



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
CÂMPUS DE PRESIDENTE PRUDENTE

Giovanna Carreira Marinho

**Análise de dois espaços de atributos a partir do uso de uma
técnica de redução de dimensionalidade e de uma estratégia de
detecção de anomalias em imagens de sensoriamento remoto**

Presidente Prudente

2024

Giovanna Carreira Marinho

Análise de dois espaços de atributos a partir do uso de uma técnica de redução de dimensionalidade e de uma estratégia de detecção de anomalias em imagens de sensoriamento remoto

Orientador: Prof. Dr. Maurício Araújo Dias

Coorientador: Prof. Dr. Danilo Medeiros Eler

Dissertação apresentada como parte dos requisitos para obtenção do título de Mestre em Ciência da Computação, junto ao Programa de Pós-Graduação em Ciência da Computação, da Faculdade de Ciências e Tecnologia da Universidade Estadual Paulista "Júlio de Mesquita Filho", Câmpus de Presidente Prudente.

Presidente Prudente

2024

M338a	Marinho, Giovanna Carreira Análise de dois espaços de atributos a partir do uso de uma técnica de redução de dimensionalidade e de uma estratégia de detecção de anomalias em imagens de sensoriamento remoto / Giovanna Carreira Marinho. -- Presidente Prudente, 2024 80 p. : il., tabs. Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências e Tecnologia, Presidente Prudente Orientador: Maurício Araújo Dias Coorientador: Danilo Medeiros Eler 1. Ciência da computação. 2. Análise de imagem. 3. Inteligência artificial. 4. Reconhecimento de padrões. 5. Imagens de sensoriamento remoto. I. Título.
-------	---

IMPACTO POTENCIAL DESTA PESQUISA

O estudo mostra que a estratégia de detecção de anomalias baseada na Taxonomia de Kittler não deve ser aplicada a espaços de baixa dimensão obtidos pelo método PCA. Tal descoberta contribui para nortear uma metodologia que pode ajudar na preservação de recursos hídricos e na garantia de água potável e saneamento, como objetivado pela ONU no 6º ODS.

POTENTIAL IMPACT OF THIS RESEARCH

The study shows that the anomaly detection strategy based on Kittler's Taxonomy should not be applied to low-dimensional spaces obtained by the PCA method. This finding contributes to guiding a methodology that can help preserve water resources and ensure safe drinking water and sanitation, as aimed by the UN in the 6th SDG.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Análise de dois espaços de atributos a partir do uso de uma técnica de Redução de Dimensionalidade e de uma estratégia de Detecção de Anomalias em imagens de Sensoriamento Remoto.

AUTORA: GIOVANNA CARREIRA MARINHO

ORIENTADOR: MAURÍCIO ARAÚJO DIAS

COORIENTADOR: DANILO MEDEIROS ELER

Aprovada como parte das exigências para obtenção do Título de Mestra em Ciência da Computação, área: Computação Aplicada pela Comissão Examinadora:

Prof. Dr. MAURÍCIO ARAÚJO DIAS (Participação Virtual)
Departamento de Matemática e Computação / Faculdade de Ciências e Tecnologia de Presidente Prudente

Profa. Dra. SAMARA CALÇADO DE AZEVEDO (Participação Virtual)
UNIFEI / Universidade Federal de Itajubá

Prof. Dr. DANIEL CRUZ CAVALIERI (Participação Virtual)
Engenharia de Controle e Automação / Instituto Federal do Espírito Santo

Presidente Prudente, 13 de dezembro de 2024



Documento assinado digitalmente

MAURICIO ARAUJO DIAS

Data: 13/12/2024 23:28:09-0300

Verifique em <https://validar.iti.gov.br>

Ao meu avô, Manoel Marinho (in memoriam)

AGRADECIMENTOS

Aos meus pais, Jane e Cícero, agradeço pelo esforço que tiveram para me proporcionar uma educação e formação de qualidade. Obrigada por acreditarem e confiarem em mim todos os dias. Ao Henrique, agradeço pelo companheirismo, apoio e amizade.

Ao professor Maurício, agradeço pela orientação, iniciada durante o segundo ano da graduação, em 2019, para um projeto de Iniciação Científica. A partir desse período, aprendi não apenas conceitos técnicos, mas também valores e princípios valiosos para minha carreira. Muito obrigada pela parceria, amizade e paciência.

Agradeço ao professor Danilo, pela coorientação, amizade e apoio desde a graduação. Aos demais professores e servidores da Universidade Estadual Paulista (UNESP) que, direta ou indiretamente, contribuíram para fornecer uma educação gratuita e de qualidade. Obrigada pelos sete anos de aprendizados.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo apoio financeiro no processo #2020/06477-7.

A todos aqueles que contribuíram e continuam contribuindo na minha carreira acadêmica e profissional.

"O maior inimigo do conhecimento não é a ignorância, mas a ilusão do conhecimento." –

Stephen Hawking

RESUMO

A redução de dimensionalidade é uma das transformações de dados mais usadas em pesquisas científicas. Ela desempenha um papel crítico na manutenção das propriedades significativas dos atributos dos dados enquanto transforma esses dados de um espaço de alta para um de baixa dimensão. Estudos anteriores, e.g., sobre análise de imagens, comparando dados desses dois espaços descobriram que, geralmente, qualquer estudo relacionado à detecção de anomalias pode alcançar resultados iguais ou semelhantes quando aplicado a ambos os espaços dimensionais. No entanto, não existem estudos que comparam diferenças nesses espaços dimensionais relacionadas à estratégia de detecção de anomalias baseada na Taxonomia de Kittler (ADS-KT, do inglês *Anomaly Detection Strategy based on Kittler's Taxonomy*). Este estudo tem como objetivo investigar as diferenças entre os dois espaços dimensionais, quando a técnica redução de dimensionalidade *Principal Components Analysis* (PCA) está associada à ADS-KT durante a análise de uma imagem de satélite. A metodologia iniciou com a execução da fase inicial da ADS-KT para criar o espaço de alta dimensão. Logo após, a técnica de redução de dimensionalidade PCA gerou o espaço de baixa dimensão, em que combinações desse espaço foram feitas. Algumas características foram extraídas desses espaços dimensionais e analisadas com base em gráficos. Por fim, as abordagens de aprendizado de máquina, de acordo com a ADS-KT, produziram resultados para esses espaços. No capítulo de resultados, as métricas e as análises que avaliaram os espaços dimensionais apresentaram comportamentos diferentes. Em geral, nenhum espaço de atributos foi capaz de gerar os resultados com a mesma intensidade e qualidade que aquele obtido no espaço de alta dimensão. Portanto, concluímos que a redução da dimensionalidade impacta diretamente na aplicação da ADS-KT.

Palavras-chave: redução de dimensionalidade; sensoriamento remoto; Taxonomia de Kittler; detecção de anomalia; aprendizado de máquina; análise de imagem.

ABSTRACT

Dimensionality reduction is one of the most widely used data transformations in scientific research. It plays a critical role in maintaining the meaningful properties of data attributes while transforming the data from a high- to a low-dimensional space. Previous studies, e.g., on image analysis, comparing data from these two spaces have found that, generally, any study related to anomaly detection can achieve the same or similar results when applied to both dimensional spaces. However, there are no studies that compare differences in these dimensional spaces related to the Anomaly Detection Strategy based on Kittler's Taxonomy (ADS-KT). This study aims to investigate the differences between the two dimensional spaces when the dimensionality reduction technique *Principal Components Analysis* (PCA) is associated with ADS-KT during satellite image analysis. The methodology started by performing the initial phase of ADS-KT to create the high-dimensional space. Afterward, the dimensionality reduction technique PCA generated the low-dimensional space, in which combinations of this space were made. Some features were extracted from these dimensional spaces and analyzed based on graphics. Finally, the machine learning approaches, according to ADS-KT, produced results for these spaces. In the results chapter, the metrics and analyses that evaluated the dimensional spaces showed different behaviors. In general, no feature space was able to generate results with the same intensity and quality as that obtained in the high-dimensional space. Therefore, we conclude that dimensionality reduction directly impacts the application of ADS-KT.

Keywords: dimensionality reduction; remote sensing; Kittler's Taxonomy; anomaly detection; machine learning; image analysis.

LISTA DE FIGURAS

Figura 1	– Informações relacionadas à área de estudo: localização da cidade de Mariana e do estado de Minas Gerais na América do Sul (a); destaque do Rio Doce, da bacia que recebe o mesmo nome do rio, e da hidrografia da região (b); sobreposição da imagem da área de estudo renderizada com a composição R(4)G(3)B(2) e com ajuste de contraste (c).	32
Figura 2	– Sequência de etapas da metodologia proposta. A etapa usada para a redução de dimensionalidade encontra-se destacada em verde. Com essa etapa a metodologia proposta neste estudo diferencia-se da ADS-KT apresentada por Dias et al. (2020)	34
Figura 3	– Fluxograma com uma visão detalhada da metodologia proposta.	36
Figura 4	– <i>Raster</i> virtual (a imagem multiespectral com resolução espacial de 30 metros) e as bandas que o compõem, após ajuste de contraste. A Figura (a) apresenta toda a área de estudo, enquanto as Figuras (b-h) destacam apenas uma parte dela e que foi diretamente afetada pelo desastre ambiental de Mariana.	37
Figura 5	– Imagem fusionada (com resolução espacial de 15 metros) e as bandas que a compõem, após ajuste de contraste. A Figura (a) apresenta toda a área de estudo, enquanto as Figuras (b-h) destacam apenas uma parte dela e que foi diretamente afetada pelo desastre ambiental de Mariana.	39
Figura 6	– Imagem resultante do PCA (renderizada com as componentes 5, 6 e 7) e as suas componentes. A Figura (a) apresenta toda a área de estudo, enquanto as Figuras (b-h) destacam apenas uma parte dela e que foi diretamente afetada pelo desastre ambiental de Mariana.	42
Figura 7	– Os pontos em vermelho, na Figura (a), indicam as localizações das amostras coletadas na imagem. Exemplo de amostras de água (b) e não-água (c) selecionadas na imagem, em uma região aproximada.	43

Figura 8 – Gráfico de pontos do espaço espectral dos pixels das amostras usando a banda infravermelho próximo (5, NIR) e a banda vermelho (4, Red). Os pontos em azul indicam os pixels das amostras de água e, em cinza, não-água. A Figura (a) mostra todo o gráfico, enquanto a Figura (b), uma aproximação (<i>zoom</i>) na região dos pixels das amostras de água. Em outras palavras, a Figura (b) é a ampliação (<i>zoom</i>) do canto inferior esquerdo da Figura (a).	43
Figura 9 – Processo de extração de características das imagens. Cada imagem possui sete bandas ou componentes. O processo para duas amostras (<i>A</i> , em vermelho, e <i>B</i> , em azul) é exemplificado. A média e o desvio padrão foram calculados levando-se em consideração as regiões delimitadas pelas amostras.	44
Figura 10 – Geração das combinações de componentes do PCA. Para os <i>rasters</i> com mais de três componentes, as três últimas foram escolhidas para a sua renderização RGB. Por exemplo, na Figura (j), as componentes 2, 3 e 4 foram escolhidas; na Figura (k), componentes 3, 4 e 5; na Figura (l), componentes 4, 5 e 6; e na Figura (m), componentes 5, 6 e 7.	45
Figura 11 – Gráficos de densidade obtidos considerando a média das características extraídas sobre a imagem fusionada (a) e a imagem do PCA (b). Em cada visualização, uma distribuição é gerada para cada banda ou componente. . .	50
Figura 12 – Gráficos de densidade obtidos considerando o desvio padrão das características extraídas sobre a imagem fusionada (a) e a imagem do PCA (b). Em cada visualização, uma distribuição é gerada para cada banda ou componente. . .	51
Figura 13 – Diagramas de caixa obtidos considerando as características extraídas sobre a imagem fusionada (a) e a imagem do PCA (b), e considerando a média e o desvio padrão. Cada visualização considera uma das métricas usadas para cada banda ou componente.	52
Figura 14 – Mapas de calor obtidos a partir da similaridade de cossenos das distribuições do desvio padrão das amostras entre a imagem fusionada e a do PCA (a), apenas a imagem fusionada (b) e apenas a imagem do PCA (c). Valores próximos de 1 indicam maior similaridade.	53

- Figura 15 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem fusionada em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios. 58
- Figura 16 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera apenas a primeira componente (PC 1) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios. 59
- Figura 17 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera as duas primeiras componentes (PC 1 – 2) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios. 61
- Figura 18 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera as três primeiras componentes (PC 1 – 2 – 3) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios. 62
- Figura 19 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera as quatro primeiras componentes (PC 1 – 2 – 3 – 4) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios. 63

- Figura 20 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera as cinco primeiras componentes (PC 1 – 2 – 3 – 4 – 5) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios. 64
- Figura 21 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera as seis primeiras componentes (PC 1 – 2 – 3 – 4 – 5 – 6) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios. 65
- Figura 22 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera todas as componentes (PC 1 – 2 – 3 – 4 – 5 – 6 – 7) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios. 66

LISTA DE TABELAS

Tabela 1 – Resumo dos trabalhos relacionados.	27
Tabela 2 – Comprimentos de onda e resoluções espaciais das bandas do satélite Landsat 8.	33
Tabela 3 – Matriz do PCA usada para fazer a transformação linear dos dados no espaço de origem para o de destino. O número de colunas está vinculado ao número de bandas do espaço de origem e, o número de linhas, à quantidade de componentes da saída. Dessa forma, cada linha representa um autovetor.	41
Tabela 4 – Autovalores do PCA vinculados a cada componente e a retenção de informação para cada uma.	41
Tabela 5 – Matriz de confusão.	48
Tabela 6 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem fusionada.	54
Tabela 7 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1.	54
Tabela 8 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1 – 2.	54
Tabela 9 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1 – 2 – 3.	55
Tabela 10 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1 – 2 – 3 – 4.	55
Tabela 11 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1 – 2 – 3 – 4 – 5.	55
Tabela 12 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1 – 2 – 3 – 4 – 5 – 6.	55
Tabela 13 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1 – 2 – 3 – 4 – 5 – 6 – 7.	56
Tabela 14 – Resumo da análise das classificações para as oito imagens.	67

LISTA DE ABREVIATURAS

ADS-KT	<i>Anomaly Detection Strategy based on Kittler's Taxonomy</i>
PCA	<i>Principal Component Analysis</i>

SUMÁRIO

1	INTRODUÇÃO	17
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	Redução de dimensionalidade	21
2.2	Principal Components Analysis	21
2.3	Imagens multi e hiperespectrais	22
2.4	Classificação	23
2.5	Taxonomia de Kittler	24
3	TRABALHOS RELACIONADOS	27
4	METODOLOGIA PROPOSTA	32
4.1	Área de estudo	32
4.2	Materiais	32
4.3	Metodologia	33
4.3.1	Descrição resumida da metodologia	33
4.3.2	Descrição detalhada da metodologia	35
5	RESULTADOS	50
6	DISCUSSÕES	68
7	CONCLUSÃO	71
	REFERÊNCIAS	73
	APÊNDICE A – PARÂMETROS DOS PROCESSAMENTOS . . .	78
A.1	Pré-processamento	78
A.2	Redução de dimensionalidade	79
A.3	Classificação	79
A.4	Extração de características	81

1 INTRODUÇÃO

As técnicas de redução de dimensionalidade são fundamentais para transformar dados de um espaço de alta dimensão (e.g., imagens multiespectrais) para um espaço de baixa dimensão, sem que esses dados percam muitas propriedades relevantes. Essa transformação é viável porque essas técnicas reduzem redundâncias, mas preservam a maioria dos atributos desses dados. As transformações e combinações do espaço de dados realizadas por essas técnicas são de grande importância no processamento de dados, sendo usadas em uma ampla gama de campos e casos de estudo, como gestão de recursos hídricos (TIOUIOUINE et al., 2020), medicina (WANG; LAURI; HASSANI, 2021), seleção de rota (SAMEER; ABED; SAYL, 2023), etc. As principais vantagens do uso da redução de dimensionalidade estão amplamente descritas na literatura científica, por exemplo, em vários estudos envolvendo análise de imagens digitais (FOWLER et al., 2009; GHOSH; PRAMANIK, 2019; BILIUS; PENTIUC, 2022; SELLAMI; FARAH, 2018; AVRAMOVIC; RISOJEVIC, 2011; JOURNAUX et al., 2006; GROBLER; KLEYNHANS; SALMON, 2019; NAVIN; AGILANDEESWARI; ANJANEYULU, 2020; YANG et al., 2019; ZHANG et al., 2016; GU; WANG, 2016; LIANG et al., 2018). Esses estudos mostram que é possível obter resultados semelhantes tanto analisando dados em alta como em baixa dimensão.

Quando as imagens a serem analisadas são multi e hiperespectrais, o que é muito comum, por exemplo, para as imagens de sensoriamento remoto, elas podem conter muitos dados redundantes entre as suas bandas. A redução de dimensionalidade reduz as redundâncias dessas imagens e aumenta a eficiência computacional. Consequentemente, a posterior análise dessas imagens, por exemplo para detecção de anomalias, pode ser feita sobre uma quantidade menor de dados. Dessa forma, a redução de dimensionalidade contribui para que a etapa posterior, e.g., a análise de imagens, demande menos recursos computacionais. No entanto, as consequências do uso da redução de dimensionalidade associada a certas estratégias de análise de imagens, e.g., a detecção de anomalias baseada na Taxonomia de Kittler (KITTLER et al., 2014), permanecem desconhecidas. Portanto, novos estudos são necessários para descobrir as consequências do uso da redução de dimensionalidade e da estratégia de detecção de anomalias baseada na Taxonomia de Kittler (ADS-KT, acrônimo do termo em inglês *Anomaly Detection Strategy based on Kittler's Taxonomy*) aplicadas juntas a imagens de sensoriamento remoto.

