemporais, e análises baseadas em evidências, visando contribuir para o planejamento territorial sustentável e a mitigação de impactos ambientais.

2 OBJETIVOS

2.1 Objetivo Geral

Analisar a evolução espaço-temporal do uso e cobertura da terra no município de Barão de Cotegipe (RS).

2.2 Objetivos Específicos

- Levantar métodos de classificação de uso e cobertura da terra usando imagens de satélite.
- Mapear e quantificar as classes de cobertura da terra de acordo com a resposta hidrológica.

3 REVISÃO BIBLIOGRÁFICA

3.1 Classificação semiautomática da cobertura da terra

A classificação semiautomática é uma técnica de processamento de imagens que permite a identificação de materiais em uma imagem, de acordo com suas assinaturas espectrais (Congedo, 2020). É caracteriza-se pela participação ativa do analista, exigindo conhecimento prévio sobre os alvos de interesse. Nesse processo, o analista seleciona pixels representativos das classes desejadas, e o software identifica automaticamente outros pixels com características semelhantes, aplicando regras estatísticas pré-definidas para realizar a classificação. As amostras escolhidas devem ser representativas de cada classe, pois quanto maior o número e a qualidade dessas amostras, maior tende a ser a acurácia dos resultados (Ferreira et al., 2023). Diversos algoritmos podem ser empregados nesse tipo de classificação, mas todos têm como finalidade principal a geração de um mapa temático da cobertura da terra.

3.1.1 Aprendizagem de máquina

Aprendizado de Máquina é um amplo conjunto de técnicas de classificação que visam construir modelos matemáticos com base em dados de treinamento. Em geral, algoritmos de Aprendizado de Máquina dividem os dados em conjunto de Dados de Treinamento (os dados de amostra usados para ajustar o modelo), conjunto de Dados de Validação (os dados de amostra usados para ajustar os parâmetros do modelo para que se ajustem ao conjunto de dados de treinamento) e conjunto de Dados de Teste (os dados de amostra usados para fornecer uma avaliação do modelo final). Normalmente, o treinamento e a avaliação do modelo são realizados interativamente.


3.1.1.0 Random Forest

O Random Forest (RF) é um algoritmo de aprendizado de máquina do tipo ensemble que utiliza o método de bagging (ou agregação bootstrap), no qual amostras aleatórias com substituição são extraídas do conjunto de dados original para gerar múltiplas árvores de decisão. Cada árvore é construída com base nessas amostras (amostras bootstrap), e a previsão final do modelo é determinada pela votação da maioria entre as árvores conforme elaborado na Figura 1. Esse processo reduz a variabilidade dos resultados, melhora a precisão preditiva e

torna o modelo mais robusto frente a dados inconsistentes ou com variações inesperadas (Ramachandra; Mondal; Setturu, 2023; Congedo, 2020; Tikuye et al., 2023). Segundo Belgiu e Drăguț (2016), essa combinação de múltiplas árvores permite ao RF lidar de maneira eficiente com altas dimensionalidades e forte multicolinearidade entre variáveis, características típicas dos dados de sensoriamento remoto. A capacidade de processar um grande número de atributos sem perda significativa de desempenho é uma das razões pelas quais esse classificador se tornou amplamente adotado na área.

Sua robustez advém da combinação dos classificadores, sendo a predição final baseada no voto majoritário das árvores. O uso de amostras “fora da bolsa” (out-of-bag) permite avaliar o desempenho sem a necessidade de um conjunto de validação separado. Essa abordagem reduz a multicolinearidade e aumenta a generalização do modelo. Assim, o RF tem se destacado como uma técnica eficaz para classificação e regressão em diversos contextos. Para melhorar a precisão da classificação, este classificador utiliza a tomada de decisão combinada de múltiplas CART (Classification and Regression Trees) (Farnaz, 2024). Complementarmente, Belgiu e Drăguț (2016) destacam que o RF apresenta baixa sensibilidade ao sobreajuste, rapidez no processamento e desempenho superior quando comparado a classificadores tradicionais, como SVM, CART e Redes Neurais. Os autores também enfatizam a utilidade da métrica de importância das variáveis (Variable Importance), que auxilia na identificação dos atributos mais relevantes e na redução da dimensionalidade, tornando o algoritmo especialmente adequado para aplicações ambientais.

Figura 1: Classificador utilizando o método RF



3.1.1.1 Multi-Layer Perceptron

O Perceptron Multicamadas (MLP) é um algoritmo de aprendizado supervisionado que aprende uma função por meio de treinamento em um conjunto de dados, onde o número de dimensões para a entrada é o número de dimensões para a saída (Congedo, 2020). Dado um conjunto de características e um alvo, ele pode aprender um aproximador de função não linear para classificação ou regressão. Ele difere da regressão logística, pois entre as camadas de entrada e saída, pode haver uma ou mais camadas não lineares, chamadas camadas ocultas. (Scikit-learn, 2025).

Além dessas características, o MLP destaca-se pela capacidade de modelar relações complexas entre variáveis, tornando-se especialmente útil em cenários em que as classes apresentam sobreposição espectral ou comportamento não linear, como ocorre frequentemente em sensoriamento remoto. Seu processo de aprendizado utiliza o algoritmo de retropropagação para ajustar iterativamente os pesos das conexões neuronais, reduzindo o erro entre as saídas previstas e as reais. Em aplicações ambientais, o MLP tem sido amplamente empregado para identificar padrões multitemporais e, quando integrado a modelos estocásticos como as Cadeias de Markov, apresenta elevado desempenho na previsão espacial de mudanças no uso e cobertura da terra, produzindo simulações consistentes e espacialmente coerentes (Saha, 2022).


3.1.1.2 Support Vector Machine

A Support Vector Machine (SVM) é um algoritmo supervisionado de classificação baseado na definição de hiperplanos que separam os dados de entrada em classes distintas (Congedo, 2020). Seu funcionamento se baseia na criação de um hiperplano que separa as classes dentro de um espaço n -dimensional. Esse hiperplano é definido a partir dos vetores de suporte nos pontos extremos dos dados, sendo seu objetivo maximizar a margem entre as classes conforme ilustrado na Figura 2. A distância entre os vetores de suporte e o hiperplano é chamada de margem, e quando essa margem é maximizada, obtém-se o chamado hiperplano ótimo, que favorece a generalização do modelo e reduz os efeitos do ruído nos dados (Ramachandra; Mondal; Setturu, 2023).

A técnica utiliza a teoria do aprendizado estatístico, transformando os dados em um

espaço de alta dimensionalidade por meio de funções kernel. A SVM é amplamente aplicada em classificações binárias, como na distinção entre áreas inundadas e não inundadas. Sua eficácia depende da escolha adequada do kernel, o que impacta diretamente na acurácia do modelo (Islam, 2025). A capacidade da SVM de operar em espaços de alta dimensão e maximizar as margens entre classes a torna uma ferramenta poderosa para diversas aplicações em aprendizado de máquina e análise de dados (Farnaz, 2024).

Figura 2: Classificador utilizando o método SVM



Fonte: Ramachandra (2023)

A escolha dos algoritmos Random Forest (RF) e Support Vector Machine (SVM) neste trabalho se justifica pela complementaridade de suas abordagens e pela alta precisão demonstrada em estudos de classificação do uso e cobertura da terra. O Random Forest foi empregado devido à sua robustez e eficiência em análises ambientais complexas, pois combina múltiplas árvores de decisão para aprimorar o desempenho e reduzir erros de classificação. Essa técnica de aprendizado de máquina apresenta excelente capacidade de generalização, sendo resistente a ruídos e valores extremos, além de demandar poucos parâmetros de ajuste, basicamente o número de árvores (*ntree*) e o número de variáveis por divisão (*mtry*) (Noi; Kappas, 2018). De acordo com Tikuye et al. (2023), algoritmos de *ensemble* como o RF oferecem soluções mais estáveis e precisas na análise multitemporal de imagens de satélite.

