

Universidade de Lisboa
Instituto de Geografia e Ordenamento do Território



**Metodologias de avaliação e caracterização das condições fluviais
com recurso a veículos aéreos não tripulados**

Pedro Costa Nascimento

Mestrado em Geografia Física e Ordenamento do Território

Relatório de Estágio orientado pelo Doutor Eusébio Joaquim Marques dos Reis

2024

Universidade de Lisboa
Instituto de Geografia e Ordenamento do Território



**Metodologias de avaliação e caracterização das condições fluviais com
recurso a veículos aéreos não tripulados**

Pedro Costa Nascimento

Mestrado em Geografia Física e Ordenamento do Território

Relatório de Estágio orientado pelo Doutor Eusébio Joaquim Marques dos Reis

Júri:

Presidente: Doutor Gonçalo Brito Guapo Teles Vieira, Professor Associado com Agregação do Instituto de Geografia e Ordenamento do Território da Universidade de Lisboa

Vogais:

- Doutor Pedro Miguel Berardo Duarte Pina, Professor Associado com Agregação da Faculdade de Ciências e Tecnologia da Universidade de Coimbra
- Doutora Cláudia Morais Viana, Investigadora Júnior do Instituto de Geografia e Ordenamento do Território da Universidade de Lisboa

Declaração de Autoria

Eu Pedro Costa Nascimento, declaro que o presente relatório de estágio de mestrado intitulado/a *Metodologias de avaliação e caracterização das condições fluviais com recurso a veículos aéreos não tripulados*, é o resultado da minha investigação pessoal e independente. O conteúdo é original e todas as fontes consultadas estão devidamente mencionadas na bibliografia ou outras listagens de fontes documentais, tal como todas as citações diretas ou indiretas têm devida indicação ao longo do trabalho segundo as normas académicas.

Resumo

A caracterização das condições fluviais providencia elementos que integram as avaliações de eficácia dos Regimes de Caudais Ecológicos em aproveitamentos hidroelétricos, concebidas para minimizar os impactes da alteração do regime hidrológico a jusante de barragens. Esta caracterização pode ser melhorada através da utilização de Veículos Aéreos não Tripulados (VAnT): reduzindo alguma subjetividade na recolha de elementos no terreno, imposta por limitações de segurança e de acessibilidade em alguns troços fluviais; efetuando análises temporais das alterações ocorridas; cartografando os diversos elementos fluviais através da criação de mapas. Os objetivos centram-se no desenvolvimento de um conjunto de procedimentos metodológicos automáticos e semiautomáticos, de modo a caracterizar as alterações nos troços fluviais a jusante de barragens, sendo, progressivamente, aplicados a diferentes troços em contextos diversificados, e introduzidos nas caracterizações fluviais tradicionais. Assim, foram elaboradas diversas tarefas: compilação de metodologias para caracterizar as condições fluviais; elaboração de mapas, utilizando ferramentas e *softwares* de Sistemas de Informação Geográfica (SIG), provenientes de ortofotos, vídeos e imagens LiDAR, obtidos na área de estudo; utilização dos dados obtidos por VAnT para analisar as características hidrogeomorfológicas e fitogeográficas com o pós-processamento das imagens nos SIG. Os métodos e técnicas utilizados foram a obtenção de imagens de alta definição através de VAnT e o seu processamento no *software* Pix4D. Foram também utilizadas ferramentas em *softwares* de SIG para classificar os ortomosaicos, através de classificações semiautomáticas com algoritmos no ArcGIS Pro. Verificam-se alguns problemas nos resultados obtidos nas classificações, devido às diversas orientações das vertentes do vale e, conseqüentemente, aos contrastes na incidência da radiação solar. Apesar disso, identificou-se a classificação supervisionada do ArcGIS Pro com o algoritmo *Support Vector Machine* e os atributos de segmentação *Active chromaticity color* e *Mean digital number*, como o método mais eficaz para caracterizar e classificar semiautomaticamente as condições fluviais neste tipo de relevo.

Palavras-Chave:

Veículo Aéreo Não Tripulado; Classificação semiautomática; Condições Fluviais; Caudal Ecológico; Troço fluvial

Abstract

The characterization of river conditions provides elements that are part of the effectiveness assessments of Environmental Flow Regimes in hydroelectric dams, that aims at minimizing the impacts of altering the hydrological regime of dams downstream. This characterization can be improved using Unmanned Aerial Vehicles (UAVs): reducing some subjectivity in field data collection, imposed by safety and accessibility limitations on some river stretches; allowing temporal analysis of the changes occurred in river sections, as well as a more rigorous characterization by mapping various river elements. The objectives are focused on developing a set of automatic and semi-automatic methodological procedures to characterize changes in river sections downstream of dams, which can be progressively applied to different sections in diverse contexts and introduced into traditional river characterizations. Therefore, several tasks were developed: compilation of methodologies to characterize river conditions; creation of maps, using Geographic Information Systems (GIS) tools, derived from orthophotos, videos and LiDAR images, obtained in the study area; use of the data to analyze the hydrogeomorphological and phytogeographical characteristics with the post-processing of the images in GIS. The methods and techniques applied in this project consisted of the utilization of high-resolution images using UAVs, that were processed in Pix4D software to create orthomosaics and Digital Surface Models. Additionally, GIS software tools were used to classify the orthomosaics through semi-automatic classifications with algorithms in ArcGIS Pro. The analysis revealed some problems with the results obtained from this classification, due to the different valley slopes orientation which leads to a high variability of solar radiation incidence. Despite this, it was determined that the supervised classification of ArcGIS Pro, using the Support Vector Machine algorithm, the Active Chromaticity Color and Mean Digital Number segmentation attributes are the most effective methods for semi-automatically characterizing and classifying river conditions in this type of terrain.