Estudos a respeito de como a redução de dimensionalidade impacta a detecção de anomalias baseada na Taxonomia de Kittler são de grande interesse dentro do campo de aprendizado de máquina. A razão para esse interesse está no fato da detecção de anomalias baseada na Taxonomia de Kittler ser uma estratégia inovadora e promissora do reconhecimento de padrões, a qual pode ser usada para ajudar máquinas a reconhecerem a ocorrência de problemas, e.g., desastres ambientais, em diferentes contextos presentes em imagens de sensoriamento remoto. A ADS-KT foi aplicada para o reconhecimento de problemas monitorados por sensoriamento remoto pela primeira vez por [Dias et al. \(2020\)](#). O estudo apresenta uma abordagem para sistemas de tomada de decisão, baseada no fato de que as máquinas estariam mais próximas de reconhecer os contextos nos quais os problemas estão inseridos. A estratégia usa ferramentas para detecção de anomalias e incongruências relacionadas com a poluição de águas fluviais decorrente de desastres ambientais. Entretanto, apenas publicações da aplicação dessa estratégia em dados de alta dimensionalidade são encontradas na literatura científica. Resultados da sua aplicação sobre dados de baixa dimensionalidade permanecem desconhecidos.

Portanto, este estudo objetiva analisar o comportamento da aplicação da ADS-KT, apresentada por [Dias et al. \(2020\)](#), em um espaço de baixa dimensão, obtido a partir da técnica de redução de dimensionalidade *Principal Components Analysis* (PCA), ou em um espaço de dados transformado. Este objetivo é importante para ajudar a entender se e como a técnica impacta a detecção de anomalias baseada na Taxonomia de Kittler, quando aplicada a uma imagem de sensoriamento remoto e especialmente quando um desastre ambiental é usado como estudo de caso.

De modo a atingir esse objetivo, este estudo aplicou a fase inicial da ADS-KT ([DIAS et al., 2020](#)) a uma imagem de satélite que registra as consequências de um desastre ambiental. Uma vez obtido esse resultado, i.e., a imagem fusionada, o método de redução de dimensionalidade PCA foi aplicado para gerar dados em um espaço de baixa dimensão. Diferentes combinações desse espaço foram feitas para gerar conjuntos de atributos. Em seguida, foram extraídas características tanto da imagem fusionada quanto desses espaços de atributos, de modo a analisar algumas métricas por meio de gráficos. Por fim, as abordagens de treinamento, validação e teste dos classificadores foram realizadas para esses resultados - o resultado obtido pela fase inicial da estratégia (alta dimensão) e as diferentes combinações do resultado obtido pelo algoritmo de redução de dimensionalidade (baixa dimensão).

A partir dos resultados das classificações e da taxonomia de Kittler, foi observado de

modo geral que o uso da baixa dimensão (menos características) evidenciou a ocorrência de uma categoria de anomalia diferente daquela encontrada na classificação feita a partir da alta dimensão. Nenhum espaço de atributos gerou resultados com a mesma qualidade e nível de detecção de anomalia que aquele obtido ao usar o espaço original dos dados (alta dimensão). Tal descoberta reforça a importância do uso da taxonomia para classificar os diferentes comportamentos que ocorrem quando se trabalha com aprendizado de máquina.

A principal contribuição deste estudo é mostrar aos pesquisadores da área de Sensoriamento Remoto que as investigações sobre a ocorrência de anomalias do tipo *Unexpected structure and structural components* (KITTLER et al., 2014) devem levar em consideração espaços de alta dimensão em vez de espaços de baixa dimensão obtidos pelo método PCA. Enquanto estudos relacionados à análise de imagens digitais, como os propostos por Fowler et al. (2009), Ghosh e Pramanik (2019), Bilius e Pentiu (2022), Sellami e Farah (2018), Avramovic e Risojevic (2011), Journaux et al. (2006), Grobler, Kleynhans e Salmon (2019), Navin, Agilandeewari e Anjaneyulu (2020), Yang et al. (2019), Zhang et al. (2016), Gu e Wang (2016), Liang et al. (2018), permitem aos pesquisadores sustentar a ideia de que a análise de dados em alta dimensão gera resultados semelhantes aos analisados em baixa dimensão, este estudo contribui para mostrar que há pelo menos uma exceção a esta regra, quando a análise de imagens digitais envolve detecção de anomalias com base na Taxonomia de Kittler.

A inovação deste estudo está no fato dele ser, ao conhecimento dos autores, o primeiro a descrever a ocorrência de uma anomalia do tipo *Unexpected structural component* (ver Kittler et al. (2014)) em uma pesquisa na área de Sensoriamento Remoto. Esta inovação é importante porque a detecção de anomalias baseada na Taxonomia de Kittler mostrou ser uma ferramenta promissora no que diz respeito ao aprendizado de máquina aplicado ao sensoriamento remoto. Desse modo, esse estudo (MARINHO et al., 2023) se junta a outros publicados anteriormente, como Dias et al. (2020) e Dias et al. (2022), os quais também inovaram ao descreverem pesquisas a respeito do uso da Taxonomia de Kittler na área de Sensoriamento Remoto.

Tanto os estudos citados anteriormente (MARINHO et al., 2023; DIAS et al., 2020; DIAS et al., 2022) quanto qualquer outro que aplique a detecção de anomalias baseada na Taxonomia de Kittler à análise de corpos d'água são fundamentais para ajudar a preservar os recursos hídricos. Ademais, vale ressaltar que, água potável e saneamento correspondem ao 6º objetivo dos Objetivos de Desenvolvimento Sustentável da ONU (United Nations Department of Economic and Social Affairs, 2022). Esse objetivo recebeu considerável atenção crítica da comunidade

científica para investigar e publicar estudos, a fim de ajudar a garantir a disponibilidade e a gestão sustentável dos recursos hídricos e do saneamento para o mundo (ASSAF; SAYL; ADHAM, 2021; ADHAM et al., 2018; SHEN et al., 2023; SULAIMAN et al., 2019; SAYL et al., 2016).

Este documento está organizado da seguinte maneira. O Capítulo 2 consiste em uma fundamentação teórica. O Capítulo 3 apresenta uma revisão bibliográfica, comentando sobre os trabalhos relacionados ao tema. O Capítulo 4 descreve a metodologia proposta para conduzir os experimentos. O Capítulo 5 mostra os resultados alcançados. O Capítulo 6 discute os resultados obtidos. O Capítulo 7 apresenta as conclusões, e propõem experimentos futuros a serem realizados.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Redução de dimensionalidade

As técnicas de redução de dimensionalidade mantêm as propriedades originais dos dados ao mapeá-los de uma alta para uma baixa dimensão (MARCÍLIO-JR; ELER, 2021). Esse processo ocorre em duas etapas: a seleção e a extração de características (GHOSH; PRAMANIK, 2019; SELLAMI; FARAH, 2018), que são descritas a seguir.

Na etapa de seleção de características, ocorre uma busca de um subconjunto de características que atendem a determinado critério. Esse critério pode variar conforme o método empregado e pode envolver a similaridade dos dados, entropia, variância, entre outros. Nessa etapa, as informações importantes e não redundantes são selecionadas, mantendo-se a relação entre elas. No caso de imagens de sensoriamento remoto, o objetivo é selecionar bandas espectrais significativas para a análise. A seleção de características pode ser feita por métodos supervisionados, não supervisionados ou semi-supervisionados. Por exemplo, o *Principal Components Analysis* (PCA) é um método não supervisionado de redução de dimensionalidade, pois usa somente as características dos dados de entrada.

Na etapa de extração de características, busca-se construir um novo espaço a partir da maximização da separabilidade entre os dados. Essa etapa pode ser realizada com métodos que aplicam transformações lineares ou não lineares. Por exemplo, o PCA usa uma transformação linear para mapear o espaço de alta para baixa dimensionalidade.

2.2 Principal Components Analysis

O *Principal Components Analysis* (PCA) é um método que pode ser usado para a redução de dimensionalidade (CROSTA, 1999; NAVIN; AGILANDEESWARI; ANJANEYULU, 2020; GROBLER; KLEYNHANS; SALMON, 2019; MARCÍLIO-JR; ELER, 2021). Ele implementa a Transformada de Karhunen–Loève e, quando aplicado a imagens de sensoriamento remoto, constitui uma poderosa ferramenta na análise espectral dessas imagens (CROSTA, 1999). O PCA pode ser aplicado no pré-processamento dos dados para a melhoria da qualidade da imagem, reduzindo a sua dimensionalidade e facilitando a análise (NAVIN; AGILANDEESWARI; ANJA-

NEYULU, 2020). Nesse método, todas as informações necessárias são estimadas diretamente a partir dos dados.

No que se refere ao seu funcionamento, o PCA maximiza a variância dos novos componentes e minimiza o erro quadrático médio entre os dados originais e essa nova representação. Como o seu objetivo é reduzir a redundância entre os dados de entrada, primeiramente é feita uma decomposição das características, e, em seguida, a dimensionalidade é reduzida pela obtenção de novas características, que sejam combinações lineares dos dados originais. Esse é um método popular para a redução de dimensionalidade de dados de sensoriamento remoto (GROBLER; KLEYNHANS; SALMON, 2019), comumente aplicado em imagens multiespectrais e hiperespectrais.

2.3 Imagens multi e hiperespectrais

As imagens de sensoriamento remoto são geradas a partir da capturada interação entre a radiação eletromagnética e os alvos da superfície terrestre (ZHANG et al., 2016; MENESES; ALMEIDA; BAPTISTA, 2019). Os sensores embarcados nos satélites, por exemplo, capturam a radiação refletida e registram essa informação em bandas espectrais, que correspondem a faixas do espectro eletromagnético (como a luz visível e o infravermelho, por exemplo).

Nesse sentido, as bandas são responsáveis por armazenar o comportamento espectral dos alvos de uma cena, uma vez que cada matéria possui uma interação diferente com a radiação. Assim, diferentes bandas podem ser combinadas para analisar alvos diferentes. Neste estudo, como será apresentado nos capítulos futuros, a área de estudo corresponde a um local com água contaminada por rejeitos de minério, o que torna relevante o uso de bandas que evidenciem não só a presença de água, mas também minerais e outros elementos.

As imagens multi e hiperespectrais de sensoriamento remoto oferecem uma vasta quantidade de informações valiosas para classificação e detecção. As imagens multiespectrais capturam uma quantidade mais limitada de informação do espectro eletromagnético, apresentando, portanto, um número menor de bandas em comparação com as imagens hiperespectrais, cuja resolução espectral é significativamente maior.

Essas imagens são representadas como um cubo de imagens, no qual a largura e a altura são associadas respectivamente aos eixos x e y , enquanto a quantidade de bandas é associada ao eixo z (GHOSH; PRAMANIK, 2019). Cada pixel da imagem fornece uma informação espectral

a respeito de uma observação e pode ser representado como um vetor de alta dimensão, em que cada dimensão representa uma banda espectral (SELLAMI; FARAH, 2018).

Por conta da alta resolução espectral, essas imagens possuem muitas informações redundantes (alta dimensionalidade) que, além de aumentar o custo e armazenamento computacional, podem reduzir a acurácia da classificação, por exemplo. Diante disso, o uso da redução de dimensionalidade é importante, uma vez que ela busca um espaço de baixa dimensão a partir de uma seleção de bandas, na qual as informações redundantes entre elas são eliminadas, podendo tornar a classificação computacional mais eficiente (FOWLER et al., 2009; GHOSH; PRAMANIK, 2019; LIANG et al., 2018; SELLAMI; FARAH, 2018; GU; WANG, 2016; JOURNAUX et al., 2006; YANG et al., 2019).

2.4 Classificação

A classificação é uma atividade que consiste em atribuir, para cada amostra, uma classe discreta pertencente a um conjunto de classes disponíveis (BISHOP, 2006). Na classificação de imagens de sensoriamento remoto, uma amostra pode ser representada por um subconjunto de pixels pertencentes à mesma classe. Desse modo, após a seleção manual de algumas amostras em uma imagem, um modelo é gerado por meio do treinamento de um classificador, uma espécie de especialista. Com base nesse modelo, identifica-se a qual classe pertence cada pixel da imagem inteira.

Quando amostras rotuladas, i.e., amostras identificadas quanto à classe, são usadas para o treinamento do classificador, a classificação é chamada de supervisionada (RICHARDS; JIA, 1999). Quando não há amostras rotuladas, a classificação é chamada de não-supervisionada. Se apenas parte das amostras estiverem rotuladas, a classificação é chamada de semi-supervisionada. Neste estudo, classificações supervisionadas são feitas, uma vez que amostras rotuladas são usadas para o treinamento dos classificadores selecionados. Além dessas categorias de classificação, no sensoriamento remoto existem dois tipos de classificadores: contextuais e não contextuais (KITTLER et al., 2014), que serão explicados a seguir.

Os classificadores contextuais (i.e., classificadores fortes) dependem de conhecimentos específicos, como conhecimentos anteriores ou dados de treinamento. Este estudo usou, a saber, o classificador *Boost* (OpenCV Project, 2019a; DING; XIAO, 2012) como classificador contextual. Esse classificador realiza a tarefa de classificação supervisionada e faz uso de classificadores

fracos, combinando os resultados desses, para alcançar o objetivo final. Como sugerido pelo nome, a tomada de decisão de um classificador contextual não considera somente a informação individual de cada pixel, mas também, a relação (contexto) entre seus vizinhos.

Já os classificadores não contextuais (i.e., classificadores fracos) são menos restritos e precisos em relação aos contextuais. Este estudo usou o classificador Árvore de Decisão (DT, do inglês *Decision Tree*) ([OpenCV Project, 2019b](#)) como classificador não contextual. Esse classificador, também usado na classificação supervisionada, pode ser usado em conjunto ou sozinho; cada nó de decisão é responsável por realizar uma separação dos dados em duas classes (no caso das Árvores Binárias). O classificador não contextual realiza a classificação levando em consideração apenas a individualidade de cada pixel isoladamente, por isso, também pode ser chamado de classificação baseada em pixel.

Ao fazer uso de um classificador contextual e um não contextual espera-se que seus resultados ao classificar o mesmo dado de entrada, sejam similares, i.e., que suas estimativas de probabilidade de classe sejam parecidas ([WEINSHALL et al., 2012](#); [KITTLER; ZOR, 2015](#); [PONTI et al., 2017](#); [KITTLER; ZOR, 2019](#)). Nesse contexto, quando ocorre uma discordância entre os resultados, pode existir uma incongruência relacionada a algum tipo de anomalia. Dessa forma, a análise da divergência entre os resultados obtidos por um classificador contextual e um não-contextual é essencial para detectar incongruências no contexto de uso neste estudo.

Por exemplo, os classificadores contextuais e não contextuais podem ser usados para classificar uma imagem de satélite composta por um rio e por outros elementos diversos, considerando-se que os resultados obtidos por ambos os classificadores diverjam em algumas regiões desse rio. Dito de outro modo, um classificador pode atribuir uma classe “água” e o outro uma classe “não-água” para uma mesma porção do rio. Essa divergência pode indicar a presença de uma incongruência. A categorização da anomalia que pode estar relacionada com essa incongruência pode ser feita por meio da Taxonomia de Kittler ([KITTLER et al., 2014](#)).

2.5 Taxonomia de Kittler

A Taxonomia de Kittler consiste em um *framework* de detecção de anomalia que foi proposto por [Kittler et al. \(2014\)](#). Esse *framework* expõe a natureza multifacetada de cada anomalia e sugere mecanismos efetivos para identificar e para diferenciar cada particularidade da anomalia, contribuindo com a sua detecção. A Taxonomia também ajuda a identificar as

diferentes causas de eventos anômalos.

É útil ressaltar que, anomalia, de acordo com Kittler et al. (2014), é o fenômeno que acontece quando os sistemas de percepção de máquina, já treinados e modelados para um domínio de aplicação, são expostos a um novo cenário. Assim, após essa mudança de domínio, eles irão falhar ao atribuir o significado correto dos dados.

Métodos convencionais de detecção de anomalia estão concentrados no conceito de anomalia observacional (*observational anomaly*), que pode ser *outlier (likelihood anomaly)* ou desvio de uma distribuição (*distributional anomaly*). Esses tipos de abordagens não evidenciam diretamente uma anomalia de domínio (*domain anomaly*), mas fornecem meios para isso. A anomalia de domínio surge quando os dados observados não são explicados pelos modelos existentes.

Os métodos convencionais usam modelos não generativos para a classificação de dados, por conta de sua performance. Contudo, os modelos não generativos não são capazes de detectar anomalia de domínio. Posto isso, o uso de mais de um especialista permite que essa detecção aconteça. A incongruência entre os resultados de vários modelos não generativos é um indicativo de uma potencial anomalia de domínio. Ademais, a incongruência pode ajudar na identificação do tipo da anomalia.

Quando múltiplos especialistas devem ser usados para permitirem a detecção de anomalias de domínio, a categoria de classificador contextual se destaca. Isso, se deve ao fato de que sua classificação é capaz de representar hierarquicamente os dados sensoriais. A atribuição da classe para cada dado é feita pelo classificador contextual a partir de informações desse dado e de seus vizinhos, já o classificador não contextual faz uso apenas de informações relativas ao próprio dado.

Alguns fatores, por conseguinte, devem ser avaliados em conjunto, para a detecção e identificação de anomalia de domínio, a saber: alta qualidade do dado obtido pelo sensor, classificação contextual e não contextual dos mesmos dados, e ocorrência de incongruência. A Taxonomia descrita por Kittler et al. (2014) organiza as anomalias nos seguintes tipos: *Measurement model drift*, *Component model drift*, *Unexpected structure and structural components*, *Unknown object*, *Unknown structure* e *Unexpected structural component*. A seguir, serão detalhadas apenas as categorias analisadas nos resultados deste estudo.

- *Unexpected structure and structural components*: essa anomalia está relacionada a uma

mudança integral ou parcial da área de estudo, i.e., do domínio. Nesse caso, a observação difere consideravelmente dos modelos de referência dos classificadores em relação a sua estrutura (que define sua forma) e componentes (que, em conjunto, compõem a estrutura). Isso, considerando-se um modelo criado para classificar pixels em uma imagem nas classes “água” e “não-água”. Durante a classificação, ao analisar um rio que pertence à imagem, caso esse rio tenha sofrido uma mudança de domínio (tenha recebido uma quantidade considerável de rejeitos de minério, por exemplo) o classificador que tinha condições de identificar o rio como “água” pode falhar, já que a estrutura e os componentes desse rio são inesperados (esperava-se água, e virou lama). Este exemplo foi estudado e publicado por [Dias et al. \(2020\)](#);

- *Unexpected structural component*: essa outra categoria de anomalia está relacionada à falta de atributos nas características do modelo (apenas um subconjunto de modelos de objetos é usado), i.e., a ausência de informações relevantes leva à ocorrência desse tipo de anomalia. Por exemplo, a aplicação de um filtro qualquer pode ser responsável por eliminar características relevantes do modelo para classificar um objeto como pertencente a certo tipo de anomalia, já que nem todas as características do universo considerado foram contempladas.