Já o Support Vector Machine (SVM) foi selecionado por sua eficácia na separação de classes com limites não lineares, utilizando funções de kernel que permitem projetar os dados em espaços de maior dimensão para otimizar a classificação. Essa característica o torna

especialmente útil em áreas com alta heterogeneidade espectral, comuns em ambientes rurais e florestais. Segundo Ramachandra, Mondal e Setturu (2023), o SVM é amplamente reconhecido por seu desempenho consistente mesmo em conjuntos de dados reduzidos, complementando a abordagem do RF em contextos onde as classes apresentam maior sobreposição espectral. Dessa forma, a aplicação conjunta dos dois algoritmos neste estudo buscou aumentar a confiabilidade dos resultados e validar a coerência espacial das classificações obtidas.

3.2 Resposta Hidrológica, Uso da Terra e Implicações para Áreas Suscetíveis a Inundações

A compreensão da resposta hidrológica em microbacias é fundamental para avaliar como as alterações no uso da terra influenciam a geração de escoamento, especialmente em áreas suscetíveis a inundações. Esse conjunto de processos envolve a transformação da precipitação em escoamento superficial, infiltração e armazenamento, sendo regulado por fatores como cobertura vegetal, tipos de solo, rugosidade superficial, intensidade da chuva e umidade antecedente. Mudanças antrópicas que reduzem a proteção do solo como desmatamento, remoção de vegetação nativa ou expansão agrícola tendem a aumentar a velocidade e o volume do escoamento, elevando picos de descarga e ampliando o risco de erosão, enchentes e transporte de sedimentos. Em contrapartida, áreas com vegetação conservada ou restaurada apresentam maior dissipação de energia da chuva e maior infiltração, resultando em respostas hidrológicas mais estáveis (Rodrigues, 2013).


Além dos fatores estruturais da bacia, a resposta hidrológica também é modulada por variabilidades climáticas de grande escala, como o fenômeno ENSO (El Niño–Oscilação Sul), que influencia diretamente a precipitação e, portanto, o comportamento das vazões. Estudos mostram que regiões brasileiras, como o Nordeste e o Sul, apresentam forte sensibilidade às fases de El Niño e La Niña, que podem intensificar ou reduzir as chuvas e modificar significativamente os padrões de escoamento. A interação entre essas variáveis climáticas e o uso da terra define a magnitude, a frequência e o tempo de resposta das inundações, tornando o processo hidrológico altamente complexo e multivariado (Carrielo, 2005).

4 MATERIAS E MÉTODOS

4.1 Características gerais da área de estudo

A área de estudo situa-se entre os paralelos 27° 37' 17.42" de Latitude e, 52° 22' 38.82" de Longitude, com uma área aproximada de 260,50 km² (Figura 3) e tem como limitantes territoriais os municípios de Barra do Rio Azul (norte), Gaurama (nordeste), Monte Alegre(noroeste), Ponte Preta (sudoeste), Paulo Bento (sul) e Erechim (leste). Segundo o IBGE (2024), a população Cotegipense era constituída por 7144 habitantes, com uma densidade demográfica de 27,42 hab/km².

Figura 3: Localização do município de Barão de Cotegipe -RS




Fonte: Autoria Própria (2025)

A região apresenta uma geomorfologia característica de planícies de sedimentação, com solos formados a partir de deposições aluviais e coluviais. Quanto à geologia, predominam os solos de origem sedimentar, como argilas, areias e cascalhos. O Município de Barão do Cotegipe situa-se no Planalto Meridional (ou Basáltico), formado por rochas basálticas decorrentes de um grande derrame de lavas, ocorrido na era Mesozoica. Geologicamente a região em que está inserido o município sofreu atividades vulcânicas do complexo cristalino, provocando um derrame basáltico, o qual forma vales profundos com ombreiras escarpadas, trechos retilíneos devido ao controle estrutural e corredeiras,

apresentando grandes números de formação de banhados, rios e lagos. Na Figura 3a, encontra-se o mapa geomorfológico do Rio Grande do Sul, estado onde está situada a cidade de Barão do Cotegipe (Felipetto, 2021).

Figura 3a. Mapa Geomorfológico do Rio Grande do Sul




Fonte: Dantas (2010)

O clima de Barão de Cotegipe é classificado como subtropical úmido, com verões quentes e invernos frios. As temperaturas médias anuais variam em torno de 18°C, com precipitação distribuída ao longo do ano, sendo 145 mm em média a cada mês, onde os meses do outono são mais chuvosos.

A hidrologia da região do Alto Uruguai é marcada pela presença de rios e arroios que drenam a área, sendo parte da bacia hidrográfica do Rio Uruguai (Figura 3b). A Bacia Hidrográfica do Rio Passo Fundo está localizada ao norte do Estado do Rio Grande do Sul, compreendendo uma área delimitada pelas coordenadas geográficas 27°04' a 28°19' de latitude Sul e 52°13' a 52°51' de longitude Oeste. Pertencente à Região Hidrográfica do Uruguai, essa bacia tem uma extensão de 4.859 km². No sistema de divisão das bacias hidrográficas do estado aprovado pelo Conselho de Recursos Hídricos, ela é identificada pela sigla U-20 (SEMA, 2009). Já a Bacia Hidrográfica dos rios Apuaê-Inhandava está situada na Região Hidrográfica do Rio Uruguai, na parte norte-nordeste do estado do Rio Grande do Sul, abrangendo as coordenadas geográficas 27°14' a 28°45' de latitude Sul e 50°42' a 52°26' de longitude Oeste. Com uma área de 14.479,14 km², representa aproximadamente 5,14% da área total do Estado do Rio Grande do Sul, sendo designada como U010 (SEMA, 2009).

Figura 3b. Hidrologia de Barão de Cotegipe-RS



Fonte: Autoria Própria (2025)

4.2 Semi-Automatic Classification Plugin (SCP)


O Semi-Automatic Classification Plugin (SCP) é uma ferramenta de código aberto desenvolvida por *Congedo (2023)*, amplamente utilizada em ambientes do QGIS para o processamento digital de imagens de sensoriamento remoto. Esse plugin permite tanto classificações supervisionadas quanto não supervisionadas, aplicando algoritmos capazes de distinguir diferentes tipos de cobertura e uso da terra a partir de assinaturas espectrais obtidas de amostras representativas.

Além de possibilitar o treinamento e a validação de classes por meio das Regiões de Interesse (ROIs), o SCP também integra funcionalidades de pré-processamento (como o recorte de imagens, correção atmosférica e conversão para reflectância), o que garante maior confiabilidade nos resultados. O plugin se destaca por incluir uma série de ferramentas que automatizam etapas do fluxo de trabalho, desde o download das imagens até a geração dos mapas finais de classificação.

A interface do SCP (Figura 3C) é intuitiva e de fácil operação, permitindo que o usuário configure rapidamente todo o processo desde a preparação das imagens até a análise quantitativa da acurácia. Assim, o SCP pode ser entendido como um ambiente completo para o tratamento de dados de sensoriamento remoto, cuja estrutura pode ser resumida da seguinte maneira (Figura 3D):


- Aquisição de imagens orbitais por meio de plataformas de teledetecção;
- Pré-processamento das imagens, com recorte, correção atmosférica e conversão espectral;
- Processamento e classificação supervisionada com base em algoritmos de aprendizado;
- Pós-processamento e refinamento, incluindo interpretação visual e ajuste das classes;
- Avaliação da acurácia, com criação de amostras de validação e cálculo de métricas de precisão.

Figura 3C. Interface do plugin SCP automatic classification



Fonte: Autoria Própria (2025)

Figura 3D. Diagrama dos procedimentos desenvolvidos para fazer a classificação



Fonte: Autoria Própria (2025)

4.3 Imagens de satélite multiespectrais e processamento de dados no QGIS

Foram utilizadas imagens multitemporais dos satélites Landsat 7 e Landsat 8, referentes às datas seguintes: (2003/03/27; 2003/05/14; 2003/05/30; 2013/05/09; 2013/05/17; 2013/04/03; 2023/04/03; 2023/04/21; 2023/05/13), com um limite máximo de cobertura de nuvens de 10%. e boa visibilidade da superfície terrestre. As imagens do Landsat 7, referentes ao ano de 2003, utilizaram as bandas B1, B2, B3 e B4 (Tabela 1), enquanto as do Landsat 8, correspondentes aos anos de 2013 e 2023, empregaram as bandas B2, B3, B4 e B5 (Tabela 2), abrangendo faixas espectrais do visível ao infravermelho próximo, o que possibilita a diferenciação de alvos como vegetação, solo exposto, corpos d'água e áreas agrícolas.

Todas as imagens apresentam resolução espacial de 30 metros, garantindo uniformidade na análise comparativa entre os períodos. O download das cenas foi realizado a partir da plataforma gratuita USGS EarthExplorer, e os arquivos foram submetidos às etapas de recorte da área de estudo, correção atmosférica e conversão dos valores digitais (DN) em

reflectância, assegurando a qualidade e a padronização dos dados utilizados.

A partir das bandas processadas, foram gerados compósitos coloridos que facilitaram a interpretação visual dos elementos da paisagem e a identificação das áreas de interesse. Com base nessas imagens, foram delimitadas Regiões de Interesse (ROIs) por meio de polígonos vetoriais desenhados sobre regiões homogêneas.

Tendo-se em vista a grande variedade de fontes de informação utilizadas na avaliação multitemporal, optou-se por adotar uma legenda a fim de possibilitar a uniformização das informações temáticas para todos os momentos avaliados integrando-se as informações de forma a qualificar e quantificar as mudanças ocorridas no uso e cobertura da terra no município de Barão de Cotegipe-RS. Assim, a legenda estabelecida para a série de mapeamentos multitemporais é a seguinte:

- Floresta – compreende as formações florestais dentre elas: mata ciliar, mata de galeria, mata mesofítica, mata de encosta, cerrado e reflorestamento correspondendo às áreas com plantios homogêneos de eucaliptos;
- Agricultura – compreende as áreas ocupadas por culturas intensivas, áreas irrigadas, chácaras caracterizadas pela coexistência de atividades agrícolas; Pastagem, as formações com extrato predominantemente herbáceo de caráter antropizado;
- Água – corresponde aos espelhos d'água formados por lagos, lagoas e represas.
- Solo Exposto – corresponde às áreas sem nenhuma cobertura com exposição direta do solo às intempéries, tais como solo em pousio (preparado para o plantio);

Tabela 1: Propriedades do Satélite Landsat 7 ETM+ com o seu sensor, resolução espacial, resolução espectral, banda espectrais e o comprimento da onda central

Sensor	Resolução Espacial	Resolução Temporal	Área imageada	Resolução Radiométrica	Número da Banda	Bandas Espectrais	Comprimento da Onda Central
Landsat 7 Enhanced Thematic Mapper Plus (ETM+)	30 m	16 dias	185 km	8 bits	B1	Blue	0.45 - 0.52 μm
					B2	Green	0.52 - 0.60 μm
					B3	Red	0.63 - 0.69 μm
					B4	infravermelho próximo	0.77 - 0.90 μm
	60 m				B5	Infravermelho de ondas curtas	1.55 - 1.75 μm
	30 m				B6	Térmica	10.40 - 12.50 μm
	15 m				B7	Infravermelho médio	2.08 - 2.35 μm
					B8	Pancromática	0,52 - 0,90 μm

Fonte: [USGS \(2025\)](#). Elaborado pelo autor (2025)

Tabela 2: Propriedades do Satélite Landsat 8 com o seu sensor, resolução espacial, resolução espectral, banda espectrais e o comprimento da onda central

Sensor	Resolução Espacial	Resolução Temporal	Área imageada	Resolução Radiométrica	Número da Banda	Bandas Espectrais	Comprimento da Onda Central
OLI (Operational Land Imager)	30 m	16 dias	170 x 183 km	16 bits	B1	Azul Costeira	0.43 - 0.45 μm
					B2	Azul	0.45 - 0.51 μm
					B3	Verde	0.53 - 0.59 μm
					B4	Vermelho	0.64 - 0.67 μm
					B5	Infravermelho próximo	0.85 - 0.88 μm
					B6	Infravermelho médio	1.57 - 1.65 μm
					B7	infravermelho médio	2.11 - 2.29 μm
					B8	Pancromática	0.50 - 0.68 μm
					B9	Cirrus	1.36 - 1.38 μm
TIRS (Thermal Infrared Sensor)	100 m	16 dias	170 x 183 km	16 bits	B10	Infravermelho termal	10.6 - 11.19 μm
	100 m				B11	Infravermelho termal	11.5 - 12.51 μm

Fonte: [ENGESAT\(2025\)](#) (2015). Elaborado pelo autor (2025)

5 RESULTADOS E DISCUSSÃO

5.1 Análise Multitemporal do Uso e Cobertura da Terra de Barão de Cotegipe-RS

A partir do pré-processamento e classificação supervisionada das imagens de 2003, 2013 e 2023, obtiveram-se mapas temáticos para cada ano respectivamente (Mapa 1b). Pelo método SVM (Gráfico 2), observa-se que a Floresta apresentou decréscimo contínuo, passando de 97 km² em 2003 para 85 km² em 2013 e 74 km² em 2023, o que indica perda gradual de aproximadamente 23,7% da cobertura vegetal, por substituição de usos antrópicos e da ausência da recomposição florestal.

A Agricultura, por sua vez, manteve-se como a principal classe de uso, embora com variações sutis ao longo do período: de 181,730 km² em 2003, reduziu levemente para 172,447 km² em 2013 (A área ocupada por floresta representa 33,30% do município, valor que confirma o resultado obtido por Rovani et al. (2015), que identificaram 33,84% de cobertura florestal em Barão de Cotegipe-RS.) e voltou a crescer para 177,855 km² em 2023.


O Solo Exposto apresentou comportamento instável (Gráfico 2), iniciando com um valor elevado de 22,814 km² em 2003, reduzindo drasticamente para 0,287 km² em 2013 e mantendo-se em 0,870 km² em 2023. Essa expressiva diminuição indica a substituição de

áreas descobertas por outros usos, especialmente agrícolas e vegetacionais, embora parte da variação também possa estar associada à limitação do algoritmo SVM em diferenciar superfícies agrícolas recém-preparadas. Já a classe Água manteve-se praticamente constante, variando levemente de 0,111 km² em 2003 para 0,210 km² em 2023.

Nos resultados do RF (Gráfico 1), as tendências são mais consistentes e condizentes com o padrão espacial das classes de usos apresentados no Mapa 1a e Gráfico 1. A Floresta apresentou queda contínua, de 89,157 km² em 2003 para 75,13 km² em 2013 e 74,06 km² em 2023, refletindo o avanço da agricultura sobre áreas antes vegetadas e representando uma perda total de 17,8%. A Agricultura aumentou de 137,729 km² em 2003 para 162,22 km² em 2013, estabilizando-se em aproximadamente 157,81 km² em 2023, o que confirma a expansão agrícola de 14,6% nas duas primeiras décadas e confirmando-se como o principal uso da terra no município.


O Solo Exposto diminuiu gradualmente, de 36,29 km² em 2003 para 22,35 km² em 2013 e 27,29 km² em 2023, enquanto a classe Água teve baixa representatividade, com uma redução inicial de 2,32 km² em 2003 para 0,781 km² em 2013 e uma leve recuperação em 2023 (1,301 km²).