3 TRABALHOS RELACIONADOS

No que se refere aos estudos envolvendo detecção de anomalias, uma estratégia inovadora que aplica a Taxonomia de Kittler em situações do mundo real é apresentada por [Dias et al. \(2020\)](#). O estudo descrito no capítulo anterior apresenta uma abordagem para sistemas de tomada de decisão, na qual as máquinas seriam capazes de reconhecer com mais precisão os contextos nos quais os problemas estão inseridos. A estratégia apresentada por [Dias et al. \(2020\)](#) é usada neste estudo para que seja possível entender o seu comportamento em um espaço de baixa dimensionalidade.

Diversos são os estudos que analisam o impacto da redução de dimensionalidade em atividades de análise de imagens ([FOWLER et al., 2009](#); [GHOSH; PRAMANIK, 2019](#); [BILIUS; PENTIUC, 2022](#); [SELLAMI; FARAH, 2018](#); [AVRAMOVIC; RISOJEVIC, 2011](#); [JOURNAUX et al., 2006](#); [GROBLER; KLEYNHANS; SALMON, 2019](#); [WANG; LAURI; HASSANI, 2021](#); [NAVIN; AGILANDEESWARI; ANJANEYULU, 2020](#); [YANG et al., 2019](#)) ou que propõem métodos diferentes daqueles anteriormente disponíveis na literatura ([ZHANG et al., 2016](#); [GU; WANG, 2016](#); [LIANG et al., 2018](#)). A Tabela 1 apresenta um resumo desses estudos.

Tabela 1 – Resumo dos trabalhos relacionados.

Artigo	Métodos e técnicas	Conclusão
Fowler et al. (2009)	Projeção aleatória e CPPCA	CPPCA gerou resultados de classificação e de detecção de anomalias semelhantes
Ghosh e Pramanik (2019)	SBS e <i>Relief</i>	<i>Relief</i> gerou melhor acurácia na classificação
Bilius e Pentiuc (2022)	Decomposição de <i>Tucker</i> e PCA	Decomposição de <i>Tucker</i> gerou resultados da classificação mais semelhantes
Sellami e Farah (2018)	Diversas técnicas de redução de dimensionalidade e classificador SVM	TLPP mostrou melhores resultados na classificação
Avramovic e Risojevic (2011)	PCA, ICA e descritores (<i>Gabor</i> e <i>Dist</i>)	O uso dos descritores e das técnicas de redução de dimensionalidade melhoraram a classificação
Journaux et al. (2006)	Cinco métodos de redução de dimensionalidade e algoritmo <i>K-means</i>	PCA foi responsável por apresentar um custo computacional baixo e um alto desempenho durante a clusterização
Grobler, Kleynhans e Salmon (2019)	FFT e PCA	PCA realizou uma separação maior das classes envolvidas no problema de classificação
Navin, Agilandeewari e Anjaneyulu (2020)	PCA e NDVI	O uso das técnicas gerou uma similaridade com os dados originais durante análise de imagens
Yang et al. (2019)	MNF	Melhorou a qualidade da imagem e a acurácia da classificação
Zhang et al. (2016)	Um novo método semi-supervisionado	O novo método proposto permitiu alcançar melhores resultados na classificação
Gu e Wang (2016)	Dois novos métodos: DGDR e MS-DGDR	Ambos métodos propostos melhoraram a acurácia da classificação
Liang et al. (2018)	Um novo método CPSDR	O novo método melhorou o desempenho da classificação

Fonte: Elaborado pela autora.

Uma análise da separabilidade das classes e da performance de detecção de anomalias foi feita por [Fowler et al. \(2009\)](#). No estudo foi investigado o impacto da redução de dimensionalidade aplicada no início das análises, i.e., durante o processo de aquisição dos sinais. As performances da redução de dimensionalidade baseada em projeção aleatória e no método *Compressive-Projection Principal Component Analysis* (CPPCA) foram avaliadas analisando os resultados de classificação e detecção de anomalias. As classificações obtidas sobre os conjuntos de dados reconstruídos a partir dessa última estratégia foram bastante semelhantes aos obtidos sobre os dados originais (coeficiente de correlação acima de 0,9 para cada componente).

Um outro estudo realizado por [Ghosh e Pramanik \(2019\)](#) teve o objetivo de melhorar a acurácia da classificação por meio de duas estratégias. O critério *Maximum Margin Criterion* (MMC) foi usado para extração de características, além disso, um método baseado em correlação foi usado para gerar um sub-conjunto de características. Em seguida, duas estratégias foram definidas para combinar exaustivamente essas características extraídas e selecionadas. Na primeira, a quantidade de características extraídas poderia ser diferente da quantidade de características selecionadas, i.e., conjuntos de diferentes cardinalidades foram considerados. Já na segunda estratégia, ambos os conjuntos tiveram a mesma cardinalidade. Por fim, a partir desses conjuntos combinados de características, obtidos nas duas estratégias, os algoritmos *Sequential Backward Selection* (SBS) e *Relief* foram usados de modo independente para eliminar redundâncias e informações menos relevantes, i.e., para realizar a redução de dimensionalidade. Os resultados obtidos a partir de três conjuntos de dados de imagens hiperespectrais mostraram que a acurácia obtida foi maior na segunda estratégia. O uso do algoritmo SBS mostrou um maior consumo de tempo quando a cardinalidade do conjunto de características combinadas era maior e nem sempre fornecia um conjunto de características reduzido e otimizado.

Dois métodos de redução de dimensionalidade foram analisados no estudo publicado por [Bilius e Pentiuc \(2022\)](#). O trabalho aplica a decomposição de *Tucker* para decompor (ou comprimir) a informação espectral de uma imagem hiperespectral. Com isso a extração de características é aplicada nesse espaço espectral para obter um conjunto de características que podem ser usadas para classificação. Em seguida, os autores aplicaram o método PCA para comparar as características obtidas e realizaram classificações a partir dessas características. Analisando os valores das métricas aplicadas sobre os resultados obtidos, a primeira transformação permitiu obter dados mais próximos dos dados originais, enquanto o PCA apresentou valor de acurácia mais baixo em um tempo mais curto.

Uma revisão das técnicas de redução de dimensionalidade comparando os resultados obtidos pelo classificador *Support Vector Machines* (SVM) foi realizado no estudo publicado por [Sellami e Farah \(2018\)](#). Os autores fizeram uso de técnicas de extração de características lineares - PCA e *Tensor Locality Preserving Projection* (TLPP), e não lineares - *Kernel Principal component analysis* (KPCA) e *Laplacian Eigenmaps* (LE), além de métodos de seleção de banda supervisionados - *Mutual Information* (MI) e *Divergence Measure* (DM), e não supervisionados - *Constrained Band Selection* (CBS) e *Propagation Affinity* (PA). A partir de imagens hiperespectrais foram feitas combinações de técnicas e análise da performance na classificação. Os resultados mostram que o TLPP ofereceu melhores resultados na classificação. Além disso, o uso conjunto do TLPP com CBS melhorou a precisão dos resultados.

Uma investigação foi feita por [Avramovic e Risojevic \(2011\)](#) para entender como os métodos de redução de dimensionalidade PCA e *Independent Component Analysis* (ICA) afetam a exatidão da classificação. Imagens aéreas, originalmente representadas por descritores de alta dimensão, (*Gabor* e *Dist*) foram consideradas para os testes de classificação. As técnicas de redução de dimensionalidade foram aplicadas nos descritores completos e naqueles calculados para cada componente espectral. Analisando a performance, a acurácia da classificação foi próxima de 90%, mesmo a partir de descritores com dimensões menores. Os autores concluíram que, por meio do uso de descritores e técnicas de redução de dimensionalidade, é possível obter resultados avançados de classificação de imagens aéreas.

No estudo publicado por [Journaux et al. \(2006\)](#), cinco métodos de redução de dimensionalidade foram comparados a partir dos resultados obtidos pelo algoritmo de agrupamento *K-means* (não supervisionado). Esses métodos foram aplicados em dez imagens multiespectrais do satélite *Landsat* e os resultados mostraram que alguns métodos não lineares mais avançados encontraram um melhor agrupamento, no entanto, o PCA, método linear, foi responsável por apresentar um custo computacional baixo e um alto desempenho.

Um *framework* de comparação de métodos para extração de características sem a necessidade do uso de rótulos foi proposto por [Grobler, Kleynhans e Salmon \(2019\)](#). Os testes realizados comparam os métodos *Fast Fourier Transform* (FFT) e PCA aplicados a algumas imagens de sensoriamento remoto. Os resultados compostos por um espaço de características reduzido obtido pelo *framework* indicam que essa última técnica (PCA) superou a primeira (FFT). Essas conclusões se devem ao fato de que o PCA realizou uma separação maior de duas classes envolvidas no problema; essa técnica produziu um espaço que tem mais de 15% de separabilidade

em relação ao FFT.

O tema do estudo realizado por [Navin, Agilandeewari e Anjaneyulu \(2020\)](#) foi a aplicação da redução de dimensionalidade por meio do método PCA e o monitoramento da vegetação por meio do índice *Normalized Difference Vegetation Index* (NDVI), em imagens de satélite. Tanto a aplicação quanto o monitoramento referem-se à mesma área de estudo. O PCA foi usado no estudo para auxiliar na análise da imagem. Já o índice NDVI, para auxiliar no monitoramento da vegetação local. A validação da imagem gerada por meio do índice NDVI foi realizado comparando essa imagem com a mesma região de uma imagem do *Google Earth*. Essa comparação indicou uma similaridade entre as duas imagens. O trabalho permitiu analisar o monitoramento da área de estudo e o gerenciamento de recursos terrestres.

A correlação entre as imagens hiperespectrais e a redução de dimensionalidade foi analisada por [Yang et al. \(2019\)](#). Por meio da aplicação de um método *Minimum Noise Fraction Rotation* (MNF) em certa área de estudo, os autores observaram uma melhoria na qualidade da imagem em termos de reduções tanto de ruído como de redundâncias entre as características. Os autores afirmam que após a transformação, os dados processados melhoraram a acurácia de algumas atividades, como a classificação.

Os estudos citados analisaram o impacto de técnicas de redução de dimensionalidade consolidadas, nas atividades de análise de imagens. Todavia, existem outros estudos ([ZHANG et al., 2016](#); [GU](#); [WANG, 2016](#); [LIANG et al., 2018](#)) que propõem métodos diferentes daqueles anteriormente disponíveis na literatura. Um método semi-supervisionado de redução de dimensionalidade baseado no conceito de representação esparsa foi proposto por [Zhang et al. \(2016\)](#). As informações de geometria intrínseca e informações discriminativas das amostras são preservadas nesse método. As amostras selecionadas no estudo são diferenciadas por meio de um coeficiente esparsa, que apresenta valores mais altos quando as amostras e as entidades de referência pertencem à mesma classe, e valores mais baixos quando são de classes diferentes. Esse coeficiente é usado na construção de um grafo. Além disso, um termo de regularização é incorporado a essa estrutura para a redução de dimensionalidade. Esse método faz uso de amostras rotuladas e não rotuladas para melhorar a performance. Além disso, o método *Linear Discriminant Analysis* (LDA) foi incorporado e comparado com métodos já existentes com base na classificação de imagens hiperespectrais e, a partir dos resultados, foi possível concluir que o método alcançou melhores resultados.

No estudo realizado por [Gu e Wang \(2016\)](#) foram apresentados dois outros métodos de redução de dimensionalidade para imagens hiperespectrais, o *Discriminative Graph-based Dimensionality Reduction* (DGDR) e a sua extensão *Multi-Scale* (MS-DGDR). No que se refere a esses métodos, uma função de projeção é buscada de modo a atingir os seguintes objetivos: a minimização de um termo de similaridade (que possui a relação de dispersão intra-classe) e a maximização de um termo de dissimilaridade (que possui a relação de distância inter-classe). Os resultados obtidos em dados reais mostraram que ambos os métodos fornecem melhorias na acurácia da classificação, em comparação aos outros métodos já existentes.


Por fim, um método de redução de dimensionalidade chamado *Class Predability Semi-supervised DR* (CPSDR) é descrito por [Liang et al. \(2018\)](#). O algoritmo do CPSDR é baseado no *Local Fisher Discriminant Analysis* (LFDA). Diferentemente dos métodos semi-supervisionados, que focam apenas em uma pequena quantidade de dados rotulados e dependem da informação da geometria local, o CPSDR foca nas amostras não rotuladas e explora, além das informações da geometria local, a informação de estrutura da classe. Por meio dessas informações, a matriz de dispersão é mais discriminativa; em termos de implementação, o problema é formulado como uma otimização e é resolvido a partir de decomposição de autovalores. Os resultados obtidos a partir de dois conjuntos de dados de imagens sugerem que o método proposto apresenta uma matriz de dispersão intra e inter-classe mais discriminativa, alcançando uma performance de classificação eficiente que resulta em um método semi-supervisionado efetivo.

4 METODOLOGIA PROPOSTA

4.1 Área de estudo

De modo a verificar a metodologia proposta, dados da região de Mariana (Minas Gerais, Brasil) foram selecionados. Essa região é importante para este estudo, porque nela ocorreu um desastre ambiental envolvendo o rompimento de uma barragem, causando um despejo de rejeitos de minério no Rio Doce em 05 de novembro de 2015. A Figura 1 apresenta informações relacionadas à área de estudo.

Figura 1 – Informações relacionadas à área de estudo: localização da cidade de Mariana e do estado de Minas Gerais na América do Sul (a); destaque do Rio Doce, da bacia que recebe o mesmo nome do rio, e da hidrografia da região (b); sobreposição da imagem da área de estudo renderizada com a composição R(4)G(3)B(2) e com ajuste de contraste (c).



Fonte: Elaborado pela autora.

4.2 Materiais

A plataforma *Earth Explorer* da *United States Geological Survey* (USGS, 2024) foi usada para selecionar os dados da área de estudo a partir das seguintes informações: zona UTM 23; coordenadas 20°13'48,07"S e 42°43'47,24"W; data 12 de novembro de 2015; e identificador LC08_L1TP_217074_20151112_20170402_01_T1. Tais dados foram capturados pelo satélite Landsat 8 e foram obtidos do catálogo USGS no “Level L1TP”, garantindo uma representação precisa em termos radiométricos e geométricos.

A cena corresponde a uma das imagens estudadas por [Dias et al. \(2020\)](#) e, uma vez que sua metodologia foi executada neste estudo, os mesmos dados (satélite e área) também foram usados aqui, a fim de permitir uma comparação mais adequada entre os estudos. Sendo assim, foram consideradas oito bandas espectrais, com os comprimentos de onda (em micrômetros) e resoluções espaciais (em metros) apresentados na Tabela 2. Cada banda possui largura e altura de 7721×7831 pixels respectivamente, com exceção da banda 8, que possui 15441×15661 pixels.

Tabela 2 – Comprimentos de onda e resoluções espaciais das bandas do satélite Landsat 8.

Banda	Comprimento de onda (micrômetros)	Resolução espacial (metros)
1—Aerossol Costeiro	0,43-0,45 μm	30 m
2—Azul	0,45–0,51 μm	30 m
3—Verde	0,53–0,59 μm	30 m
4—Vermelho	0,64–0,67 μm	30 m
5—Infravermelho Próximo (NIR)	0,85–0,88 μm	30 m
6—SWIR 1	1,57–1,65 μm	30 m
7—SWIR 2	2,11–2,29 μm	30 m
8—Pancromática (PAN)	0,50–0,68 μm	15 m

Fonte: Elaborado pela autora.

O software *QGIS* e a *toolbox Orfeo*, i.e., as mesmas ferramentas usadas por [Dias et al. \(2020\)](#), foram empregadas neste estudo para as etapas envolvendo análise de imagem. Para a criação de gráficos e de visualizações, a linguagem *Python* e o ambiente de desenvolvimento *Colaboratory - Google* foram usados em virtude da eficiência na análise de dados.


4.3 Metodologia

4.3.1 Descrição resumida da metodologia

A Figura 2 apresenta a metodologia proposta. Assim como apresentado por [Dias et al. \(2020\)](#), a metodologia recebeu como dados de entrada as bandas 1 a 7 da cena do Landsat 8 (comentada no Subcapítulo 4.2). Elas foram adicionadas como *raster layers* de modo a criar um *raster* virtual dessas bandas. Esse *raster* virtual teve suas propriedades de renderização modificadas para a composição de bandas R(4)G(3)B(2), e de contraste ajustadas com base na média e desvio padrão, gerando uma imagem multiespectral (de 30 metros de resolução espacial) exibida em cores naturais. Em seguida, a banda 8 do conjunto de dados foi usada como entrada do *pan-sharpening* (também conhecido como fusão de imagens) que foi responsável

por gerar uma imagem com resolução espacial mais alta que a anterior (no caso, 15 metros). A imagem fusionada resultante também teve as propriedades de composição de bandas e o ajuste de contraste modificados, assim como foi feito, anteriormente, para a imagem multiespectral. Após, uma redução de dimensionalidade com *Principal Components Analysis* (PCA) foi aplicada na imagem fusionada, dando origem a uma imagem composta por sete componentes. Essa etapa foi a única que diferiu da metodologia apresentada por Dias et al. (2020).

Figura 2 – Sequência de etapas da metodologia proposta. A etapa usada para a redução de dimensionalidade encontra-se destacada em verde. Com essa etapa a metodologia proposta neste estudo diferencia-se da ADS-KT apresentada por Dias et al. (2020).



Fonte: Elaborado pela autora.

A metodologia continuou com a coleta de amostras da classe “água” e “não-água” na imagem fusionada em cores naturais, facilitando esse processo. Essas amostras delimitaram regiões que foram usadas para analisar visualmente algumas características das duas imagens (fusionada e das componentes do PCA). As amostras serviram como entrada para o treinamento, validação e teste dos classificadores, junto com as estatísticas de segunda ordem (REINHARD et al., 2004) que foram também computadas para as duas imagens. A partir desses dados, foram feitos treinamentos dos classificadores contextuais e não-contextuais e, em seguida, a classificação da imagem fusionada (duas classificações para essa imagem) e das diferentes combinações de componentes do PCA (duas classificações para cada uma das sete imagens). Por fim, os resultados obtidos foram analisados e comparados. Mais detalhes sobre os parâmetros usados em algumas etapas da metodologia podem ser encontrados no Apêndice A.