Mapa 1a: Classificações realizadas com os algoritmos RF




Fonte: Autoria Própria (2025)

Gráfico 1 – Classes de uso da terra (Floresta, Agricultura, Água e Solo Exposto) - Random Forest




Fonte: Autoria Própria (2025)

Mapa 1b: Classificações realizadas com os algoritmos SVM



Fonte: Autoria Própria (2025)

Gráfico 2 – Classes de uso da terra (Floresta, Agricultura, Água e Solo Exposto) - Support Machine Vector



Fonte: Autoria Própria (2025)

4.2.2 Avaliação de precisão

Para quantificar a confiabilidade dos mapas temáticos de uso da terra produzidos (Mapa 1a e Mapa 1b), foi realizada uma avaliação de acurácia, baseada na comparação entre os produtos classificados e uma base de referência vetorial representando o pixel de cada classe. Essa base foi construída a partir da vetorização manual de polígonos representativos das macro classes definidas neste estudo (Floresta, Agricultura, Solo Exposto e Água), com base em composições RGB gerado dentro do plugin SCP, conforme as bandas descritas na tabela 1 e 2.

Uma amostragem estratificada desses polígonos foi posteriormente convertida em pixels de validação, confrontados com os pixels correspondentes ao mapa classificado, permitindo a elaboração da Matriz de Erro. A partir dela, calcularam-se automaticamente dentro do plugin as métricas estatísticas Acurácia Global (Overall Accuracy) e Coeficiente Kappa (Khat), que expressam o grau de concordância entre o mapa classificado e os dados de referência (polígonos referente aos pixels dos macro classes).

Tabela 3: Avaliação da precisão das classificações multitemporais.

Random Forest	2003	2013	2023
Overall Accuracy(%)	98.1325	98.4797	98.4649
Kappa hat classification	0.9689	0.9711	0.9705

Fonte: Autoria Própria (2025)

Os resultados obtidos para o algoritmo Random Forest (RF) (Tabela 3) demonstram desempenho excepcional em todas as séries temporais analisadas. As acurácias globais alcançaram uma média de 98,13% (2003), 98,47% (2013) e 98,46% (2023), com coeficientes Kappa de 0,9689, 0,9711 e 0,9705 a notar que são valores médios dos três mapas anual da série, respectivamente. Segundo a escala proposta por Landis e Koch (1977), esses valores correspondem à categoria de concordância quase perfeita (0,81–1,00) (tabela 4), o que indica altíssima confiabilidade na classificação.

Esse comportamento revela a capacidade do RF de distinguir com precisão classes espectralmente próximas, especialmente nas transições entre Agricultura e Floresta, e de lidar com variações radiométricas e sazonais ao longo das imagens Landsat analisadas. O método mostrou-se consistente em diferentes condições atmosféricas e espectrais, mantendo variações inferiores a 0,01 no índice Kappa entre os anos, o que reforça sua robustez estatística. Tais resultados são comparáveis aos obtidos em estudos anteriores, como o de Tikuye et al. (2023), que reportaram acurácia global de 92,6% e Kappa de 0,86 em análises multitemporais com RF, confirmando a eficiência desse classificador em ambientes agrícolas e heterogêneos.

Tabela 4: Medidas de Concordância para Dados Categóricos

Estatística Kappa	Força de Concordância
< 0	Pobre
0,00 - 0,20	Leve
0,21 - 0,40	Razoável
0,41 - 0,60	Moderada
0,61 - 0,80	Substancia
0,81 - 1,00	Quase Perfeita

Fonte: (Ferreira, 2007)

Em contrapartida, o algoritmo Support Vector Machine (SVM) apresentou comportamento mais variável, conforme evidenciado na Tabela 5. A média de acurácia global oscilou entre 55,42% (2003), 81,62% (2013) e 55,13% (2023), enquanto a média do coeficiente Kappa variou de 0,4562 a 0,6530 e 0,4429. Esses valores situam-se entre concordância moderada e substancial, com desempenho satisfatório apenas em 2013.

As reduções observadas em 2003 e 2023 sugerem maior sensibilidade do SVM à heterogeneidade espectral e à definição dos parâmetros de kernel, fatores que afetam a capacidade do modelo de generalizar padrões complexos de paisagem. Além disso, a confusão entre Agricultura e Solo Exposto, evidenciada no Mapa 1a e Mapa 1b, contribuiu para a queda do índice Kappa nos anos extremos, indicando que o SVM tende a subestimar áreas de floresta e superestimar superfícies desnudas.

Tabela 5: Avaliação da precisão das classificações multitemporais.

Support Vector Machine	2003	2013	2023
Overall Accuracy(%)	55.4238	81.6172	55.1364
Kappa hat classification	0.4562	0.6530	0.4429

Fonte: Autoria Própria (2025)

5.2 Análise espaço-temporal do uso e cobertura da terra na bacia urbana

A análise da bacia urbana de Barão de Cotegipe (Mapa 2), evidencia um padrão espacial dominado pela agricultura, com redução contínua da cobertura florestal e variações pontuais nas classes de Água e Solo Exposto ao longo do período de 2003 a 2023.

Em 2003, a bacia ainda apresentava uma expressiva presença de vegetação, com a Floresta ocupando aproximadamente 10 km². No entanto, a Agricultura já se destacava como atividade predominante, cobrindo cerca de 24 km², e 0,413 km² para classe de água e 4,946 km² para solo exposto. Esse cenário reflete uma paisagem em processo de transformação, consolidada para o uso agropecuário (Gráfico 3).


Observa-se em 2013 que a Floresta reduziu-se para 7,629 km², enquanto a Agricultura expandiu para 26,533 km², tornando-se a classe hegemônica na bacia. Este período coincide com uma trajetória de valorização das commodities agrícolas, com os preços futuros da soja

apresentando uma tendência de alta consistente saindo de patamares em torno de US\$ 24.50 (2003), atingindo picos próximos a US\$ 1.510 (2013) e se mantendo em níveis historicamente elevados, próximos a US\$ 1.418 (2023). De forma similar, o milho, cultura frequentemente associada em rotação com a soja, também experimentou uma valorização expressiva, saltando de US\$ 2,24 (2003) para US\$ 6,79 (2013) por bushel. Essa valorização conjunta funcionou como um duplo estímulo econômico para a conversão de áreas de vegetação nativa e outras coberturas em lavouras comerciais na região de Barão de Cotegipe, onde permanecem a constante cultivação desses cultivos. A fase foi marcada pela substituição significativa de vegetação nativa por cultivos, pastagens e outras atividades, acompanhada pela retração expressiva dos corpos hídricos superficiais, que diminuíram para 0,144 km² e do solo exposto para 4,127 km². Tais mudanças indicam uma possível compactação do solo e redução da infiltração, agravando a vulnerabilidade ambiental da bacia hidrográfica.


Em 2023, confirma-se a consolidação do modelo agrícola na bacia, com a classe Floresta atingindo cerca de 7,885 km², representando aproximadamente 20,37% da cobertura total da área, valor levemente superior ao de 2013, mantendo a tendência de perda de cobertura vegetal em relação a 2003. A Agricultura permanece como a principal forma de uso da terra, ocupando aproximadamente 24,955 km² cerca de 64% do uso da terra na bacia. E o Solo Exposto, por sua vez, apresentou aumento para 5,5 km², enquanto a Água superficial registrou uma leve recuperação (0,248 km²), porém ainda em níveis muito inferiores aos observados no início da série em 2003.

O solo exposto por sua vez chegou a 5,5 km² em 2023 e pode intensificar processos erosivos e aumentar o carregamento de sedimentos para os cursos d'água. A adoção de práticas conservacionistas, como o plantio direto e a manutenção de matas ciliares conforme estabelecido no código florestal (Lei 12.651/2012), seria essencial para reduzir esses impactos. No entanto, a persistência de extensas áreas sem cobertura vegetal natural indica que tais medidas ainda não são uma realidade consolidada em toda a bacia.