4.3.2 Descrição detalhada da metodologia


Uma visão mais detalhada da metodologia é apresentada na Figura 3. Inicialmente, as sete primeiras bandas (com resolução espacial de 30 metros cada), que compõem o conjunto de dados selecionado, foram adicionadas como *raster layers* a um projeto no *QGis*. A partir desses dados, um *raster* virtual foi criado por meio da sobreposição dessas bandas, de modo a facilitar a sua manipulação. Em seguida, as bandas 4 (vermelho), 3 (verde) e 2 (azul) foram escolhidas para a renderização do *raster*, e um aumento de contraste baseado na média e no desvio padrão foi realizado. Tais atividades foram importantes para melhorar a análise e a visualização das observações da imagem (*raster*) nas cores naturais.

Vamos considerar $f(x, y)$ uma função bidimensional que representa um *raster* (uma matriz numérica de dimensão $M \times N$), na qual podemos acessar o valor de intensidade do pixel nas coordenadas (x, y) , como mostra a Equação 4.1 (GONZALES; WINTZ, 1987).

$$f(x, y) = \begin{bmatrix} f(0, 0) & f(0, 1) & \dots & f(0, N - 1) \\ f(1, 0) & f(1, 1) & \dots & f(1, N - 1) \\ \vdots & \vdots & & \vdots \\ f(M - 1, 0) & f(M - 1, 1) & \dots & f(M - 1, N - 1) \end{bmatrix} \quad (4.1)$$

A notação matricial apresentada na Equação 4.2 também fornece uma representação de uma imagem e seus pixels, onde $a_{i,j} = f(x = i, y = j) = f(i, j)$ indica uma relação com a

Figura 3 – Fluxograma com uma visão detalhada da metodologia proposta.



Fonte: Elaborado pela autora.

representação anterior (GONZALES; WINTZ, 1987). Ambas notações serão usadas nas equações desse capítulo.

$$A = \begin{bmatrix} a_{0,0} & a_{0,1} & \dots & a_{0,N-1} \\ a_{1,0} & a_{1,1} & \dots & a_{1,N-1} \\ \vdots & \vdots & & \vdots \\ a_{M-1,0} & a_{M-1,1} & \dots & a_{M-1,N-1} \end{bmatrix} \quad (4.2)$$

Assim, podemos definir o *raster* virtual gerado nessa etapa como um vetor k -dimensional definido na Equação 4.3 (GONZALES; WINTZ, 1987). Nesse caso, $k = 7$ pois foram usadas sete bandas, e $b_1(x, y)$ corresponde à intensidade dos pixels da banda 1, e assim sucessivamente.

$$vr(x, y) = \begin{bmatrix} b_1(x, y) \\ b_2(x, y) \\ \vdots \\ b_k(x, y) \end{bmatrix} \quad (4.3)$$

Como o *raster* virtual é composto por sete bandas, apenas b_4 , b_3 e b_2 foram escolhidas para renderizar a imagem RGB no *QGIS*. Nesse processo de renderização a média (Equa-


ção 4.4) (GONZALES; WINTZ, 1987) e o desvio padrão (Equação 4.5) (GONZALES; WINTZ, 1987) foram calculados para ajustar o contraste, criando uma tabela de cores e facilitando a visualização da cena. Nas equações a seguir, K é um conjunto contendo os índices i das bandas da imagem f envolvidas nessa etapa, i.e., $K = \{4, 3, 2\}$.

$$g(x, y) = \frac{1}{|K|} \sum_{i \in K} f_i(x, y) \quad (4.4)$$

$$h(x, y) = \sqrt{\frac{1}{|K|} \sum_{i \in K} (f_i(x, y) - g(x, y))^2} \quad (4.5)$$

A Figura 4 apresenta o *raster* virtual (Figura 4a, a imagem multiespectral renderizada com as configurações definidas anteriormente), e as bandas (Figuras 4b-h) que o compõem. Nas Figuras 4b-h, as bandas são exibidas de modo a destacar apenas uma parte da área de estudo e que foi diretamente afetada pelo desastre ambiental. As bandas 4 (Figura 4e), 3 (Figura 4d) e 2 (Figura 4c) foram usadas para a composição em cores naturais apresentada na Figura 4a. Observa-se que o ajuste das configurações de renderização do *raster* auxilia a visualização das informações da cena em comparação com os dados brutos, apesar desse processo não modificar os dados originais (apenas a visualização).

Figura 4 – *Raster* virtual (a imagem multiespectral com resolução espacial de 30 metros) e as bandas que o compõem, após ajuste de contraste. A Figura (a) apresenta toda a área de estudo, enquanto as Figuras (b-h) destacam apenas uma parte dela e que foi diretamente afetada pelo desastre ambiental de Mariana.



Fonte: Elaborado pela autora.

Na etapa seguinte, foi feita uma fusão do *raster* virtual (composto pelas 7 bandas) com a banda 8 (pancromática, com resolução espacial de 15 metros). Esse processo é importante pois, seguindo a metodologia apresentada por Dias et al. (2020) e considerando a resolução espacial desses dados (30 metros), a visualização e a análise dos elementos presentes, e.g., corpos d'água, são melhoradas ao usar uma maior (e, conseqüentemente, melhor) resolução.

Para isso, a partir da *toolbox Orfeo*, primeiro foi realizada uma atividade chamada *superimpose sensor* para preparar o *raster* virtual e fazer a sua projeção. Com isso, existe uma projeção dessa imagem multiespectral na geometria da imagem pancromática. Em seguida, o *pan-sharpening* baseado na substituição de componentes (RCS) foi aplicado para fazer a fusão entre o *raster* virtual (já projetado) e a banda pancromática. Dessa forma, obtém-se uma imagem composta pelas sete bandas, mas com resolução espacial de 15 metros.

A Equação 4.6 descreve matematicamente as operações envolvidas nessa etapa. Na Equação 4.6 (VIVONE et al., 2015), k indica os índices das N bandas espectrais, g consiste em um vetor de *injection gains*, e w , um vetor de pesos. Assim, a partir da imagem multiespectral interpolada na escala da imagem pancromática ($S(x, y)$), a intensidade do componente I_L é calculada. Em seguida, o processo de *histogram matching* é feito entre a imagem pancromática P e o componente de intensidade I_L . Por fim, a partir da soma desses valores, o resultado do *pan-sharpening* ($R(x, y)$) é obtido (VIVONE et al., 2015; MHANGARA; MAPURISA; MUDAU, 2020; XU et al., 2014).


$$\begin{aligned}
 R_k(x, y) &= S_k(x, y) + g_k(P - I_L), \\
 \text{onde } k &= 1, \dots, N, \\
 g &= [g_1, \dots, g_k, \dots, g_N], \\
 I_L &= \sum_{i=1}^N w_i S_i(x, y), \\
 w &= [w_1, \dots, w_i, \dots, w_N].
 \end{aligned} \tag{4.6}$$

Depois, as bandas 4, 3 e 2 foram selecionadas para renderização, e o aumento de contraste também foi aplicado para uma melhor visualização da imagem nessa etapa. Esses processamentos anteriores (fusão e ajustes de renderização) são importantes porque facilitam a seleção manual de amostras na imagem estudada. Essa imagem é chamada de imagem fusionada.

A Figura 5 apresenta a imagem fusionada (Figura 5a) e as bandas (Figuras 5b-h) que a

compõem em uma região aproximada. As bandas 4 (Figura 5e), 3 (Figura 5d) e 2 (Figura 5c) foram usadas para a composição em cores naturais apresentada na Figura 5a. É possível observar que houve uma mudança na resolução espacial dos dados, ao comparar com as bandas da Figura 4.

Figura 5 – Imagem fusionada (com resolução espacial de 15 metros) e as bandas que a compõem, após ajuste de contraste. A Figura (a) apresenta toda a área de estudo, enquanto as Figuras (b-h) destacam apenas uma parte dela e que foi diretamente afetada pelo desastre ambiental de Mariana.



Fonte: Elaborado pela autora.

Em seguida, diferentemente da estratégia proposta por [Dias et al. \(2020\)](#), o método PCA foi aplicado para realizar a transformação do espaço de atributos na imagem fusionada. Essa etapa foi realizada por meio da *toolbox Orfeo*, sendo definida a quantidade de sete componentes de saída, ou seja, a mesma dimensão da imagem de entrada. Assim, a partir da imagem de entrada, com alta dimensão espacial, essa etapa gerou uma imagem com espaço de atributos transformado.

A preservação dessa dimensão (i.e., a manutenção de todas as sete componentes), que ocorreu em um primeiro momento, foi motivada pela seguinte hipótese: se as transformações no espaço de dados original impactam a ADS-KT mesmo que a dimensão seja mantida, então a redução da dimensionalidade também impacta a mesma estratégia, já que o espaço de dados original é transformado e reduzido como consequência da redução da dimensionalidade. Em outro momento, ainda dentro deste estudo, a verificação dessa hipótese aconteceu por meio do uso do método PCA associado à ADS-KT no espaço reduzido (i.e., considerando as diferentes combinações das componentes).

Em notações matemáticas, inicialmente o PCA realiza o cálculo da matriz de covariância a partir da imagem de entrada (NAVIN; AGILANDEESWARI; ANJANEYULU, 2020), nesse caso, a imagem fusionada. A matriz de covariância é composta pelas variâncias de cada dimensão e pelas covariâncias entre as diferentes combinações de dimensões, e permite calcular autovalores para a redução de dimensionalidade. A Equação 4.7 mostra esse processo, onde $\sigma_{i,j}$ corresponde à covariância de cada combinação das N bandas disponíveis, $D_{p,i}$ representa a intensidade do pixel p na banda i , e μ_i é a média de D para a banda i (ANTON; RORRES, 2012; GONZALES; WINTZ, 1987).

$$C = \begin{bmatrix} \sigma_{1,1} & \dots & \sigma_{1,n} \\ \vdots & \ddots & \vdots \\ \sigma_{n,1} & \dots & \sigma_{n,n} \end{bmatrix} \quad (4.7)$$

$$\text{onde } \sigma_{i,j} = \frac{1}{N-1} \sum_{p=1}^N (D_{p,i} - \mu_i)(D_{p,j} - \mu_j)$$

Ainda com relação ao PCA, os autovalores λ são calculados a partir da matriz de variância-covariância como raiz de $\det(C - \lambda I) = 0$, em que C é a matriz de covariância das bandas, e I é a matriz de identidade. Os autovetores t são calculados considerando os autovalores λ , i.e., $(C - \lambda I)t_k = 0$.

Durante essa etapa, os autovetores são ordenados em ordem decrescente de acordo com os respectivos autovalores associados. Assim, uma transformação é iniciada para que sejam obtidos os componentes principais. A matriz da Equação 4.8 apresenta os componentes principais, onde Y consiste no vetor de componentes principais, t é a matriz de transformação (composta pelos autovetores), e X corresponde ao vetor de dados originais de entrada (ANTON; RORRES, 2012).

$$Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} t_{1,1} & \dots & t_{1,n} \\ \vdots & \ddots & \vdots \\ t_{n,1} & \dots & t_{n,n} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} \quad (4.8)$$

Cada autovalor armazena a variância da componente principal correspondente, sendo que quanto maior o valor, maior a retenção de informação. Os autovetores, que definem as componentes principais, estão associados com seus respectivos autovalores e compõem a matriz de transformação para realizar o mapeamento dos dados do espaço original para o transformado.

As Tabelas 3 e 4 apresentam a matriz de transformação do PCA e os autovalores obtidos nessa etapa. Observa-se na Tabela 4 que a primeira componente é aquela que é responsável por reter aproximadamente 96,77% da informação, enquanto as últimas componentes armazenam menos informação.

Tabela 3 – Matriz do PCA usada para fazer a transformação linear dos dados no espaço de origem para o de destino. O número de colunas está vinculado ao número de bandas do espaço de origem e, o número de linhas, à quantidade de componentes da saída. Dessa forma, cada linha representa um autovetor.

	B1	B2	B3	B4	B5	B6	B7
C1	0,0000200588	0,0000189531	0,0000183327	0,0000180938	0,0000304597	0,0000252888	0,0000178068
C2	-0,0001402099	-0,0001599618	-0,0001427541	-0,0001565825	0,0001300476	0,0002326926	0,0000813597
C3	0,0000287708	0,0000009046	-0,0000244494	-0,0001309565	0,0003817231	-0,0002261554	-0,0002069157
C4	0,0013285182	0,0005975022	-0,0005057715	-0,0015201507	-0,0003385573	-0,0002220036	0,0008272668
C5	0,0010048158	0,0006950163	-0,0000885954	-0,0005777079	-0,0006700878	0,0020481686	-0,0029559561
C6	0,0016650022	0,0007759808	-0,0068226694	0,003885498	0,0005305906	-0,0002869542	-0,0001255631
C7	-0,0074477338	0,0103106066	-0,0016501533	-0,0017590062	0,0001468705	0,0001882505	0,0003829486

Fonte: Elaborado pela autora.

Tabela 4 – Autovalores do PCA vinculados a cada componente e a retenção de informação para cada uma.


Componente	Autovalor	Porcentagem do autovalor	Autovalor acumulado
1	302.165.501,8757	96,7660%	96,7660%
2	5.958.728,2976	1,9082%	98,6743%
3	3.872.234,0860	1,2401%	99,9143%
4	180.606,1683	0,0578%	99,9721%
5	65.720,3511	0,0210%	99,9932%
6	15.290,5374	0,0049%	99,9981%
7	5.959,5426	0,0019%	100%
Soma	312.264.040,8588	100%	

Fonte: Elaborado pela autora.

A Figura 6 apresenta a imagem resultante do PCA (a Figura 6a foi renderizada com as componentes 5, 6 e 7) e as componentes (Figuras 6b-h). As Figuras 6b-h destacam apenas uma parte da área de estudo e que foi diretamente afetada pelo desastre ambiental. É possível observar uma maior retenção de informação nas primeiras componentes em relação às últimas.

Na próxima etapa, a amostragem foi realizada selecionando-se manualmente 250 polígonos que delimitam regiões na imagem. Essa seleção foi realizada na imagem fusionada, já que ela estava nas cores naturais e em uma melhor resolução para a visualização das amostras. Para cada polígono, foi atribuída uma das classes (“água” ou “não-água”), de acordo com os elementos da região selecionada. Metade das 250 amostras corresponde a corpos d’água abertos, como lagos, rios, reservatórios, etc. Espera-se que esses corpos d’água abertos sejam classificados como “água” pelos classificadores. A outra metade corresponde a características geográficas diversas,

Figura 6 – Imagem resultante do PCA (renderizada com as componentes 5, 6 e 7) e as suas componentes. A Figura (a) apresenta toda a área de estudo, enquanto as Figuras (b-h) destacam apenas uma parte dela e que foi diretamente afetada pelo desastre ambiental de Mariana.




Fonte: Elaborado pela autora.

como campos, florestas, estradas, cidades, etc. Espera-se que essas características geográficas diversas sejam classificadas como “não-água” pelos classificadores. As observações diretamente relacionadas ao desastre ambiental, tais como reservatórios de rejeitos de minério, reservatórios de água e rios contaminados, por exemplo, não foram selecionadas como amostras para evitar resultados tendenciosos. Além disso, as amostras foram selecionadas de maneira bem distribuída na imagem, e a validação foi feita a partir de mapas topográficos da região ([Agência Nacional de Águas e Saneamento Básico \(ANA\), 2016](#)) adotados como *ground truth*. A Figura 7 apresenta um exemplo de amostra de cada classe, além de pontos indicando a dispersão de todas as amostras na imagem.


A Figura 8 apresenta uma representação do espaço espectral das amostras coletadas sobre a imagem fusionada. O espaço espectral é um sistema de coordenadas cujo número de dimensões consiste na dimensão do vetor que representa um pixel, i.e., no número de bandas de uma imagem ([RICHARDS, 2012](#)). Nesse sentido, para fazer essa visualização, cada pixel deve ser plotado como um ponto no espaço seguindo a sua intensidade em cada uma das direções de coordenadas. Uma vez que a visualização é facilitada em duas dimensões, apenas duas bandas foram selecionadas para gerar esses gráficos: infravermelho próximo e vermelho visível, que permitem a análise de coberturas como água, vegetação, solo, etc. Entretanto, caso outras bandas fossem selecionadas, poderia haver outra diferenciação entre outros tipos de cobertura.

Figura 7 – Os pontos em vermelho, na Figura (a), indicam as localizações das amostras coletadas na imagem. Exemplo de amostras de água (b) e não-água (c) selecionadas na imagem, em uma região aproximada.



Fonte: Elaborado pela autora.

Figura 8 – Gráfico de pontos do espaço espectral dos pixels das amostras usando a banda infravermelho próximo (5, NIR) e a banda vermelho (4, Red). Os pontos em azul indicam os pixels das amostras de água e, em cinza, não-água. A Figura (a) mostra todo o gráfico, enquanto a Figura (b), uma aproximação (*zoom*) na região dos pixels das amostras de água. Em outras palavras, a Figura (b) é a ampliação (*zoom*) do canto inferior esquerdo da Figura (a).



(a) Pixels de todas as amostras.


(b) *Zoom* na região próxima dos pixels da classe água.

Fonte: Elaborado pela autora.

O gráfico permite uma análise dos valores de todos os pixels das regiões delimitadas pelas amostras nas bandas infravermelho próximo e vermelho visível. Essa correlação é importante para entender a representatividade e a separabilidade das amostras coletadas no espaço espectral das bandas selecionadas, antes de realizar o treinamento dos classificadores. É possível observar que a maior parte dos pixels da classe água (pontos azuis) não estão sobrepostos no espaço dos pixels das amostras de não água (pontos cinza). Sendo assim, apesar da sobreposição de alguns pontos nesse espaço, é possível observar uma separação entre as classes.

Logo após, características foram extraídas da imagem fusionada e das componentes do PCA considerando as regiões selecionadas na amostragem. Assim, para cada amostra foi usada a média (Equação 4.9) e o desvio padrão (Equação 4.10) dos valores dos pixels em cada banda ou componente da imagem, gerando distribuições de valores. A Figura 9 representa graficamente essa etapa da metodologia proposta neste estudo.

Figura 9 – Processo de extração de características das imagens. Cada imagem possui sete bandas ou componentes. O processo para duas amostras (A, em vermelho, e B, em azul) é exemplificado. A média e o desvio padrão foram calculados levando-se em consideração as regiões delimitadas pelas amostras.



Fonte: Elaborado pela autora.

As equações a seguir apresentam essas métricas, sendo $S_{x,y,k}$ um subconjunto de M elementos da imagem f , que representa uma amostra coletada sobre as k bandas ou componentes (GONZALES; WINTZ, 1987).


$$mean_k = \frac{1}{M} \sum_{(s,t) \in S_{x,y,k}} f_k(s,t) \quad (4.9)$$

$$std_k = \sqrt{\frac{1}{M} \sum_{(s,t) \in S_{x,y,k}} [f_k(s,t) - mean_k]^2} \quad (4.10)$$

A partir dessas distribuições, visualizações do tipo gráfico de densidade, diagrama de caixa, e mapa de calor foram geradas (ver Figuras 11, 12, 13 e 14 do Capítulo 5). A primeira consiste em gráficos de densidade úteis para comparar visualmente distribuições de duas ou mais variáveis. Já a segunda permite visualizar informações como: dados discrepantes, limite inferior e superior e quartis de uma distribuição de valores. A última visualização permite analisar, a partir de cores, a relação entre valores de uma matriz. Tais visualizações foram úteis para analisar as diferenças entre os dois espaços de atributos.

Em seguida, como mostra a Figura 10, as seguintes combinações das sete componentes do PCA foram feitas considerando apenas a primeira componente (PC 1) e o empilhamento das primeiras: duas componentes (PC 1–2); três componentes (PC 1–2–3); quatro componentes (PC 1–2–3–4); cinco componentes (PC 1–2–3–4–5); seis componentes (PC 1–2–3–4–5–6); e todas as componentes (PC 1–2–3–4–5–6–7). Esse processo gerou sete imagens, cada uma com uma quantidade de informação diferente.

Figura 10 – Geração das combinações de componentes do PCA. Para os *rasters* com mais de três componentes, as três últimas foram escolhidas para a sua renderização RGB. Por exemplo, na Figura (j), as componentes 2, 3 e 4 foram escolhidas; na Figura (k), componentes 3, 4 e 5; na Figura (l), componentes 4, 5 e 6; e na Figura (m), componentes 5, 6 e 7.



Fonte: Elaborado pela autora.

Desse modo, as abordagens de treinamento, de validação e de teste de dois classificadores (*Boost* - contextual; *Decision Tree* ou Árvore de Decisão – não contextual) foram realizadas separadamente para a imagem fusionada e para as sete combinações das componentes do PCA. Para tanto, foi necessário computar as estatísticas de segunda ordem dessas imagens por meio da *toolbox Orfeo*, de acordo com as Equações 4.11 e 4.12 (GONZALES; WINTZ, 1987). Essa

etapa resulta em um arquivo para cada imagem f (de dimensão $M \times N$), contendo a média $mean$ e o desvio padrão std de cada banda ou componente k . Tais informações foram necessárias para a construção dos modelos, que foram gerados considerando cada um dos dois classificadores e uma das oito imagens, totalizando dezesseis modelos.

$$mean_k = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f_k(x, y) \quad (4.11)$$

$$std_k = \sqrt{\frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [f_k(x, y) - mean_k]^2} \quad (4.12)$$

O classificador *Boost*, durante seu treinamento, realiza uma sequência de passos a partir de um conjunto de dados $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, onde x_i representa uma amostra e y_i o seu respectivo rótulo ($y_i \in -1, 1$). Seja $D_t(x_i, y_i)$ a t -ésima distribuição sobre as amostras, a etapa começa com a inicialização dos pesos $D_0(x_i, y_i)$ (Equação 4.13). Em seguida, um processo iterativo (em relação a $t = 1, \dots, T$, onde T é o número máximo de épocas de treinamento) se inicia. Dentro desse processo iterativo as seguintes etapas são realizadas: treino de um classificador h_j (para cada característica j) que está restrito a usar uma única característica e que o erro ϵ_j é calculado como mostrado na Equação 4.14; escolha do classificador fraco h_j com o menor erro ϵ_j seguindo as regras da Equação 4.15; atualização dos pesos $D_{t+1}(x_i, y_i)$, conforme exibido na Equação 4.16, em que a constante de normalização Z_t garante que $D_t(x_i, y_i)$ seja uma distribuição normal, i.e. $\sum_{i=1}^N D_t(x_i, y) = 1$; Esse processo iterativo é feito até que um critério de parada seja satisfeito ($\epsilon \geq 1/2$, em Equação 4.15) ou o número máximo de épocas de treinamento T seja atingido. Ao final desses passos, a saída final $H(x)$ é obtida, de acordo com a Equação 4.17 (SHEN; LI, 2010; OpenCV Project, 2019a).

$$D_0(x_i, y_i) = \frac{1}{N}, \quad i = 1, \dots, N \quad (4.13)$$

$$\epsilon_j = \sum_{i: y_i \neq h_j} D_t(x_i, y_i) \quad (4.14)$$

$$\begin{aligned} \text{Se } \epsilon_t &\geq \frac{1}{2}, & \text{então } \textit{pare} \\ \text{se não } \alpha_t &= \frac{1}{2} \ln\left(\frac{1 - \epsilon_t}{\epsilon_t}\right) \end{aligned} \quad (4.15)$$

$$D_{t+1}(x_i, y_i) = \frac{D_t(x_i, y_i)e^{-\alpha_t y_t h_t(x_i)}}{Z_t} \quad (4.16)$$

$$H(x) = \text{sign}\left(\sum_{t=1}^T \alpha_t h_t(x)\right), \quad \text{sign}(x) \begin{cases} -1, & x < 0 \\ 0, & x = 0 \\ 1, & x > 0 \end{cases} \quad (4.17)$$

O classificador *Decision Tree* ou Árvore de Decisão, por sua vez, realiza a construção de uma estrutura de árvore a partir dos dados do treinamento. O *Iterative Dichotomiser 3* (ID3), por exemplo, é um algoritmo que realiza a construção da árvore de decisão a partir da entropia ($Ent(D)$, que consiste na impureza de uma coleção de amostras D de cada nó da árvore) e do ganho de informação ($Gain(D, a)$, que representa a redução esperada na entropia da coleção de amostras D em relação ao atributo a), apresentados nas Equações 4.18 e 4.19 (YI-BIN; YING-YING; XUE-WEN, 2017; SWAIN; HAUSKA, 1977; OpenCV Project, 2019b), respectivamente. Nesse processo são considerados: o conjunto de treinamento $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ e um conjunto de atributos $A = \{a_1, a_2, \dots, a_d\}$ de D , como cor, formato, textura, etc., onde $d = \{1, 2, \dots, k\}$; p_k ($k = 1, 2, \dots, |D|$), que consiste na proporção de cada tipo para cada conjunto de amostra atual; $V = \{a_i^1, a_i^2, \dots, a_i^v\}$, que é um conjunto de v características para cada atributo a_i , e D_v , que representa o subconjunto de amostras referente ao valor a_i^v de a_i em D . Assim, considerando esses dados, um processo recursivo é iniciado a partir do nó raiz e todos os dados de treinamento. O critério de pureza é aplicado em cada nó para encontrar a divisão ideal a fim de gerar novos nós-filhos. Caso alguns critérios de parada sejam atingidos (e.g., tamanho máximo do galho foi atingido, todas as amostras de um nó são da mesma classe, etc.), o processo recursivo é parado. Algumas otimizações de poda da árvore podem ser usadas em algumas implementações.

$$Ent(D) = - \sum_{d=1}^k p_k \log_2 p_k \quad (4.18)$$

$$Gain(D, a) = Ent(D) - \sum_{v=1}^V \frac{|D_v|}{|D|} Ent(D_v) \quad (4.19)$$

As etapas de treinamento e validação dos modelos dos classificadores foram realizadas considerando a imagem fusionada e as combinações de componentes do PCA. Para isso, além

das amostras selecionadas anteriormente, cada imagem analisada e o seu arquivo de estatísticas de segunda ordem foram usados. Durante essas etapas, metade (50%) das amostras foi usada para treinar cada modelo (i.e., ajustar os hiperparâmetros) e, o restante (50%), para validar (i.e., avaliar o desempenho). Embora as amostras tenham sido selecionadas sobre a imagem fusionada, os mesmos polígonos georreferenciados foram usados para indicar as mesmas regiões na imagem do PCA. Assim, os modelos aprenderam (com determinado desempenho) a classificar cada pixel dessas amostras de treinamento nas duas classes envolvidas no problema.

Em seguida, foi realizada a etapa de classificação da imagem fusionada e das combinações de componentes do PCA. Essa etapa considerou os modelos previamente treinados e validados. Assim, para cada imagem, foram usados também o respectivo arquivo de estatísticas de segunda ordem e o modelo correspondente. Cada resultado dessa etapa consiste em uma imagem binária contendo a classificação dos objetos da classe “água” na cor preta e da classe “não-água” na cor branca. Nessa etapa, o classificador atribui automaticamente, para cada pixel da imagem inteira, a classe a que o pixel pertence: “água” ou “não-água”.

Uma análise das diferenças entre as classificações contextuais e não contextuais foi realizada. Para tal atividade, algumas métricas foram obtidas e analisadas considerando os valores das matrizes de confusão geradas antes da classificação, ou seja, durante a etapa de validação. Além disso, uma análise visual das imagens obtidas na etapa de classificação foi feita. Essa etapa é importante para verificar a ocorrência ou não de divergências.

As matrizes de confusão foram construídas visando a etapa de análise do desempenho dos classificadores nas regiões cujas classes são previamente conhecidas, ou seja, nas amostras. Dada a quantidade real de pixels da classe positiva (“água”) e negativa (“não-água”) envolvidas no problema, a matriz de confusão apresenta a quantidade de pixels dessas classes preditas correta (verdadeiro) e incorretamente (falso) pelo classificador. A estrutura de uma matriz de confusão é apresentada na Tabela 5.

Tabela 5 – Matriz de confusão.

		Predito	
		Não-água	Água
Real	Não-água	Verdadeiro Negativo (VN)	Falso Positivo (FP)
	Água	Falso Negativo (FN)	Verdadeiro Positivo (VP)

Fonte: Elaborado pela autora.

A matriz de confusão permite analisar a quantidade de: Verdadeiros Negativos (VN, i.e.,

pixels da classe “não-água” preditos corretamente como “não-água”), Falsos Positivos (FP , i.e., pixels da classe “não-água” preditos incorretamente como “água”), Falsos Negativos (FN , i.e., pixels da classe “água” preditos incorretamente como “não-água”) e Verdadeiros Positivos (VP , i.e., pixels da classe “água” preditos corretamente como “água”). Diversas métricas podem ser calculadas a partir da matriz de confusão para sintetizar as informações descritas anteriormente em um único valor, e.g., as métricas acurácia (Equação 4.20), precisão (Equação 4.21), *recall* (Equação 4.22), *F1-score* (Equação 4.23) e *Kappa score* (Equação 4.24) (FAWCETT, 2006; COHEN, 1960). Essas métricas, que são importantes para comparar os desempenhos dos modelos treinados, são apresentadas a seguir.

$$\text{Acurácia} = \frac{VN + VP}{VN + FP + FN + VP} \quad (4.20)$$

$$\text{Precisão} = \frac{VP}{FP + VP} \quad (4.21)$$

$$\text{Recall} = \frac{VP}{FN + VP} \quad (4.22)$$

$$\text{F1-score} = \frac{2 \times \text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (4.23)$$

$$\text{Kappa score} = \frac{2 \times (VN \times VP - FP \times FN)}{(FP + VP) \times (VN + FP) + (FN + VP) \times (FN + VN)} \quad (4.24)$$


A acurácia representa a taxa de acertos da classificação sobre a quantidade total de classificações, indicando a eficiência dos resultados. A precisão mede a taxa de acertos da classificação na classe positiva, mensurando a relevância dos resultados. O *recall*, também chamado de taxa de verdadeiros positivos ou sensibilidade do modelo, indica a quantidade de resultados positivos relevantes. O *F1-score* calcula a média harmônica entre precisão e *recall* e fornece uma taxa considerando essas duas métricas. Por fim, o *Kappa score* representa a taxa de concordância entre as classificações.

5 RESULTADOS


A partir das amostras selecionadas anteriormente, as métricas média e desvio padrão foram usadas para analisar visualmente parte do espaço de atributos da imagem fusionada (bandas) e da imagem resultante do PCA (componentes). Dessa forma, para cada amostra foi considerada a região delimitada em cada banda ou componente da respectiva imagem e, cada métrica foi calculada sobre esse conjunto de pixels. Ao realizar esse cálculo para todas as amostras, uma distribuição de valores foi obtida para cada métrica e imagem. Assim, visualizações do tipo gráfico de densidade, diagramas de caixa e mapas de calor foram geradas para comparar os valores obtidos.

A Figura 11 apresenta duas visualizações do tipo gráfico de densidade considerando a média das características extraídas. A Figura 11a é referente aos resultados obtidos com as amostras sobre a imagem fusionada, e a Figura 11b, sobre a imagem do PCA. Essas visualizações permitem uma análise das médias dos valores de intensidade (pixels) em cada banda ou componente da imagem.

Figura 11 – Gráficos de densidade obtidos considerando a média das características extraídas sobre a imagem fusionada (a) e a imagem do PCA (b). Em cada visualização, uma distribuição é gerada para cada banda ou componente.



(a) Distribuições dos valores médios das amostras sobre as bandas da imagem fusionada.




(b) Distribuições dos valores médios das amostras sobre as componentes da imagem do PCA.

Fonte: Elaborado pela autora.


Observa-se na Figura 11a que as distribuições da média para a imagem fusionada seguem o padrão encontrado em seu histograma, em termos de valores de intensidade, amplitude e largura da distribuição. As Bandas 5 e 6 estão mais deslocadas que as demais, além de apresentarem uma distribuição mais dispersa. As Bandas 1, 2 e 3 são aquelas que possuem uma distribuição com maior amplitude. Paralelamente, a Figura 11b mostra que, após a transformação do PCA, a Componente 1 foi aquela que apresentou uma distribuição que se destaca das demais em termos de amplitude. Isso mostra que a média dos valores de intensidade dos pixels delimitados pelas amostras na Componente 1 está majoritariamente entre 0 e 1. Outro ponto importante a ser destacado é em relação aos novos valores de intensidade nesse espaço transformado, em que a maioria das distribuições está com valores entre -3 e 3 . Assim a transformação do PCA modificou os valores de intensidade em um novo intervalo.

Ainda considerando o mesmo tipo de visualização, distribuições do desvio padrão de cada amostra foram geradas para cada banda ou componente da imagem. Esses resultados são apresentados na Figura 12, sendo que a Figura 12a considera a imagem fusionada, e a Figura 12b, a imagem do PCA.

Figura 12 – Gráficos de densidade obtidos considerando o desvio padrão das características extraídas sobre a imagem fusionada (a) e a imagem do PCA (b). Em cada visualização, uma distribuição é gerada para cada banda ou componente.



(a) Distribuições dos valores de desvio padrão das amostras sobre as bandas da imagem fusionada.



(b) Distribuições dos valores de desvio padrão das amostras sobre as componentes da imagem do PCA.


Fonte: Elaborado pela autora.

A Figura 12a mostra que as distribuições de desvio padrão das Bandas 5, 6 e 7 foram aquelas que desviaram das outras distribuições, que tiveram um valor mediano próximo de 250 a


500. Isso mostra que o desvio padrão das amostras nessas três bandas abrange um intervalo maior de valores. Já a Figura 12b mostra que a Componente 1 se destaca das demais (comportamento evidenciado também na Figura 11b). Isso indica que as regiões delimitadas pelas amostras nessa Componente 1 tiveram valor de desvio padrão próximo de 0 e 0,25 após a aplicação do PCA, enquanto as outras componentes apresentaram valores mais dispersos.

Alguns diagramas de caixa foram gerados a partir das duas métricas (média e desvio padrão). Assim, em cada visualização considerou-se uma métrica e obteve-se um diagrama para cada componente ou banda. A Figura 13 exibe essas visualizações. A partir dessas visualizações, é possível realizar uma comparação mais minuciosa entre os valores obtidos pelas métricas para as duas imagens.

Figura 13 – Diagramas de caixa obtidos considerando as características extraídas sobre a imagem fusionada (a) e a imagem do PCA (b), e considerando a média e o desvio padrão. Cada visualização considera uma das métricas usadas para cada banda ou componente.



(a) Diagramas de caixa da média e do desvio padrão das amostras sobre as bandas da imagem fusionada.




(b) Diagramas de caixa da média e do desvio padrão das amostras sobre as componentes da imagem do PCA.

Fonte: Elaborado pela autora.

A Figura 13a mostra que as caixas referentes às distribuições das Bandas 5 e 6 são aquelas com maior amplitude (intervalo interquartil), e valor mediano desviando da tendência das outras bandas. Isso acontece tanto na média quanto no desvio padrão. Tal fato indica que, as regiões delimitadas pelas amostras nessas bandas estão gerando uma distribuição com maior variabilidade de valores. Além disso, observa-se que as distribuições das outras bandas possuem um menor intervalo interquartil e uma quantidade relevante de *outliers*. Ou seja, existem regiões em que essas métricas desviam da tendência geral da distribuição. Já a Figura 13b indica que a Componente 1 possui uma distribuição de valores diferente das demais, apesar do intervalo interquartil ser o menor. Isso evidencia que as amostras analisadas nessa componente apresentaram valores médios e de desvio padrão dentro de um intervalo menor de valores, enquanto as demais componentes indicam um intervalo maior.

Por fim, considerando apenas os valores de desvio padrão obtidos nas bandas da imagem fusionada e nas componentes da imagem resultante do PCA, a similaridade por cossenos dessas distribuições foi calculada para mostrar quão semelhantes são esses valores, ou seja, se existem bandas ou componentes com valores de desvio padrão parecidos. Três mapas de calor foram construídos considerando a similaridade entre: a imagem fusionada e a imagem do PCA; apenas a imagem fusionada; e apenas a imagem do PCA. Tais visualizações, exibidas na Figura 14, são úteis para analisar a relação entre esses valores.

Figura 14 – Mapas de calor obtidos a partir da similaridade de cossenos das distribuições do desvio padrão das amostras entre a imagem fusionada e a do PCA (a), apenas a imagem fusionada (b) e apenas a imagem do PCA (c). Valores próximos de 1 indicam maior similaridade.