Bacia hidrográfica




Legenda



RF-Bacia Hidrográfica Urbana						
Uso da Terra	2003		2013		2023	
	Área(km²)	Área(%)	Área(km²)	Área(%)	Área(km²)	Área(%)
Floresta	10.008	25.33%	7.629	19.85%	7.885	20.37%
Agricultura	24.14	61.10%	26.533	69.04%	24.955	64.46%
Solo Exposto	4.946	12.52%	4.127	10.74%	5.625	14.53%
Água	0.413	1.05%	0.144	0.37%	0.248	0.64%

Fonte: Autoria Própria (2025)

Gráfico 3 – Classes de uso da terra na Bacia



Fonte: Autoria Própria (2025)

5.2.0 Uso e Cobertura das Terras na área restrita legalmente

Com base na análise dos dados apresentados no Gráfico 3.0 e Mapa 2.0, observa-se que a classe Floresta apresentou uma rota de recuperação, registrando 1,7 km² em 2003, seguida por uma redução para 1,4 km² em 2013, indicando um período de perda de cobertura vegetal, possivelmente devido a pressões antrópicas. No entanto, em 2023, a área florestal retornou ao patamar inicial de 1,7 km², sugerindo processos de regeneração natural ou iniciativas de recomposição da mata ciliar (reflorestamento).


Em contraste, a Agricultura exibiu crescimento de 3,842 km² em 2003 para 4,15 km² em 2013, mas subsequentemente registrando uma redução para 3,747 km² em 2023. O padrão observado indica que, após um período de expansão sobre outras coberturas terrestres, possivelmente incluindo áreas de vegetação nativa, ocorreu uma transição que resultou na conversão de terras agrícolas para outros usos, o que pode estar relacionado a processos de regeneração natural, políticas de conservação ou mudanças nas atividades econômicas da região.

A superfície de Água experimentou uma variação significativa, com uma redução drástica de 0,078 km² para 0,047 km² entre 2003 e 2013, o que pode estar associado a períodos de seca, aumento da captação ou assoreamento. Posteriormente, houve um leve

aumento para 0,066 km² em 2023. Já a classe Solo Exposto manteve-se relativamente estável ao longo de todo o período, com áreas em torno de 0,9 km², sugerindo que a expansão agrícola não resultou em um aumento generalizado de áreas degradadas, mas sim em uma substituição direta da cobertura natural.


A análise integrada desses dados revela, portanto, uma trajetória de substituição da cobertura florestal por atividades antrópicas, especificamente a agricultura, o que realça a importância de políticas de gestão territorial, sobretudo para a proteção e recuperação das matas ciliares nas Áreas de Preservação Permanente (APP), essenciais para a conservação dos recursos hídricos.

Mapa 2.0 : Dinâmica da mata ciliar na bacia urbana



Fonte: Autoria Própria (2025)

Gráfico 3.0 – Classes de uso da terra na APP



Fonte: Autoria Própria (2025)

5.2.1 Análise das sub-bacias componentes da bacia urbana

Com base na análise integrada do Mapa 3 e dos dados quantitativos observados no Gráfico 4, a dinâmica de uso da terra na Sub-bacia 1 entre 2003 e 2023 revela transformações significativas, com destaque para a intensa pressão antrópica sobre o ambiente natural.

A classe Floresta, essencial para a conservação dos recursos hídricos e a estabilidade do ecossistema, apresentou um preocupante declínio contínuo, reduzindo de 0,2875 km² em 2003 para 0,264 km² em 2013 e, posteriormente, para 0,225 km² em 2023. Essa perda total de aproximadamente 21% da área original, indica um processo consistente de fragmentação e supressão de vegetação nativa.


Em sentido oposto, a Agricultura consolidou-se como a classe dominante na paisagem, mantendo-se como a principal forma de uso da terra, com uma área que cresceu de 0,8427 km² em 2003 para 0,912 km² em 2013, estabilizando-se em 0,904 km² em 2023. Essa expansão inicial, seguida de relativa estabilização em patamar elevado, sugere a conversão de áreas naturais para atividades agropecuárias, configurando-se como o principal vetor de transformação da paisagem na sub-bacia.

A superfície de Água apresentou uma variação brusca, com uma redução de 100% entre 2003 (0,009 km²) e 2013 (0,0009 km²), seguida pela recuperação em 2023 (0,009 km²).

Essa dinâmica pode estar relacionada a fatores como variações climáticas, alterações no regime hídrico


A classe Solo Exposto revelou uma dinâmica particularmente interessante, registrando 0,139 km² em 2003, seguida por uma expressiva redução para 0,0835 km² em 2013, e uma recuperação de aproximadamente 0,139 km² em 2023. Esta trajetória não linear sugere processos complexos de uso e manejo do solo, possivelmente relacionados a ciclos de preparo de terreno para agricultura seguidos por períodos de cobertura vegetal, embora o aumento verificado no último período indique uma retomada de áreas expostas.

Mapa 3 : Uso da terra na Sub-bacia 1



Fonte: Autoria Própria (2025)

Gráfico 4 – Classes de uso e cobertura da terra na Sub-Bacia 1



Fonte: Autoria Própria (2025)

De acordo ilustrado no Mapa 4, a Sub-Bacia 2 apresenta uma paisagem marcada pela forte presença da Agricultura e da Floresta, com ocorrências pontuais de Solo Exposto e Água ao longo da série histórica analisada. Os dados médios apresentados no Gráfico 5 permitem acompanhar as mudanças na cobertura do solo entre 2003 e 2023.


A classe Floresta, essencial para a estabilidade ecossistêmica, apresentou uma ligeira redução de 2,185 km² em 2003 para 2,01 km² em 2013, seguida por um aumento para 2,621 km² em 2023. Esse comportamento sugere que, após um período de pressão antrópica que resultou em perda de cobertura vegetal, processos de regeneração natural ou ações de recuperação permitiram a recomposição da área florestal na sub-bacia.

A Agricultura, principal uso antrópico na paisagem do município, expandiu-se de 6,789 km² em 2003 para 7,319 km² em 2013, mas retornou ao patamar inicial de 6,789 km² em 2023, indicando uma possível intensificação do uso das terras agrícolas ou conversão de algumas áreas para outros usos. A superfície de Água apresentou uma variação significativa, com redução acentuada de 0,058 km² para 0,035 km² entre 2003 e 2013, seguida por recuperação de 0,058 km² em 2023, refletindo a sensibilidade dos corpos hídricos às variações climáticas e às alterações no uso da terra.

A classe Solo Exposto, reduziu de 1,0 km² em 2003 para 0,8 km² em 2013, mas


apresentou aumento para 1,2 km² em 2023, superando o valor inicial e sugerindo um recente processo de exposição do solo, possivelmente relacionado a atividades antrópicas ou eventos naturais.

Mapa 4 : Uso da terra na Sub-bacia 2



Fonte: Autoria Própria (2025)

Gráfico 5 – Classes de uso da terra na Sub-Bacia 2



Fonte: Autoria Própria (2025)

A configuração da Sub-bacia 3 apresenta particularidades notáveis em relação às demais áreas estudadas, com dinâmicas que revelam tanto processos de conservação quanto transformações ambientais significativas. A evolução da cobertura florestal demonstra uma transformação positiva, registrando 0,907 km² em 2003, com discreta redução para 0,880 km² em 2013, seguida de expressiva expansão para 0,971 km² em 2023. Este crescimento de aproximadamente 6,6% em relação à área inicial, indica cenário favorável à conservação da biodiversidade e aos serviços ecossistêmicos como, por exemplo, projetos de reflorestamento.


A atividade agrícola manteve estabilidade ao longo de toda a série temporal, 1,599 km² em 2003, 1,653 km² em 2013 e 1,599 km² em 2023. A pouca variabilidade sugere que a sub-bacia não experimentou processos significativos de expansão ou retração da fronteira agrícola, possivelmente indicando zoneamento consolidado ou práticas de uso sustentável da terra.

Os corpos hídricos apresentaram a variação mais significativa entre todas as classes analisadas, com redução de aproximadamente 0,0055 km² para 0,0009 km² entre 2003 e 2013, seguida por um aumento de cerca de 0,009 km² em 2023. É importante destacar que estas flutuações extremas podem estar relacionadas particularmente à resolução espacial de 30 metros utilizada na classificação. Esta resolução pode ter gerado confusão espectral entre

pixels de água e outras classes, especialmente em áreas de corpos hídricos estreitos ou com vegetação ribeirinha densa, onde ocorre o efeito de pixels mistos ou pelas características altimétricas (a mais baixa das sub bacias) e portanto mais áreas inundáveis.