Fonte: Elaborado pela autora.

Observa-se na Figura 14a menores similaridades (valores próximos de 0,5) ao comparar o desvio padrão das Bandas 1, 2 e 3 da imagem fusionada com o desvio padrão da Componente 3 da imagem do PCA. Ou seja, existe uma maior diferença ao comparar as distribuições de valores

das Bandas 1, 2 e 3 com a distribuição de valores da Componente 3. Já na Figura 14b, é possível observar que existem maiores similaridades (valores próximos de 1, 0) entre os valores de desvio padrão das Bandas 1, 2, 3 e 4, assim como entre os valores de desvio padrão das Bandas 6 e 7. Por fim, a Figura 14c mostra que existem menores similaridades (valores próximos de 0, 65) ao comparar os valores de desvio padrão das Componentes 1, 2 e 7 com o desvio padrão da Componente 3.

Matrizes de confusão foram geradas durante a validação dos dois modelos de classificação treinados com cada uma das oito imagens. Essas matrizes apresentam a quantidade de acertos e erros obtidos pelos modelos nas amostras selecionadas, cujas classes dos pixels (“água” e “não-água”) já são conhecidas. A partir desses valores, as métricas acurácia, precisão, *recall*, *f1-score* e *Kappa score* foram obtidas para uma análise geral da performance de cada modelo. As Tabelas 6, 7, 8, 9, 10, 11, 12 e 13 apresentam esses valores.

Tabela 6 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem fusionada.

Classificador	Matriz de confusão				Acurácia	Precisão	Recall	F1-score	Kappa score
			Predito						
			Não-água	Água					
Decision Tree	Real	Não-água	1607	60	0,9643	0,9640	0,9646	0,9643	0,93
		Água	59	1608					
Boost	Real	Não-água	1625	42	0,9685	0,9745	0,9622	0,9683	0,94
		Água	63	1604					

Fonte: Elaborado pela autora.

Tabela 7 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1.

Classificador	Matriz de confusão				Acurácia	Precisão	Recall	F1-score	Kappa score
			Predito						
			Não-água	Água					
Decision Tree	Real	Não-água	1454	213	0,8629	0,8698	0,8536	0,8616	0,73
		Água	244	1423					
Boost	Real	Não-água	1465	202	0,8986	0,8834	0,9184	0,9006	0,80
		Água	136	1531					

Fonte: Elaborado pela autora.

Tabela 8 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1 – 2.

Classificador	Matriz de confusão				Acurácia	Precisão	Recall	F1-score	Kappa score
			Predito						
			Não-água	Água					
Decision Tree	Real	Não-água	1613	54	0,9598	0,9671	0,9520	0,9595	0,92
		Água	80	1587					
Boost	Real	Não-água	1579	88	0,9538	0,9479	0,9604	0,9541	0,91
		Água	66	1601					

Fonte: Elaborado pela autora.

Tabela 9 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1 – 2 – 3.

Classificador	Matriz de confusão			Acurácia	Precisão	Recall	F1-score	Kappa score
	Preditto							
		Não-água	Água					
Decision Tree	Real	Não-água	1622	45	0,9682	0,9727	0,9634	0,9681
		Água	61	1606				
Boost	Real	Não-água	1616	51	0,9574	0,9687	0,9454	0,9569
		Água	91	1576				

Fonte: Elaborado pela autora.

Tabela 10 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1 – 2 – 3 – 4.

Classificador	Matriz de confusão			Acurácia	Precisão	Recall	F1-score	Kappa score
	Preditto							
		Não-água	Água					
Decision Tree	Real	Não-água	1631	36	0,9724	0,9781	0,9664	0,9722
		Água	56	1611				
Boost	Real	Não-água	1615	52	0,9697	0,9689	0,9706	0,9697
		Água	49	1618				

Fonte: Elaborado pela autora.

Tabela 11 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1 – 2 – 3 – 4 – 5.

Classificador	Matriz de confusão			Acurácia	Precisão	Recall	F1-score	Kappa score
	Preditto							
		Não-água	Água					
Decision Tree	Real	Não-água	1597	70	0,9601	0,9582	0,9622	0,9602
		Água	63	1604				
Boost	Real	Não-água	1600	67	0,9646	0,9602	0,9694	0,9648
		Água	51	1616				

Fonte: Elaborado pela autora.

Tabela 12 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1 – 2 – 3 – 4 – 5 – 6.

Classificador	Matriz de confusão			Acurácia	Precisão	Recall	F1-score	Kappa score
	Preditto							
		Não-água	Água					
Decision Tree	Real	Não-água	1634	33	0,9718	0,9799	0,9634	0,9716
		Água	61	1606				
Boost	Real	Não-água	1629	38	0,9715	0,9769	0,9658	0,9713
		Água	57	1610				

Fonte: Elaborado pela autora.

Essas tabelas mostram semelhança entre os desempenhos dos modelos treinados com as imagens: fusionada (Tabela 6), PC 1 – 2 (Tabela 8), PC 1 – 2 – 3 (Tabela 9), PC 1 – 2 – 3 – 4 (Tabela 10), PC 1 – 2 – 3 – 4 – 5 (Tabela 11), PC 1 – 2 – 3 – 4 – 5 – 6 (Tabela 12) e PC 1 – 2 – 3 – 4 – 5 – 6 – 7 (Tabela 13). As métricas dos classificadores, considerando essas imagens,

Tabela 13 – Matriz de confusão e métricas do desempenho dos modelos, considerando a imagem PC 1 – 2 – 3 – 4 – 5 – 6 – 7.

Classificador	Matriz de confusão				Acurácia	Precisão	Recall	F1-score	Kappa score
			Preditó						
			Não-água	Água					
Decision Tree	Real	Não-água	1619	48	0,9742	0,9714	0,9772	0,9743	0,95
		Água	38	1629					
Boost	Real	Não-água	1620	47	0,9727	0,9719	0,9736	0,9727	0,95
		Água	44	1623					

Fonte: Elaborado pela autora.

tiveram valores semelhantes (próximos de 0,90), tanto para o classificador contextual (*Boost*) quanto para o classificador não-contextual (*Decision Tree*). Isso significa que esses modelos, após o treinamento, tiveram desempenho relevante e as quantidades de acertos e erros foram semelhantes ao classificar as regiões das amostras de validação nas classes “água” e “não-água”.

Entretanto, na Tabela 7, observa-se que os dois classificadores treinados sobre a imagem PC 1 não obtiveram um resultado tão semelhante aos demais. Os valores da matriz de confusão apresentaram uma quantidade maior de Falsos Negativos e Verdadeiros Negativos e, conseqüentemente as métricas ficaram próximas de 0,70 e 0,80. Tal desempenho indica que, após o treinamento, esses modelos tiveram taxa de erro maior e taxa de acerto menor que os demais modelos treinados com as outras imagens.

As matrizes de confusão e as métricas apresentadas anteriormente são ideais para analisar o desempenho dos dois classificadores treinados em cada uma das imagens. Entretanto, essa performance considera apenas os pixels delimitados pelas amostras de validação. Dessa forma, a análise dos resultados das classificações das imagens também é indispensável, já que outras regiões da imagem que não foram fornecidas durante o treinamento são apresentadas ao classificador. Além disso, independente do seu desempenho durante a validação, esse classificador pode ter um comportamento inesperado ao classificar essas novas regiões, pois os elementos presentes na imagem podem ser diferentes do esperado.

A incongruência é uma indicação da presença de anomalias e acontece quando ocorre divergência nas predições. A abordagem usada, neste estudo, para mensurar a incongruência foi a análise da divergência, responsável por verificar a diferença entre duas distribuições de probabilidade. Isso é necessário porque é esperado que as duas classificações (contextual e não-contextual) produzam estimativas de probabilidade semelhantes durante a etapa de classificação para a mesma imagem. Dessa forma, os resultados das duas classificações para a mesma região


foram analisados em conjunto, para identificar a presença de anomalias.

As Figuras 15, 16, 17, 18, 19, 20, 21 e 22 apresentam parte dos resultados (em quatro recortes da área de estudo) da classificação contextual (obtida pelo classificador *Boost*) e não contextual (obtida pelo classificador *Decision Tree*). As duas primeiras linhas de cada figura mostram duas regiões com corpos d'água poluídos (i.e., afetados pelo desastre e indicados pelas setas vermelhas) e não poluídos (i.e., não afetados pelo desastre e indicados pelas setas azuis). A terceira linha mostra uma região com um corpo d'água poluído, e a última linha, com um corpo d'água não poluído. Para a imagem fusionada e para as combinações de componentes do PCA, cada figura mostra, na respectiva região, os resultados das duas classificações (*Boost* e *Decision Tree*).

A Figura 15 mostra as regiões da imagem fusionada (Figuras 15a, 15d, 15g, 15j) e os resultados da sua classificação contextual (Figuras 15b, 15e, 15h, 15k) e não-contextual (Figuras 15c, 15f, 15i, 15l) para cada uma das quatro regiões da área de estudo. Ao analisar as classificações dos corpos d'água que foram afetados pelo desastre ambiental, e.g., as partes indicadas pelas setas vermelhas (Figuras 15a, 15d, 15g), observa-se que houve divergência entre a classificação contextual e a não contextual em cada região. Isso indica incongruência em relação aos corpos d'água poluídos. Esse fato não ocorre na classificação de outros corpos d'água não afetados pelo desastre, e.g., aqueles indicados pelas setas azuis (Figuras 15a, 15d, 15j). Isso indica congruência para água não contaminada com rejeito de minérios.

Outras situações são observadas ao analisar os resultados das classificações obtidas a partir das combinações das componentes do PCA, i.e., considerando as diferentes camadas de informação. A Figura 16 apresenta os resultados das classificações contextual (Figuras 16b, 16e, 16h, 16k) e não-contextual (Figuras 16c, 16f, 16i, 16l), considerando apenas a primeira componente (Figuras 16a, 16d, 16g, 16j). Observa-se que ambos classificadores foram capazes de classificar corpos d'água poluídos como “não-água”, e.g., aqueles indicados pelas setas vermelhas nas Figuras 16a, 16d, 16g. Entretanto, classificaram como “água” apenas corpos d'água não afetados pelo desastre ambiental, e.g., aqueles indicados pelas setas azuis nas Figuras 16a, 16d, 16j. A classificação contextual apresenta resultados com muitos ruídos, o que pode ter impactado negativamente os valores da matriz de confusão e das métricas apresentados na Tabela 7. Há congruência entre as classificações de corpos d'água poluídos e não poluídos, uma vez que os classificadores não apresentam classificações divergentes em relação ao mesmo corpo d'água da região mostrada.


Figura 15 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem fusionada em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d'água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d'água não afetados pelo desastre, portanto não poluídos com rejeito de minérios.



Fonte: Elaborado pela autora.

Analisando os resultados das classificações na Figura 17, que exibe a imagem composta pelas duas primeiras componentes nas quatro regiões (Figuras 17a, 17d, 17g, 17j), observa-se que, nas duas primeiras regiões (Figuras 17a-f), houve divergências parciais para classificação dos corpos d'água poluídos, indicados pelas setas vermelhas nas Figuras 17a e 17d. Essas

Figura 16 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera apenas a primeira componente (PC 1) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios.



Fonte: Elaborado pela autora.

divergências ocorreram porque o classificador não-contextual (Figuras 17c e 17f) identificou o rio contaminado de maneira menos intensa do que o classificador contextual (Figuras 17b e 17e). Ambos os classificadores identificaram os corpos d’água não poluídos, indicados pelas setas azuis nas Figuras 17a e 17d, como “água”. Na terceira região, observou-se congruência

nos resultados dos classificadores para o corpo d'água poluído apresentado (Figuras 17g, 17h, 17i), fenômeno também observado ao classificarem o corpo d'água não poluído na última região (Figuras 17j, 17k, 17l). Portanto, identificou-se incongruência parcial ou congruência para a classificação dos corpos d'água poluídos e congruência para a classificação dos corpos d'água não poluídos.


Essa mesma análise se aplica à Figura 18, que apresenta as classificações da imagem composta pelas três componentes nas mesmas regiões (Figuras 18a, 18d, 18g, 18j). Ambos os classificadores mostraram concordância ao classificar os corpos d'água não poluídos como “água”. Em relação aos corpos d'água poluídos, foi encontrada incongruência parcial (Figuras 18b, 18c e 18e, 18f) ou congruência (Figuras 18h, 18i).

A Figura 19 exibe os resultados das classificações da imagem composta pelas quatro primeiras componentes. Ela também mostra resultados mais próximos dos obtidos com a imagem fusionada (Figura 15). O classificador contextual identificou corpos d'água poluídos e não poluídos como “água” nas Figuras 19b, 19e e 19k. Em contrapartida, o classificador não-contextual identificou corpos d'água poluídos como “não-água” e corpos d'água não poluídos como “água” (Figuras 19c, 19f, 19l). No entanto, na terceira região (Figuras 19g, 19h, 19i), os resultados divergiram do esperado: o classificador contextual (Figura 19h) classificou uma parte poluída do rio como “não-água”, enquanto o não-contextual (Figura 19i) a classificou como “água”. Embora essa inversão tenha ocorrido nessa região específica, ambos os classificadores mantiveram a incongruência na classificação dos corpos d'água poluídos e a congruência nos corpos d'água não poluídos.

Na Figura 20, ao analisar a imagem composta pelas cinco componentes do PCA, observa-se que ambos os classificadores identificaram corpos d'água poluídos como “não-água” e corpos d'água não poluídos como “água” (Figuras 20b, 20c, 20e, 20f, 20h, 20i, 20k, 20l). Esses resultados indicam concordância nas classificações para ambas as classes, evidenciando congruência.

Na Figura 21, a situação de incongruência parcial na classificação dos corpos d'água poluídos reaparece. A Figura 21 exibe os resultados das classificações da imagem com as seis primeiras componentes. Nas regiões das duas primeiras linhas (Figuras 21a-f), o classificador não-contextual classificou os corpos d'água poluídos como “água” com menor intensidade (Figuras 21c e 21f), enquanto o classificador contextual identificou esses mesmos corpos como “não-água” (Figuras 21b e 21e), evidenciando incongruência parcial entre as Figuras 21b e 21c, e 21e e


Figura 17 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera as duas primeiras componentes (PC 1 – 2) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios.



Fonte: Elaborado pela autora.

21f. Na terceira região (Figuras 21g-i), o classificador não-contextual classificou o corpo d’água poluído como “água” com maior intensidade (Figura 21i), enquanto o classificador contextual o identificou como “não-água” (Figura 21h), reforçando a incongruência na classificação dos corpos d’água poluídos nessa área. Por outro lado, os corpos d’água não poluídos, indicados pelas setas


Figura 18 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera as três primeiras componentes (PC 1 – 2 – 3) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios.



Fonte: Elaborado pela autora.

azuis nas Figuras 21a, 21d e 21j, foram classificados como “água” por ambos os classificadores, conforme evidenciado nas Figuras 21b, 21c, 21e, 21f, 21k e 21l. Dessa forma, dependendo da região poluída analisada, encontrou-se incongruência parcial ou total para classificação dos corpos d’água poluídos, enquanto congruência foi observada para os corpos d’água não poluídos.


Figura 19 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera as quatro primeiras componentes (PC 1 – 2 – 3 – 4) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios.



Fonte: Elaborado pela autora.

Na Figura 22, que apresenta os resultados das classificações feitas considerando todas as componentes, observa-se que os corpos d’água afetados pelo desastre, indicados pelas setas vermelhas nas Figuras 22a, 22d e 22g, foram classificados como “não-água” por ambos os classificadores, indicando congruência para classificação dos corpos d’água poluídos. As regiões

Figura 20 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera as cinco primeiras componentes (PC 1 – 2 – 3 – 4 – 5) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d’água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d’água não afetados pelo desastre, portanto não poluídos com rejeito de minérios.




Fonte: Elaborado pela autora.

não afetadas, indicadas pelas setas azuis nas Figuras 22a, 22d e 22j, foram classificadas como “água” tanto pelo classificador contextual quanto pelo não-contextual, revelando congruência para classificações de corpos d’água poluídos e não poluídos.

Assim, ao analisar os resultados das classificações das oito imagens nas quatro regiões,


Figura 21 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera as seis primeiras componentes (PC 1 – 2 – 3 – 4 – 5 – 6) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d'água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d'água não afetados pelo desastre, portanto não poluídos com rejeito de minérios.



Fonte: Elaborado pela autora.

percebe-se que a classificação dos pixels correspondentes a corpos d'água depende do tipo de classificador (contextual ou não-contextual) e do espaço de características da imagem. A redução de dimensionalidade influenciou os classificadores, levando a classificações distintas das obtidas na imagem fusionada. No espaço de alta dimensionalidade (Figura 15), o classificador *Boost* foi

Figura 22 – Resultados da classificação contextual (*Boost*) e da não contextual (*Decision Tree*) obtidos com a imagem que considera todas as componentes (PC 1 – 2 – 3 – 4 – 5 – 6 – 7) em quatro regiões da área de estudo. As setas vermelhas, em (a, d, g), indicam corpos d'água que foram afetados pelo desastre ambiental, portanto poluídos, e as setas azuis, em (a, d, j), corpos d'água não afetados pelo desastre, portanto não poluídos com rejeito de minérios.



Fonte: Elaborado pela autora.

capaz de classificar tanto os corpos d'água poluídos quanto os não poluídos como “água”. Por outro lado, o classificador Árvore de Decisão identificou apenas os corpos d'água não poluídos como “água”, classificando os corpos d'água poluídos como “não-água”. No espaço transformado pelo PCA (imagem com todas as sete componentes), ambos os classificadores classificaram

como “água” apenas os corpos d’água não poluídos (Figura 22). As diferentes combinações de componentes do PCA (espaços transformados e reduzidos) geraram resultados distintos para os classificadores, como observado nas Figuras 16, 17, 18, 19, 20 e 21. A Tabela 14 apresenta um resumo dos resultados obtidos ao analisar os resultados das classificações das oito imagens.

Tabela 14 – Resumo da análise das classificações para as oito imagens.

Imagem	Corpos d’água poluídos	Corpos d’água não poluídos
Fusionada	Incongruência	Congruência
PC 1	Congruência	Congruência
PC 1-2	Incongruência parcial ou congruência	Congruência
PC 1-2-3	Incongruência parcial ou congruência	Congruência
PC 1-2-3-4	Incongruência*	Congruência
PC 1-2-3-4-5	Congruência	Congruência
PC 1-2-3-4-5-6	Incongruência parcial ou total	Congruência
PC 1-2-3-4-5-6-7	Congruência	Congruência

Fonte: Elaborado pela autora.

Independentemente do espaço analisado, para todas as oito imagens (a imagem fusionada e as sete combinações das componentes do PCA), tanto o classificador contextual (*Boost*) quanto o não-contextual (Árvore de Decisão ou *Decision Tree*) mostraram concordância ao classificar os corpos d’água não contaminados, evidenciando congruência nos resultados. Contudo, dependendo da imagem analisada, a concordância na classificação de corpos d’água poluídos esteve ausente ou presente, podendo ou não apresentar incongruências. A ocorrência de discordâncias entre as classificações evidencia a ocorrência de anomalias nos resultados de classificação do rio contaminado e, como observado, isso aconteceu apenas quando a imagem de alto espaço dimensional foi analisada (Figura 15). O único espaço de baixa dimensionalidade que apresentou resultados semelhantes foi aquele cujas quatro primeiras componentes foram consideradas (Figura 19).

6 DISCUSSÕES

Este estudo teve como objetivo investigar o impacto da técnica de redução de dimensionalidade *Principal Components Analysis* (PCA) na detecção de anomalias em imagens de sensoriamento remoto, com base na Taxonomia de Kittler. Os resultados obtidos indicaram que a aplicação da ADS-KT em imagens com espaço de atributos reduzido ou transformado não produziu resultados completamente semelhantes aos obtidos na imagem original (exceto em um caso específico). Tais achados sugerem que a técnica pode não ser recomendada a esse tipo de abordagem.

Com base nos resultados das classificações da imagem fusionada (mantendo o espaço de atributos original), isto é, os mesmos resultados obtidos por [Dias et al. \(2020\)](#), a divergência entre as duas classificações dos corpos d'água poluídos em cada região indicou a ocorrência de anomalias do tipo *Unexpected structure and structural components*, uma vez que as condições propostas por [Kittler et al. \(2014\)](#) para sua detecção foram satisfeitas. Tal divergência está evidenciada na Figura 15. Dessa forma, os classificadores, que foram modelados a partir de amostras de “água” e “não água” para aplicarem-se a um domínio específico, apresentaram divergências ao serem usados para classificar a imagem completa, que inclui corpos d'água afetados por mudanças estruturais e de componentes, devido a um desastre ambiental.

Ao aplicar, por sua vez, o método PCA e realizar diferentes combinações de componentes, apenas algumas características foram preservadas, gerando imagens com espaço de atributos reduzido ou transformado e valores estatísticos diferentes dos da imagem original. Como nem todas as características das amostras originais foram consideradas, os resultados das classificações indicaram outra categoria de anomalia (*Unexpected structural component*). Em outras palavras, a redução de dimensionalidade eliminou atributos referentes a características ou componentes estruturais da imagem original, o que resultou em uma modelagem insuficiente dos classificadores. Essa modelagem fraca levou ao surgimento de um componente estrutural inesperado: onde se esperava uma classificação de “água” por um dos classificadores, houve a classificação como “não água”. No entanto, não foram observadas divergências relevantes na classificação, conforme ilustrado nas Figuras 16, 17, 18, 20, 21 e 22.

Entretanto, uma exceção foi identificada. Como apresentado na Figura 19, ao considerar as

quatro primeiras componentes, observou-se incongruência nas classificações dos corpos d'água poluídos, semelhante ao que ocorreu na imagem fusionada (conforme [Dias et al. \(2020\)](#)). Em uma região específica, porém, a divergência entre as duas classificações ainda era evidente, mas o classificador contextual deixou de classificar a água poluída como “água”, e o classificador não contextual passou a classificar esse corpo d'água como “água”, assim como se vê na Figura 19h,i.

Em suma, observou-se que, no geral, nenhum dos espaços de atributos dimensionais resultantes permitiu atingir a mesma qualidade e nível de detecção de anomalia similarmente à forma obtida na imagem fusionada (conforme [Dias et al. \(2020\)](#)). Espera-se que o classificador que identifica corpos d'água poluídos como “não-água” continue a fazer isso para todas as ocorrências de água poluída, assim como aquele que classifica esses corpos d'água como “água”.

Todavia, uma semelhança ao resultado original pode ser alcançada ao usar uma combinação de componentes: as quatro primeiras. Essa similaridade ocorre porque, embora o comportamento descrito anteriormente tenha sido observado na maioria das regiões analisadas, houve uma região em que os classificadores inverteram seus comportamentos. Entretanto, a divergência – um indicativo de incongruência – permaneceu presente nessa situação.

Assim, essa exceção mostra que, caso não haja restrições de recursos computacionais para a detecção de anomalias, é recomendado o uso da estratégia sobre os dados sem redução de dimensionalidade, ou seja, empregando a imagem fusionada, já que ela apresenta divergência nas áreas afetadas pelo desastre ambiental sem qualquer variação nos resultados. Contudo, caso a análise envolva restrições computacionais, o uso de um espaço de características reduzido pode ser uma opção viável ao usar a combinação das quatro primeiras componentes. Nesse caso, é importante considerar as combinações a serem analisadas, de modo que os resultados obtidos sejam semelhantes, mesmo que haja alguma perda de detecção.

As matrizes de confusão e as métricas dos classificadores apresentadas nas Tabelas 6 a 13 mostraram que ambos os classificadores tiveram performances semelhantes durante a validação. Entretanto, diferentes comportamentos foram observados ao classificarem a imagem completa, como discutido anteriormente. Além disso, as visualizações geradas a partir das características extraídas da imagem fusionada e das componentes do PCA (Figuras 11 a 14) revelaram diferenças estruturais entre os dois espaços de atributos. Como observado, após a aplicação do PCA, a média e o desvio padrão dos valores de intensidade dos pixels delimitados pelas amostras sofreram alteração.

Em resumo, embora muitos estudos (FOWLER et al., 2009; GHOSH; PRAMANIK, 2019; BILIUS; PENTIUC, 2022; SELLAMI; FARAH, 2018; AVRAMOVIC; RISOJEVIC, 2011; JOURNAUX et al., 2006; GROBLER; KLEYNHANS; SALMON, 2019; NAVIN; AGILANDE-ESWARI; ANJANEYULU, 2020; YANG et al., 2019; ZHANG et al., 2016; GU; WANG, 2016; LIANG et al., 2018) tenham obtido resultados semelhantes em suas análises de dados, tanto no baixo quanto no alto espaço de atributos, este estudo introduz uma nova exceção: quando a detecção de anomalias baseada na Taxonomia de Kittler é aplicada em atividades de análise de imagens, o uso de um baixo espaço de atributos pode levar à ocorrência de um tipo de anomalia diferente daquele identificado no espaço de alta dimensão.

7 CONCLUSÃO

Este estudo investigou o impacto da técnica de redução de dimensionalidade *Principal Components Analysis* (PCA) e da ADS-KT, comparando os resultados obtidos pela aplicação da estratégia em diferentes espaços de atributos. Assim, conclui-se que a técnica afeta diretamente a aplicação da ADS-KT, usada por [Dias et al. \(2020\)](#), uma vez que a aplicação do método PCA gerou resultados diferentes daqueles originalmente apresentados por [Dias et al. \(2020\)](#), os quais também foram corretamente reproduzidos neste estudo. Esse fato evidencia que a taxonomia é bastante restritiva em relação ao conteúdo descrito pela teoria apresentada por [Kittler et al. \(2014\)](#). Em outras palavras, os limites entre os diferentes tipos de anomalias propostos pela Taxonomia de Kittler são bem definidos, de tal modo que nuances na aplicação da metodologia podem levar à extrapolação desses limites, resultando na identificação de um tipo de anomalia diferente daquele esperado.

Os resultados indicam que a redução da dimensionalidade, por um lado, dificulta a detecção de anomalias do tipo *Unexpected structure and structural components*, todavia, por outro lado, possibilita a detecção de anomalias do tipo *Unexpected structural component*, que foram inesperadas. Para conhecimento dos autores, este é o primeiro estudo a descrever a ocorrência de uma anomalia do tipo *Unexpected structural component* em Sensoriamento Remoto.

Uma limitação deste estudo é que não foram contabilizadas as anomalias identificadas em cada resultado da classificação das combinações de componentes, o que impede uma comparação numérica direta com os valores obtidos por [Dias et al. \(2020\)](#). Assim, como apresentado, foram analisados numericamente apenas os resultados individuais das classificações nas amostras coletadas, com o objetivo de comparar a performance dos classificadores sem considerar o contexto. Além disso, foi feita uma análise visual da divergência entre as duas classificações, ou seja, não foi feita uma avaliação manual que contabiliza a ocorrência de congruências e incongruências, como feito por [Dias et al. \(2020\)](#).

Dessa forma, sugere-se, como trabalho futuro, uma análise automática dos resultados completos das classificações das oito imagens (a imagem fusionada e as sete combinações das componentes do PCA), considerando o contexto no qual os pixels estão inseridos, i.e., se estão

em uma região afetada ou não pelo desastre natural. Dessa maneira, será possível mensurar de forma automática a porcentagem do impacto do uso de cada espaço de atributos no resultado final da detecção de anomalias.

Além disso, sugere-se também a investigação: do uso de outras técnicas de redução de dimensionalidade, já que este estudo usou apenas a técnica PCA; do uso da técnica de fusão de imagens na estratégia proposta por [Dias et al. \(2020\)](#); da remoção de algumas bandas na geração da imagem fusionada; do uso de outros classificadores (além do *Boost* e *Árvore de Decisão*) na estratégia.

Espera-se que os resultados e *outcomes* alcançados neste estudo também contribuam com outras pesquisas relacionadas ao aprendizado de máquina. Além disso, espera-se que este estudo incentive outros pesquisadores a investigarem a aplicação da detecção de anomalias baseada na Taxonomia de Kittler, não somente para o Sensoriamento Remoto, mas também em outras áreas do conhecimento.

REFERÊNCIAS

ADHAM, A.; SAYL, K. N.; ABED, R.; ABDELADHIM, M. A.; WESSELING, J. G.; RIKSEN, M.; FLESKENS, L.; KARIM, U.; RITSEMA, C. J. A gis-based approach for identifying potential sites for harvesting rainwater in the western desert of iraq. *International Soil and Water Conservation Research*, v. 6, n. 4, p. 297–304, 2018. ISSN 2095-6339. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S209563391830114X>>.

Agência Nacional de Águas e Saneamento Básico (ANA). *Encarte Especial sobre a Bacia do Rio Doce*. 2016. Disponível em: <https://www.snirh.gov.br/portal/centrais-de-conteudos/conjuntura-dos-recursos-hidricos/encarteriodoce_22_03_2016v2.pdf>. Acesso em: 05 de out. de 2024.

ANTON, H.; RORRES, C. *Álgebra Linear com Aplicações - 10.ed.* Bookman Editora, 2012. ISBN 9788540701700. Disponível em: <<https://books.google.com.br/books?id=WL4JBwAAQBAJ>>.

ASSAF, A. T.; SAYL, K. N.; ADHAM, A. Surface water detection method for water resources management. *Journal of Physics: Conference Series*, IOP Publishing, v. 1973, n. 1, p. 012149, aug 2021. Disponível em: <<https://dx.doi.org/10.1088/1742-6596/1973/1/012149>>.

AVRAMOVIC, A.; RISOJEVIC, V. Descriptor dimensionality reduction for aerial image classification. In: *2011 18th International Conference on Systems, Signals and Image Processing*. [s.n.], 2011. p. 1–4. Disponível em: <<https://ieeexplore.ieee.org/document/5977397>>.

BILIUS, L.-B.; PENTIUC, S. G. Tensor-based and projection-based methods for dimensionality reduction of hyperspectral images. In: *2022 International Conference on Development and Application Systems (DAS)*. [s.n.], 2022. p. 167–170. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/9786148>>.

BISHOP, C. M. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Berlin, Heidelberg: Springer-Verlag, 2006. ISBN 0387310738. Disponível em: <<https://link.springer.com/book/9780387310732>>.

COHEN, J. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, v. 20, n. 1, p. 37–46, 1960. Disponível em: <<https://doi.org/10.1177/001316446002000104>>.

CROSTA, A. *Processamento Digital de Imagens de Sensoriamento Remoto*. UNICAMP/Instituto de Geociências, 1999. ISBN 9788585369026. Disponível em: <<https://books.google.com.br/books?id=XBNQAAAACAAJ>>.

DIAS, M. A.; MARINHO, G. C.; NEGRI, R. G.; CASACA, W.; MUÑOZ, I. B.; ELER, D. M. A machine learning strategy based on kittler's taxonomy to detect anomalies and recognize contexts applied to monitor water bodies in environments. *Remote Sensing*, v. 14, n. 9, 2022. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/14/9/2222>>.

DIAS, M. A.; SILVA, E. A. d.; AZEVEDO, S. C. d.; CASACA, W.; STATELLA, T.; NEGRI, R. G. An incongruence-based anomaly detection strategy for analyzing water pollution in images from remote sensing. *Remote Sensing*, v. 12, n. 1, 2020. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/12/1/43>>.

DING, Y.; XIAO, J. Contextual boost for pedestrian detection. In: *2012 IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2012. p. 2895–2902.

FAWCETT, T. An introduction to roc analysis. *Pattern Recognition Letters*, v. 27, n. 8, p. 861–874, 2006. ISSN 0167-8655. ROC Analysis in Pattern Recognition. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S016786550500303X>>.

FOWLER, J. E.; DU, Q.; ZHU, W.; YOUNAN, N. H. Classification performance of random-projection-based dimensionality reduction of hyperspectral imagery. In: *2009 IEEE International Geoscience and Remote Sensing Symposium*. [s.n.], 2009. v. 5, p. V–76–V–79. Disponível em: <<https://ieeexplore.ieee.org/document/5417730>>.

GHOSH, S.; PRAMANIK, P. A combined framework for dimensionality reduction of hyperspectral images using feature selection and feature extraction. In: *2019 IEEE Recent Advances in Geoscience and Remote Sensing : Technologies, Standards and Applications (TENGARSS)*. [s.n.], 2019. p. 39–44. Disponível em: <<https://ieeexplore.ieee.org/document/8976039>>.

GONZALES, R. C.; WINTZ, P. *Digital Image Processing (2nd Ed.)*. USA: Addison-Wesley Longman Publishing Co., Inc., 1987. ISBN 0201110261. Disponível em: <<https://dl.acm.org/doi/10.5555/22881>>.

GROBLER, T.; KLEYNHANS, W.; SALMON, B. Empirically comparing two dimensionality reduction techniques – pca and fft: A settlement detection case study in the gauteng province of south africa. In: *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*. [s.n.], 2019. p. 3329–3332. Disponível em: <<https://ieeexplore.ieee.org/document/8898585>>.

GU, Y.; WANG, Q. Discriminative graph-based dimensionality reduction for hyperspectral image classification. In: *2016 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*. [s.n.], 2016. p. 1–5. Disponível em: <<https://ieeexplore.ieee.org/document/8071777>>.

JOURNAUX, L.; TIZON, X.; FOUCHEROT, I.; GOUTON, P. Dimensionality reduction techniques: An operational comparison on multispectral satellite images using unsupervised clustering. In: *Proceedings of the 7th Nordic Signal Processing Symposium - NORSIG 2006*. [s.n.], 2006. p. 242–245. Disponível em: <<https://ieeexplore.ieee.org/document/4052228>>.

KITTLER, J.; CHRISTMAS, W.; CAMPOS, T. de; WINDRIDGE, D.; YAN, F.; ILLINGWORTH, J.; OSMAN, M. Domain anomaly detection in machine perception: A system architecture and taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 36, n. 5, p. 845–859, 2014. Disponível em: <<https://ieeexplore.ieee.org/document/6636290>>.

KITTLER, J.; ZOR, C. A measure of surprise for incongruence detection. In: *2nd IET International Conference on Intelligent Signal Processing 2015 (ISP)*. [s.n.], 2015. p. 1–6. Disponível em: <<https://ieeexplore.ieee.org/document/7745770>>.

KITTLER, J.; ZOR, C. Delta divergence: A novel decision cognizant measure of classifier incongruence. *IEEE Transactions on Cybernetics*, v. 49, n. 6, p. 2331–2343, 2019. Disponível em: <<https://ieeexplore.ieee.org/document/8370682>>.

LIANG, L.; XIA, Y.; XUN, L.; YAN, Q.; ZHANG, D. Class-probability based semi-supervised dimensionality reduction for hyperspectral images. In: *2018 IEEE 9th International Conference*

on *Software Engineering and Service Science (ICSESS)*. [s.n.], 2018. p. 460–463. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/8663769>>.

MARCÍLIO-JR, W. E.; ELER, D. M. Explaining dimensionality reduction results using shapley values. *Expert Systems with Applications*, v. 178, p. 115020, 2021. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417421004619>>.

MARINHO, G. C.; JÚNIOR, W. E. M.; DIAS, M. A.; ELER, D. M.; NEGRI, R. G.; CASACA, W. Dimensionality reduction and anomaly detection based on kittler's taxonomy: Analyzing water bodies in two dimensional spaces. *Remote Sensing*, v. 15, n. 16, 2023. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/15/16/4085>>.

MENESES, P. R.; ALMEIDA, T. de; BAPTISTA, G. M. d. M. *Reflectância dos Materiais Terrestres: Análise e Interpretação*. São Paulo, Brasil: Oficina de Textos, 2019. ISBN 978-85-7975-301-5. Disponível em: <https://www.ofitexto.com.br/reflectancia-dos-materiais-terrestres/p?srsId=AfmBOoq-A-4E3JxRDGWEdsdjs8_gXMTXN2IOhp9SdMVEvuh2w53HLjLG>.

MHANGARA, P.; MAPURISA, W.; MUDAU, N. Comparison of image fusion techniques using satellite pour l'observation de la terre (spot) 6 satellite imagery. *Applied Sciences*, v. 10, p. 1881, 03 2020. Disponível em: <<https://www.mdpi.com/2076-3417/10/5/1881>>.

NAVIN, M. S.; AGILANDEESWARI, L.; ANJANEYULU, G. Dimensionality reduction and vegetation monitoring on liss iii satellite image using principal component analysis and normalized difference vegetation index. In: *2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE)*. [s.n.], 2020. p. 1–5. Disponível em: <<https://ieeexplore.ieee.org/document/9077875>>.