A exposição do solo apresentou evolução favorável, com redução consistente de 0,301 km² em 2003 para 0,218 km² em 2013 e, posteriormente, para 0,208 km² em 2023. Este declínio gradual, totalizando redução de aproximadamente 33% ao longo do período, sugere eficiência em estratégias de cobertura vegetal e manejo conservacionista.

Mapa 5 : Uso da terra na Sub-bacia 3



Fonte: Autoria Própria (2025)

Gráfico 6 – Classes de uso da terra na Sub-Bacia 3



Fonte: Autoria Própria (2025)


A cobertura florestal demonstrou uma trajetória inicialmente negativa, com redução de 0,701 km² em 2003 para 0,540 km² em 2013, representando uma perda expressiva de 21,4% em uma década. No entanto, o período subsequente registrou significativa recuperação, com aumento para 0,648 km² em 2023, indicando processos de regeneração natural ou possíveis ações de reflorestamento que reverteram parcialmente a tendência anterior.

A atividade agrícola aumentou de 2,268 km² em 2003 para 2,425 km² em 2013 e, posteriormente, reduzindo para 2,273 km² em 2023. Os corpos hídricos apresentaram comportamento flutuante, com redução inicial de 0,008 km² para 0,006 km² entre 2003 e 2013, seguida por expressiva expansão para 0,014 km² em 2023. Esta recuperação final, que representa mais que o dobro da área registrada em 2013, pode estar associada a variações climáticas, alterações no regime de precipitação.

O solo exposto apresentou tendência no período final, mantendo-se relativamente estável entre 2003 (0,288 km²) e 2013 (0,261 km²), mas registrando aumento significativo para 0,368 km² em 2023. Este incremento de aproximadamente 30% em relação ao período anterior constitui um alerta para processos recentes de degradação do solo, possivelmente relacionados a atividades antrópicas ou eventos naturais que resultaram na remoção da


cobertura vegetal.

Mapa 6 : Uso da terra na Sub-bacia 4



Fonte: Autoria Própria (2025)

Gráfico 7 – Classes de uso da terra na Sub-Bacia 4



Fonte: Autoria Própria (2025)


A Sub-bacia 5 apresentou uma dinâmica ambiental complexa ao longo das duas décadas analisadas, a cobertura florestal demonstrou notável resiliência, registrando 2,033 km² em 2003, seguida por uma contração para 1,838 km² em 2013, e subsequentemente uma recuperação integral para 2,034 km² em 2023. Este padrão de recuperação florestal ao final do período sugere a ocorrência de processos de regeneração natural ou a implementação de ações de recomposição da vegetação nativa.

O uso agrícola apresentou comportamento oscilante, com expansão inicial de 3,485 km² para 3,897 km² entre 2003 e 2013, seguida por retração para os 3,544 km² em 2023. A área cultivada permaneceu basicamente igual em todos os períodos. Já os corpos hídricos manifestaram sensibilidade às variações ambientais, com expressiva redução de 0,039 km² para 0,018 km² entre 2003 e 2013, representando uma perda de aproximadamente 55% na superfície aquática. O período subsequente registrou uma recuperação parcial para 0,034 km² em 2023, embora sem atingir o patamar inicial, refletindo possíveis alterações no regime hidrológico ou efeitos de intervenções antrópicas.

Por outro lado, o solo exposto apresentou uma evolução não linear, com redução significativa de 0,766 km² para 0,525 km² entre 2003 e 2013, indicando possíveis processos de revegetação ou melhorias no manejo do solo. Contudo, o aumento para 0,639 km² em 2023 representa uma reversão nesta tendência, sugerindo o recrudescimento de processos

degradativos ou mudanças no uso da terra na sub-bacia.

Mapa 7 : Uso da terra na Sub-bacia 5



Fonte: Autoria Própria (2025)

Gráfico 8 – Classes de uso da terra na Sub-Bacia 5



Fonte: Autoria Própria (2025)

A Sub-bacia 6, que representa a maior unidade territorial do estudo, apresentou transformações significativas em sua estrutura paisagística ao longo do período. A cobertura florestal, registrou 3,007 km² em 2003, com posterior declínio para 2,561 km² em 2013, seguido por substancial recuperação para 2,869 km² em 2023. Está quase completa a restauração da área florestal no período final e reflete processos ecológicos de regeneração ou possíveis iniciativas de conservação que reverteram a tendência de perda observada na década intermediária.


O setor agrícola consolidou-se como a principal forma de uso da terra nesta sub-bacia, apresentando expansão contínua de 12,536 km² em 2003 para 13,137 km² em 2013, com ligeira contração para 12,536 km² em 2023. A manutenção destes patamares elevados confirma a predominância das atividades agropecuárias na configuração da paisagem, embora a discreta redução final possa indicar processos de transição para outros usos da terra.

Os corpos hídricos exibiram sensibilidade às variações ambientais, com redução de 0,143 km² para 0,103 km² entre 2003 e 2013, seguida por recuperação parcial para 0,133 km² em 2023. Esta flutuação, que acompanha em certa medida o comportamento observado nas demais sub-bacias, pode estar associada a alterações no regime pluviométrico ou a modificações no uso da terra no entorno dos cursos d'água.

A classe de solo exposto apresentou tendência preocupante no período final, mantendo


relativa estabilidade entre 2003 (2,078 km²) e 2013 (2,045 km²), mas registrando expressivo aumento para 2,762 km² em 2023. Este incremento de aproximadamente 40% na última década constitui um alerta para processos recentes de degradação do solo, possivelmente relacionados à expansão de atividades antrópicas ou a eventos climáticos extremos que resultaram na remoção da cobertura vegetal.

Mapa 8 : Uso da terra na Sub-bacia 6



Fonte: Autoria Própria (2025)

Gráfico 9 – Classes de uso da terra na Sub-Bacia 6



Fonte: Autoria Própria (2025)

A síntese dos resultados referentes ao uso e cobertura da terra no período de 2003, 2013 a 2023 (Tabela 6) mostra uma dinâmica de transformação significativa na paisagem da área de estudo. Ao longo das duas décadas analisadas, observa-se uma trajetória clara de expansão das áreas antrópicas, notadamente da classe Água, que apresentou a variação percentual mais expressiva em praticamente todas as sub-bacias analisadas. Esse crescimento, no entanto, foi marcado por flutuações interanuais, sugerindo uma alta sensibilidade a fatores climáticos ou à própria resolução espacial do método de classificação, que pode ter captado áreas inundáveis sazonais.

De forma paralela e consistente, a classe Agricultura consolidou-se como a cobertura dominante do território, mantendo a maior porcentagem de área em todos os anos censitários. A estabilidade relativa desta classe indica a forte vocação econômica da região e sua persistência como principal vetor de modificação do uso da terra.

Em contrapartida, as classes Floresta e Solo Exposto demonstraram comportamentos variáveis e, em muitos casos, antagônicos. Enquanto as florestas sofreram um processo geral de redução de sua área, refletindo a pressão antrópica por expansão de terras para cultivo ou urbanização, a classe de Solo Exposto apresentou flutuações que podem estar intrinsecamente ligadas ao ciclo da agropecuária, sendo convertida em lavoura ou revelando áreas de pousio.

Os dados apontam para um processo contínuo de substituição de coberturas naturais

por usos antrópicos, com a agropecuária atuando como a principal força motriz dessa transformação. A aparente instabilidade de algumas classes, como a Água e o Solo Exposto, ressalta a importância de considerar a sazonalidade e as limitações metodológicas (resolução espacial) para uma interpretação precisa das tendências de longo prazo, que sinalizam para uma paisagem cada vez mais antropizada.

Tabela 6: Síntese geral dos resultados de uso da terra (2003,2013 e 2023).