OpenCV Project. *Boosting - OpenCV documentation*. 2019. Disponível em: <<https://docs.opencv.org/2.4/modules/ml/doc/boosting.html>>. Acesso em: 16 de fev. de 2024.

OpenCV Project. *Decision Trees - OpenCV documentation*. 2019. Disponível em: <https://docs.opencv.org/2.4/modules/ml/doc/decision_trees.html>. Acesso em: 16 de fev. de 2024.

Orfeo Project. *Documentation for Orfeo ToolBox 6.4*. 2018. Disponível em: <<https://www.orfeo-toolbox.org/CookBook-6.4/>>. Acesso em: 16 de fev. de 2024.

Orfeo Project. *Documentation for Orfeo ToolBox 7.4*. 2022. Disponível em: <<https://www.orfeo-toolbox.org/CookBook-7.4/>>. Acesso em: 16 de fev. de 2024.

PONTI, M.; KITTLER, J.; RIVA, M.; CAMPOS, T. de; ZOR, C. A decision cognizant kullback-leibler divergence. *Pattern Recognition*, v. 61, p. 470–478, 2017. ISSN 0031-3203. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S003132031630231X>>.

QGIS Project. *Documentation for QGIS 2.18*. 2019. Disponível em: <<https://docs.qgis.org/2.18/en/docs/>>. Acesso em: 16 de fev. de 2024.

QGIS Project. *Documentation for QGIS 3.22*. 2023. Disponível em: <<https://docs.qgis.org/3.22/en/docs/>>. Acesso em: 16 de fev. de 2024.

REINHARD, E.; SHIRLEY, P.; ASHIKHMIN, M.; TROSCIANKO, T. Second order image statistics in computer graphics. In: *Proceedings of the 1st Symposium on Applied Perception in Graphics and Visualization*. New York, NY, USA: Association for

Computing Machinery, 2004. (APGV '04), p. 99–106. ISBN 1581139144. Disponível em: <<https://doi.org/10.1145/1012551.1012568>>.

RICHARDS, J. *Remote Sensing Digital Image Analysis: An Introduction*. Springer Berlin Heidelberg, 2012. ISBN 9783642300622. Disponível em: <<https://books.google.com.br/books?id=ETfwQnBMP4UC>>.

RICHARDS, J.; JIA, X. *Remote Sensing Digital Image Analysis*. Springer Berlin Heidelberg, 1999. ISBN 978-3-662-03980-9. Disponível em: <<https://link.springer.com/book/10.1007/978-3-662-03978-6>>.

SAMEER, Y. M.; ABED, A. N.; SAYL, K. N. Geomatics-based approach for highway route selection. *Applied Geomatics*, v. 15, n. 1, p. 161–176, Mar 2023. ISSN 1866-928X. Disponível em: <<https://doi.org/10.1007/s12518-023-00495-x>>.

SAYL, K. N.; MUHAMMAD, N. S.; YASEEN, Z. M.; EL-SHAFIE, A. Estimation the physical variables of rainwater harvesting system using integrated gis-based remote sensing approach. *Water Resources Management*, v. 30, n. 9, p. 3299–3313, Jul 2016. ISSN 1573-1650. Disponível em: <<https://doi.org/10.1007/s11269-016-1350-6>>.

SELLAMI, A.; FARAH, M. Comparative study of dimensionality reduction methods for remote sensing images interpretation. In: *2018 4th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP)*. [s.n.], 2018. p. 1–6. Disponível em: <<https://ieeexplore.ieee.org/document/8364490>>.

SHEN, J.; LI, J.; ZHANG, Y.; SONG, J. Farmers' water poverty measurement and analysis of endogenous drivers. *Water Resources Management*, Jul 2023. ISSN 1573-1650. Disponível em: <<https://doi.org/10.1007/s11269-023-03554-5>>.

SHEN, L.; LI, C. Water body extraction from landsat etm+ imagery using adaboost algorithm. In: *2010 18th International Conference on Geoinformatics*. [s.n.], 2010. p. 1–4. Disponível em: <<https://ieeexplore.ieee.org/document/5567762>>.

SULAIMAN, S. O.; KAMEL, A. H.; SAYL, K. N.; ALFADHEL, M. Y. Water resources management and sustainability over the western desert of iraq. *Environmental Earth Sciences*, v. 78, n. 16, p. 495, Aug 2019. ISSN 1866-6299. Disponível em: <<https://doi.org/10.1007/s12665-019-8510-y>>.

SWAIN, P. H.; HAUSKA, H. The decision tree classifier: Design and potential. *IEEE Transactions on Geoscience Electronics*, v. 15, n. 3, p. 142–147, 1977. Disponível em: <<https://ieeexplore.ieee.org/document/6498972>>.

TIOUIOUINE, A.; YAMEOGO, S.; VALLES, V.; BARBIERO, L.; DASSONVILLE, F.; MOULIN, M.; BOURAMTANE, T.; BAHAI, T.; MORARECH, M.; KACIMI, I. Dimension reduction and analysis of a 10-year physicochemical and biological water database applied to water resources intended for human consumption in the provence-alpes-côte d'azur region, france. *Water*, v. 12, n. 2, 2020. ISSN 2073-4441. Disponível em: <<https://www.mdpi.com/2073-4441/12/2/525>>.

United Nations Department of Economic and Social Affairs. *The Sustainable Development Goals Report 2022 - July 2022*. New York, USA: United Nations Publications, 2022. Disponível em: <<https://unstats.un.org/sdgs/report/2022/>>.

USGS. *USGS - The United States Geological Survey, "Earth Explorer"*. 2024. Disponível em: <<https://earthexplorer.usgs.gov/>>. Acesso em: 16 de fev. de 2024.

VIVONE, G.; ALPARONE, L.; CHANUSSOT, J.; MURA, M. D.; GARZELLI, A.; LICCIARDI, G. A.; RESTAINO, R.; WALD, L. A critical comparison among pansharpening algorithms. *IEEE Transactions on Geoscience and Remote Sensing*, v. 53, n. 5, p. 2565–2586, 2015. Disponível em: <<https://ieeexplore.ieee.org/document/6998089>>.

WANG, G.; LAURI, F.; HASSANI, A. H. E. A study of dimensionality reduction's influence on heart disease prediction. In: *2021 12th International Conference on Information, Intelligence, Systems Applications (IISA)*. [s.n.], 2021. p. 1–6. Disponível em: <<https://ieeexplore.ieee.org/document/9555550>>.

WEINSHALL, D.; ZWEIG, A.; HERMANSKY, H.; KOMBRINK, S.; OHL, F. W.; ANEMÜLLER, J.; BACH, J.-H.; GOOL, L. V.; NATER, F.; PAJDLA, T.; HAVLENA, M.; PAVEL, M. Beyond novelty detection: Incongruent events, when general and specific classifiers disagree. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 34, n. 10, p. 1886–1901, 2012. Disponível em: <<https://ieeexplore.ieee.org/document/6122029>>.

XU, Q.; LI, B.; ZHANG, Y.; DING, L. High-fidelity component substitution pansharpening by the fitting of substitution data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 52, n. 11, p. 7380–7392, 2014. Disponível em: <<https://ieeexplore.ieee.org/document/6784416>>.

YANG, X.; XU, W.-d.; LIU, H.; ZHU, L.-y. Research on dimensionality reduction of hyperspectral image under close range. In: *2019 International Conference on Communications, Information System and Computer Engineering (CISCE)*. [s.n.], 2019. p. 171–174. Disponível em: <<https://ieeexplore.ieee.org/document/8805928>>.

YI-BIN, L.; YING-YING, W.; XUE-WEN, R. Improvement of id3 algorithm based on simplified information entropy and coordination degree. In: *2017 Chinese Automation Congress (CAC)*. [s.n.], 2017. p. 1526–1530. Disponível em: <<https://ieeexplore.ieee.org/document/8243009>>.

ZHANG, X.; HUYAN, N.; ZHOU, N.; AN, J. Semi-supervised sparse dimensionality reduction for hyperspectral image classification. In: *2016 IEEE Region 10 Conference (TENCON)*. [s.n.], 2016. p. 2830–2833. Disponível em: <<https://ieeexplore.ieee.org/document/7848559>>.

APÊNDICE A – Parâmetros dos processamentos

A.1 Pré-processamento

Nas etapas de pré-processamento, foram usados o software *QGis* ([QGis Project, 2019](#)), versão 2.18.19 - Las Palmas, e a *toolbox Orfeo* ([Orfeo Project, 2018](#)), versão 6.4.0.

A partir das sete bandas da imagem do satélite *Landsat 8* importadas no *QGis* como *raster layers* na ordem da banda 7 a 1, a ferramenta *Build Virtual Raster (Catalog)* (encontrada no menu *Raster* e opção *Miscellaneous*) foi usada. Foram escolhidos os *raster layers* visíveis (as sete bandas selecionadas) como entrada e a opção *Separate* foi marcada para que cada *raster* de origem fosse armazenado em uma banda no *raster* de saída (virtual).

No que se refere às configurações de renderização de *raster* usadas neste estudo, podem ser definidas na opção *Properties* do menu de *click* do botão direito sobre o respectivo *raster* a ser configurado. Nessa opção, ao selecionar o menu *Style*, a *Banda 4* foi definida como *Red band*, a *Banda 3* como *Green band* e a *Banda 2* como *Blue band*. Além disso, as opções *Mean +/- standard deviation x* (o valor 2,00 foi definido) e *Clip extent to canvas* foram selecionadas e aplicadas.

Para realizar o *pan-sharpening*, a *toolbox Orfeo* foi usada. Na seção *Geometry*, a opção *Superimpose sensor* é a responsável por realizar a projeção. Nessa etapa, a entrada de referência foi definida como o *raster* da banda 8 (imagem pancromática), já a imagem a ser projetada, como o *raster virtual* criado anteriormente (imagem multi-espectral). Os valores padrões foram mantidos, ou seja, 0 para *Default elevation*, 4 para *Spacing of the deformation field, default Mode* e *Interpolation* do tipo *Nearest Neighbor - NN*.

Em seguida, a fusão é realizada pela opção *Pansharpening (rcs)* da *toolbox*. Nessa etapa, a imagem pancromática e o resultado do *Superimpose sensor* foram selecionados como entradas para gerar a imagem resultante do pré-processamento.

Para os passos descritos nas subseções a seguir, o software *QGis* ([QGis Project, 2023](#)), versão 3.22.12 - Białowieża, e a *toolbox Orfeo* ([Orfeo Project, 2022](#)), versão 7.4.0, foram usados.

A.2 Redução de dimensionalidade

A redução de dimensionalidade foi realizada pela opção *DimensionalityReduction* da seção *Image Filtering* da *toolbox Orfeo*. Essa etapa recebeu como entrada a imagem resultante do pré-processamento e usou os seguintes parâmetros.

- *Rescale Output*: no;
- *Algorithm*: *pca*;
- Opção *Perform pca whitening*: marcada (*True*);
- Number of Components: 0, indicando que todas as componentes serão mantidas;
- Opção *Center and reduce data*: desmarcada (*False*).

A.3 Classificação

As estatísticas de segunda ordem, usadas na classificação, foram computadas pela opção *ComputeImageStatistics* da seção *Learning* da *toolbox Orfeo*. Essa etapa foi executada para a imagem resultante do pré-processamento e, posteriormente, para a imagem resultante do PCA, uma vez que foram realizadas classificações nas duas imagens, tornando-se necessário saber os valores estatísticos de ambas.

Para o treinamento dos dois classificadores (*Boost* e *Decision Tree*) sobre as duas imagens, a opção *TrainImagesClassifier* da *toolbox Orfeo* foi usada. Essa etapa recebeu como entrada a respectiva imagem (resultado do pré-processamento ou PCA), o arquivo das amostras coletadas na amostragem e o respectivo arquivo de estatísticas da imagem. A maioria dos valores padrões foram mantidos.

- *Maximum training sample size per class*: 1000;
- *Maximum validation sample size per class*: 1000;
- *Bound sample number by minimum*: 1;
- *Training and validation sample ratio*: 0.5;

- *Name of the discrimination field* - o nome do campo do que contém as classes no arquivo das amostras coletadas, um *shapefile*): *Class*;
- *Default elevation*: 0;
- *Random seed*: 0.

De acordo com o classificador, outros parâmetros padrões foram usados. No caso do *Boost*:

- *Boost type*: *real*;
- *Weak count*: 100;
- *Weight Trim Rate*: 0.95;
- *Maximum depth of the tree*: 1.

Já para o *Decision Tree*:

- *Maximum depth of the tree*: 65535;
- *Minimum number of samples in each node*: 10;
- *Termination criteria for regression tree*: 0.01;
- *Cluster possible values of a categorical variable into $K \leq \text{cat}$ clusters to find a suboptimal split*: 10;
- Opção *Set UseIseRule flag to false*: marcada (*True*);
- Opção *Set TruncatePrunedTree flag to false*: marcada (*True*).

Ao final dessa etapa, a matriz de confusão e o modelo são gerados para cada classificador, associado a cada imagem.

A classificação foi realizada pela opção *ImageClassifier*, também da *toolbox Orfeo*, que recebeu como entrada a respectiva imagem (resultado do pré-processamento ou PCA), o respectivo modelo criado anteriormente para os dois classificadores (*Boost* ou *Decision Tree*) e o arquivo de estatística da imagem, resultando nas classificações. Os valores padrões dessa versão foram mantidos.

A.4 Extração de características

Para a extração das características, a ferramenta *Zonal Statistics* disponível na seção *Raster Analysis*, da *Processing Toolbox* no *QGIS*, foi usada. Dessa forma, para cada banda ou para cada componente da imagem, a ferramenta foi executada para calcular as seguintes estatísticas: média, mediana, desvio padrão, mínimo, máximo e variância. A camada criada na etapa de amostragem também foi usada, para informar as regiões da imagem em que esses valores fossem computados. Assim, para cada banda ou componente, considerando os polígonos (as amostras), foram calculadas as seis estatísticas.

O arquivo final dessa etapa foi usado para gerar as visualizações desenvolvidas a partir da linguagem *Python*, dentro do ambiente de desenvolvimento *Colaboratory - Google*.

DADOS CURRICULARES

IDENTIFICAÇÃO			
Nome completo	Giovanna Carreira Marinho	Data de nascimento	21/05/2000
Filiação	Jane Andréa Carreira Marinho Cícero Marinho Silva	Nome em citações bibliográficas	Marinho, Giovanna Carreira Marinho, G. C.
Naturalidade	Presidente Prudente, São Paulo	Currículo Lattes	3261077745815886
Nacionalidade	Brasileira	ORCID	0000-0002-4074-2733
FORMAÇÃO ACADÊMICA			
2018 - 2022	Graduação em Ciência da Computação. Universidade Estadual Paulista (UNESP), câmpus de Presidente Prudente.		
2022 - 2024	Mestrado em Ciência da Computação. Universidade Estadual Paulista (UNESP), câmpus de Presidente Prudente.		
PRODUÇÃO BIBLIOGRÁFICA			
Artigos publicados em revistas científicas			
DIAS, MAURÍCIO ARAÚJO; MARINHO, GIOVANNA CARREIRA; NEGRI, ROGÉRIO GALANTE; CASACA, WALLACE; MUÑOZ, IGNÁCIO BRAVO; ELER, DANILO MEDEIROS. <i>A Machine Learning Strategy Based on Kittler's Taxonomy to Detect Anomalies and Recognize Contexts Applied to Monitor Water Bodies in Environments</i> . Remote Sensing, v. 14, p. 2222, 2022. DOI: 10.3390/rs14092222 .			
MARINHO, GIOVANNA CARREIRA; JÚNIOR, WILSON ESTÉCIO MARCÍLIO; DIAS, MAURICIO ARAUJO; ELER, DANILO MEDEIROS; NEGRI, ROGÉRIO GALANTE; CASACA, WALLACE. <i>Dimensionality Reduction and Anomaly Detection Based on Kittler's Taxonomy: Analyzing Water Bodies in Two Dimensional Spaces</i> . Remote Sensing, v. 15, p. 4085, 2023. DOI: 10.3390/rs15164085 .			
MARINHO, GIOVANNA CARREIRA; JÚNIOR, WILSON ESTÉCIO MARCÍLIO; DIAS, MAURICIO ARAUJO; ELER, DANILO MEDEIROS; ARTERO, ALMIR OLIVETTE; CASACA, WALLACE; NEGRI, ROGÉRIO GALANTE. <i>Associating Anomaly Detection Strategy Based on Kittler's Taxonomy with Image Editing to Extend the Mapping of Polluted Water Bodies</i> . Remote Sensing, v. 15, p. 5760, 2023. DOI: 10.3390/rs15245760 .			
Projetos de pesquisa			
2019 - 2019	Projeto de Iniciação Científica: <i>UTILIZAÇÃO DE TÉCNICAS DE MORFOLOGIA MATEMÁTICA E PROCESSAMENTO DIGITAL NA EXTRAÇÃO DE FEIÇÕES CARTOGRÁFICAS EM IMAGENS DIGITAIS: USO DO MATLAB E TOOLBOXES</i> . Financiamento: CNPq (PIBIC).		
2019 - 2020	Projeto de Iniciação Científica: <i>INTERFACEAMENTO DE ROTINAS MORFOLÓGICAS PARA EXTRAÇÃO DE FEIÇÕES CARTOGRÁFICAS E DE RECONSTRUÇÃO DE FEIÇÕES PARCIALMENTE DETECTADAS EM IMAGENS DIGITAIS JUNTO AO CARTOMORPH</i> . Financiamento: CNPq (PIBITI).		
2020 - 2021	Projeto de Iniciação Científica: <i>Análise de Séries Temporais de Imagens de Sensoriamento Remoto para a Detecção de Anomalias</i> . Financiamento: FAPESP (processo #2020/06477-7).		
PARTICIPAÇÃO EM EVENTOS CIENTÍFICOS			
XXXI Congresso de Iniciação Científica da Unesp (primeira fase). <i>Desenvolvimento de rotina morfológica para detecção de áreas de queimadas em imagens de satélite</i> . 2019.			
XXXII Congresso de Iniciação Científica da Unesp (primeira e segunda fases). <i>Interfaceamento de rotina morfológica para extração de queimadas em imagens digitais junto ao CARTOMORPH</i> . 2020.			