SVM-Barão Cotegipe (RS)							RF-Barão Cotegipe (RS)						
Uso da Terra	2003		2013		2023		Uso da Terra	2003		2013		2023	
	Área(km²)	Área(%)	Área(km²)	Área(%)	Área(km²)	Área(%)		Área(km²)	Área(%)	Área(km²)	Área(%)	Área(km²)	Área(%)
Floresta	93.984	31.47%	86.410	33.30%	74.370	29.36%	Floresta	89.157	33.58%	75.13	28.84%	74.06	28.43%
Agricultura	181.730	60.85%	172.447	66.47%	177.855	70.21%	Agricultura	137.729	51.88%	162.22	62.28%	157.81	60.59%
Solo Exposto	22.814	7.64%	0.287	0.11%	0.870	0.34%	Solo Exposto	36.29	13.67%	22.35	8.58%	27.29	10.48%
Água	0.111	0.04%	0.310	0.12%	0.210	0.08%	Água	2.32	0.87%	0.781	0.30%	1.301	0.50%
Total	296.639		259.454		253.305			265.496		260.481		260.461	
RF-Bacia Hidrográfica Urbana							RF-Bacia Hidrográfica Urbana(APP)						
Uso da Terra	2003		2013		2023		Uso da Terra	2003		2013		2023	
	Área(km²)	Área(%)	Área(km²)	Área(%)	Área(km²)	Área(%)		Área(km²)	Área(%)	Área(km²)	Área(%)	Área(km²)	Área(%)
Floresta	10.008	25.33%	7.629	19.85%	7.885	20.37%	Floresta	1.674	25.73%	1.388	21.77%	1.677	26.18%
Agricultura	24.14	61.10%	26.533	69.04%	24.955	64.46%	Agricultura	3.842	59.04%	4.15	65.10%	3.747	58.50%
Solo Exposto	4.946	12.52%	4.127	10.74%	5.625	14.53%	Solo Exposto	0.913	14.03%	0.79	12.39%	0.915	14.29%
Água	0.413	1.05%	0.144	0.37%	0.248	0.64%	Água	0.078	1.20%	0.047	0.74%	0.066	1.03%
Total	39.507		38.433		38.713			6.507		6.375		6.405	
RF-Sub-Bacia 1							RF-Sub-Bacia 2						
Uso da Terra	2003		2013		2023		Uso da Terra	2003		2013		2023	
	Área(km²)	Área(%)	Área(km²)	Área(%)	Área(km²)	Área(%)		Área(km²)	Área(%)	Área(km²)	Área(%)	Área(km²)	Área(%)
Floresta	0.2875	22.49%	0.264	20.95%	0.225	17.62%	Floresta	2.185	21.83%	2.01	19.50%	2.162	21.19%
Agricultura	0.8427	65.93%	0.912	72.36%	0.904	70.79%	Agricultura	6.789	67.82%	7.319	71.02%	6.789	66.53%
Solo Exposto	0.139	10.87%	0.0835	6.62%	0.139	10.88%	Solo Exposto	0.979	9.78%	0.942	9.14%	1.196	11.72%
Água	0.009	0.70%	0.0009	0.07%	0.009	0.70%	Água	0.058	0.58%	0.035	0.34%	0.058	0.57%
Total	1.2782		1.2604		1.277			10.011		10.306		10.205	
RF-Sub-Bacia 3							RF-Sub-Bacia 4						
Uso da Terra	2003		2013		2023		Uso da Terra	2003		2013		2023	
	Área(km²)	Área(%)	Área(km²)	Área(%)	Área(km²)	Área(%)		Área(km²)	Área(%)	Área(km²)	Área(%)	Área(km²)	Área(%)
Floresta	0.907	32.25%	0.88	31.98%	0.971	32.52%	Floresta	0.701	21.47%	0.54	16.71%	0.648	19.62%
Agricultura	1.599	56.85%	1.653	60.07%	1.599	53.55%	Agricultura	2.268	69.46%	2.425	75.03%	2.273	68.82%
Solo Exposto	0.301	10.70%	0.218	7.92%	0.208	6.97%	Solo Exposto	0.288	8.82%	0.261	8.08%	0.368	11.14%
Água	0.0055	0.20%	0.0009	0.03%	0.208	6.97%	Água	0.008	0.25%	0.006	0.19%	0.014	0.42%
Total	2.8125		2.7519		2.986			3.265		3.232		3.303	
RF-Sub-Bacia 5							RF-Sub-Bacia 6						
Uso da Terra	2003		2013		2023		Uso da Terra	2003		2013		2023	
	Área(km²)	Área(%)	Área(km²)	Área(%)	Área(km²)	Área(%)		Área(km²)	Área(%)	Área(km²)	Área(%)	Área(km²)	Área(%)
Floresta	2.033	32.15%	1.838	29.28%	2.034	32.54%	Floresta	3.007	16.93%	2.561	14.35%	2.869	15.68%
Agricultura	3.485	55.12%	3.897	62.07%	3.544	56.69%	Agricultura	12.536	70.57%	13.137	73.61%	12.536	68.50%
Solo Exposto	0.766	12.11%	0.525	8.36%	0.639	10.22%	Solo Exposto	2.078	11.70%	2.045	11.46%	2.762	15.09%
Água	0.039	0.62%	0.018	0.29%	0.034	0.54%	Água	0.143	0.80%	0.103	0.58%	0.133	0.73%
Total	6.323		6.278		6.251			17.764		17.846		18.3	

Fonte: Autoria Própria (2025)

6 CONSIDERAÇÕES FINAIS

A questão ambiental tornou-se tema de preocupação global, é necessário chamar a atenção para os impactos ambientais provenientes da dinâmica do uso e cobertura da terra. A utilização de um sistema de informações geográficas (SIG) e o uso de imagens de satélite são ferramentas importantes para a obtenção de uma significativa base de dados. A metodologia utilizada possibilitou gerar mapas de uso e cobertura da terra que podem ser utilizados na implementação do manejo adequado da terra e podem, ainda, dar subsídios para a delimitação das APPs, como também serem utilizados pelos órgãos fiscalizadores com vistas a identificar e localizar as áreas que estão em constante transformação antrópica, viabilizando, de maneira efetiva, a aplicação do Código Florestal.

A análise dos dados referentes à evolução do uso do solo no município de Barão de Cotegipe, processados pelo algoritmo RF nos anos de 2003, 2013 e 2023, revela mudanças substanciais na configuração territorial. Em 2003, a atividade agropecuária caracterizava-se como o principal uso da terra, abarcando cerca de 51,88% da superfície municipal, o que equivale a aproximadamente 137,7 km². No ano de 2013, observou-se um crescimento dessa classe, que atingiu 62,28% do território (162,22 km²), demonstrando a consolidação e a intensificação do modelo agrícola na região. Em 2023, os mapas gerados indicam um ligeiro declínio dessa classe, que passou a representar 60,59% da área do município, equivalente a cerca de 157,81 km², refletindo uma possível estabilização das atividades agropecuárias e eventuais processos de transição ou recuperação da cobertura vegetal.

Quanto às alterações no uso e cobertura da terra da bacia e das sub bacias estudadas nos períodos de 2003, 2013 e 2023, o cálculo de áreas indicou a ocorrência de um processo gradativo de expansão das fronteiras agrícolas, consequentemente comprometendo os remanescentes de vegetação natural e acelerando o impacto dos eventos hidrológicos na região devido a ampla atividades antrópicas desenvolvidos.

A confiabilidade desta análise é respaldada pelo alto desempenho do algoritmo RF, que gerou mapas temáticos com acurácia superior a 98%, comprovando sua eficácia para estudos de dinâmica territorial.

Dessa forma, este trabalho fornece um subsídio técnico-científico crucial para o planejamento territorial de Barão de Cotegipe-RS, orientando ações futuras que visem ao desenvolvimento sustentável e à redução da vulnerabilidade a eventos hidrológicos extremos devido ao mal uso da terra.

7 REFERÊNCIAS

- ABOLMAALI, S. M.-R. *et al.* Impacts of spatio-temporal change of landscape patterns on habitat quality across Zayanderud Dam watershed in central Iran. **Scientific Reports**, v. 14, p. 8780, 2024. DOI: <https://doi.org/10.1038/s41598-024-58783-4>.
- ADAM, E.; MUTANGA, O.; ODINDI, J.; ABDEL-RAHMAN, E. M. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers. **International Journal of Remote Sensing**, v. 35, n. 10, p. 3440–3458, 2014. DOI: <https://doi.org/10.1080/01431161.2014.903435>.
- BELGIU, M.; DRĂGUT, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016. DOI: <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.
- BERON DE LA PUENTE, F. J. *et al.* Clasificación de uso y cobertura del suelo basada en modelos de Aprendizaje de Máquina Supervisados. **Universidad Nacional del Sur / CONICET**, 2023.
- BRASIL. Lei nº 12.651, de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa [...]. **Diário Oficial da União**, Brasília, DF, 28 maio 2012. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/12651.htm. Acesso em: 6 nov. 2025.
- CAVERNAS no Rio Grande do Sul. Disponível em: <https://www.ufrgs.br/paleotocas/RioGrandedoSul.htm>. Acesso em: 19 jul. 2025.
- CARRIELLO, Felix; SOARES, João Viane; FERREIRA, Nelson Jesus. A resposta hidrológica das sub-bacias brasileiras e sua relação com o fenômeno ENSO–El Niño/Oscilação Sul. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. Anais [...]. Goiânia: INPE, 2005. p. 2479-2486.
- CONGEDO, L. Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. **The Journal of Open Source Software**, v. 5, n. 51, p. 3172, 2020. DOI: 10.21105/joss.03172.
- DANTAS, M.; VIERO, A. C.; SILVA, D. R. Origem das paisagens do estado do Rio Grande do Sul. In: **GEODIVERSIDADE do estado do Rio Grande do Sul**. Porto Alegre: CPRM, 2010. p. 35–50.
- FARNAZ, A.; NUTHAMMADHOT, N.; ALI, M. Z. Comparative study of multiple algorithms classification for land use and land cover change detection and its impact on local climate of Mardan District, Pakistan, 2023.
- FELIPETTO, T. P.; GOETTEMES, R. F. Análise urbana e morfológica de Barão de Cotegipe - RS. Disponível em: <https://www.seer.ufal.br/index.php/revistaimpeto/article/view/12606/9385>. Acesso em: 19 jul. 2025.
- FERREIRA, A. C. S. Evolução espaço-temporal do uso de cobertura de terra e a suscetibilidade do Município de Angra dos Reis aos escorregamentos de terra. 2023. Dissertação (Mestrado em Agronomia – Ciência do Solo) – Universidade Federal Rural do Rio de Janeiro, Seropédica, 2023. Disponível em: <https://rjma.ufrj.br/jspui/handle/20.500.14407/10628>. Acesso em: 5 nov. 2025.
- FERREIRA, E.; DANTAS, A. A. A.; MORAIS, A. R. Exatidão na classificação de fragmentos de matas em imagem do satélite CBERS-CCD, no município de Lavras, MG. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, p. 887–894, 21–26 abr. 2007. INPE.

FOLEY, J. A. *et al.* Global consequences of land use. **Science**, v. 309, n. 5734, p. 570–574, 2005. DOI: <https://doi.org/10.1126/science.1111772>.

GETACHEW TIKUYE, B.; RUSNAK, M.; MANJUNATHA, B. R.; JOSE, J. Land use and land cover change detection using the random forest approach: The case of the Upper Blue Nile River Basin, Ethiopia. **Global Challenges**, v. 7, n. 9, p. 2300155, 2023. DOI: <https://doi.org/10.1002/geh2.202300155>.

IBGE. Panorama Barão de Cotegipe. Disponível em: <https://cidades.ibge.gov.br/brasil/rs/barao-de-cotegipe/panorama>. Acesso em: 12 jun. 2025.

INVESTING. US Corn. Disponível em: <https://www.investing.com/commodities/us-corn>. Acesso em: 5 nov. 2025.

INVESTING. US Soybeans. Disponível em: <https://www.investing.com/commodities/us-soybeans-streaming-chart>. Acesso em: 5 nov. 2025.

NOI, P. T.; KAPPAS, M. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. **Sensors**, v. 18, n. 1, p. 18, 2018. DOI: 10.3390/s18010018.

OEA. Comissão Interamericana de Direitos Humanos (CIDH). *Impactos das enchentes no Rio Grande do Sul: observações e recomendações para a garantia dos direitos econômicos, sociais, culturais e ambientais*. Washington, D.C.: Organização dos Estados Americanos, 2025. Disponível em: https://www.oas.org/pt/cidh/relatorios/pdfs/2025/informe_redesca_brasil_pt.pdf. Acesso em: 5 nov. 2025.

RAMACHANDRA, T. V.; MONDAL, T.; SETTURU, B. Relative performance evaluation of machine learning algorithms for land use classification using multispectral moderate resolution data. **SN Applied Sciences**, v. 5, art. 274, 2023. Disponível em: <https://link.springer.com/article/10.1007/s42452-023-05496-4>. Acesso em: 13 jun. 2025.

RODRIGUES, Joseilson O. et al. Respostas hidrológicas em pequenas bacias na região semiárida em função do uso do solo. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 17, n. 3, p. 281-289, 2013. DOI: 10.1590/S1415-43662013000300010.

ROVANI, F. F. M.; CASSOL, R.; WOLLMANN, C. A.; SIMIONI, J. P. D. Análise da vulnerabilidade natural à perda de solo de Barão de Cotegipe, RS. **Revista do Departamento de Geografia – USP**, São Paulo, v. 29, p. 262–278, 2015.

SACHETTI, Á. S.; ROJAS, J. W. J.; HEINECK, K. S. Caracterização geotécnica dos solos de Passo Fundo e Erechim, e geológica da rocha de Passo Fundo. **Revista de Engenharia Civil IMED**, Passo Fundo, v. 1, n. 1, p. 11–17, ago. 2014. ISSN 2358-6508. Disponível em: <https://seer.atitus.edu.br/index.php/revistaec/article/view/577/493>. Acesso em: 19 jul. 2025.

SAHA, P.; MITRA, R.; CHAKRABORTY, K.; ROY, M. Application of multi layer perceptron neural network Markov Chain model for LULC change detection in the Sub-Himalayan North Bengal. **Remote Sensing Applications: Society and Environment**, v. 27, p. 100730, 2022. DOI: <https://doi.org/10.1016/j.rsase.2022.100730>.

SCIKIT-LEARN. MLPClassifier — scikit-learn 1.4.2 documentation. Disponível em: https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPClassifier.html. Acesso em: 8 jun. 2025.

SECRETARIA DO MEIO AMBIENTE E INFRAESTRUTURA – SEMA. Bacia Hidrográfica dos Rios Apuaê–Inhandava. Disponível em: <https://www.sema.rs.gov.br/u010-bh-apuae-inhandava>. Acesso em: 19 jun. 2025.

TEMPA, K.; ARYAL, K. R. Classificação semi-automática para uma delimitação rápida das zonas de risco geológico utilizando imagens de satélite Sentinel-2, 2022.

WINKLER, K.; FUCHS, R.; ROUNSEVELL, M.; HEROLD, M. Global land use changes are four times greater than previously estimated. **Nature Communications**, v. 12, n. 1, p. 2501, 2021. DOI: <https://doi.org/10.1038/s41467-021-22702-2>.

YUH, Y. G.; TRACZ, W.; MATTHEWS, H. D.; TURNER, S. E. Application of machine learning approaches for land cover monitoring in northern Cameroon. **Ecological Informatics**, v. 72, p. 101955, 2022. DOI: <https://doi.org/10.1016/j.ecoinf.2022.101955>.