Key-Words:

Unmanned Aerial Vehicles; Semi-automatic Classification; River Conditions; Environmental Flow; River Stretch

Agradecimentos

Primeiramente, quero agradecer e dedicar este trabalho aos meus pais e à minha irmã. São o meu pilar e exemplo de vida. O meu eterno obrigado pelo amor e apoio incondicional.

Ao meu orientador, Professor Eusébio Reis, o meu profundo agradecimento por todos os ensinamentos e pelo auxílio durante estes dois anos. A sua orientação foi fundamental para a realização deste trabalho.

Ao Professor Gonçalo Vieira, pela partilha de conhecimento e pela ajuda na resolução de problemas.

Ao Pedro Freitas, pelo papel fundamental na elaboração dos resultados deste trabalho. O meu muito obrigado por todo o apoio e mentoria. Sem ti, o resultado do trabalho não teria sido o mesmo.

Obrigado a toda a minha família pelo apoio, em especial ao meu avô. Estejas onde estiveres, tenho a certeza de que a conclusão desta etapa te deixará orgulhoso.

Obrigado a todos os meus amigos que acompanharam e tornaram este percurso ainda mais especial. Ao Diogo e ao Afonso, obrigado por estes cinco anos. A faculdade não teria sido a mesma sem vocês.

À Margarida, por todo o amor, apoio e motivação. Sem ti, tudo seria mais difícil.

Por fim, quero agradecer à EDP Labelec e a todos os envolvidos neste projeto, nomeadamente ao João Pádua, ao Sílvio Romão e ao Ricardo Branca. Ao Ricardo, um agradecimento especial pela oportunidade e por todo o apoio, compreensão e confiança depositadas em mim. O meu sincero obrigado.

Índice

Resumo	iv
Abstract	v
Agradecimentos	vi
Índice	vii
Índice de Figuras	ix
Índice de Quadros	xi
1. Introdução	12
1.1 Enquadramento institucional	12
1.2 Objetivos	12
1.3 Estrutura do Relatório	13
2. Enquadramento concetual e estado da arte	14
2.1 Caudais ecológicos: implementação e avaliação de eficácia	14
2.2 Caracterização das condições fluviais: o papel dos VAnT e respetivos métodos e técnicas.....	16
3. Área de Estudo	19
3.1 Localização.....	19
3.2 Enquadramento climático regional	20
3.3 Caracterização geomorfológica	21
3.4 Caracterização hidrográfica	26
3.4.1 Sistema Cávado – Rabagão – Homem	27
3.4.2 Aproveitamento Hidroelétrico de Salamonde.....	28
3.4.2.1 Barragem e Albufeira.....	28
3.4.2.2 Bacia Hidrográfica do AH de Salamonde.....	30
3.5 Caracterização do troço fluvial	31
4. Métodos e Dados	38
4.1 Metodologia	38
4.2 Características dos voos com VAnT	39
4.3 Processamento de imagens no Pix4Dmapper.....	41
4.4 Técnicas de classificação semiautomática de imagens VAnT	43
4.4.1 <i>Image Classification Wizard</i>	45
4.4.2 Algoritmos de Classificação	48

4.4.3 Processos de validação	50
5. Resultados	53
5.1 Classificações <i>Pixel-based</i>	53
5.2 Classificações <i>Object-based</i>	58
5.3 Melhor classificação <i>Pixel-based</i> e <i>Object-based</i>	64
5.4 Variação temporal e espacial do nível da água do troço fluvial.....	68
6. Conclusão	70
Bibliografia	74

Índice de Figuras

Figura 1 - Enquadramento geográfico da área de estudo do projeto.	19
Figura 2 - Regime termopluiométrico de Montalegre (1981-2010).	20
Figura 3 - Distribuição espacial da altitude (m) da região da área de estudo.	22
Figura 4 - Distribuição espacial do declive (°) da região da área de estudo.	23
Figura 5 - Distribuição espacial da exposição de vertentes da região da área de estudo.	24
Figura 6 - Extrato da folha 06-A da Carta Geológica de Portugal, na escala 1/50000, da região em análise (extraído de Profico Ambiente, 2010, pag. 86).	25
Figura 7 - Localização das barragens construídas na bacia hidrográfica do rio Cávado (extraído de Ferreira, 2018, pag. 10).	26
Figura 8 - Esquema simplificado do Sistema Cávado – Rabagão – Homem (extraído de Profico Ambiente, 2010, pag. 125).	27
Figura 9 - Aproveitamento Hidroelétrico de Salamonde.	28
Figura 10 - Barragem de Salamonde.	28
Figura 11 - Bacia de Drenagem do AH de Salamonde.	31
Figura 12 - Enquadramento geográfico do troço fluvial em estudo. Localização dos perfis transversais elaborados.	32
Figura 13 - Altitude (m) do troço fluvial em estudo.	33
Figura 14 - Declives (°) do troço fluvial em estudo.	34
Figura 15 - Exposição de vertentes do troço fluvial em estudo.	34
Figura 16 - Altitude, declives e exposição de vertentes do leito fluvial.	35
Figura 17 - Perfis transversais em três setores do troço fluvial.	36
Figura 18 - Fluxo metodológico das várias componentes do trabalho.	38
Figura 19 - VAnT utilizados na recolha de dados.	40
Figura 20 - Resultados do processamento da primeira e segunda fase no Pix4Dmapper, das imagens dos levantamentos de fevereiro (A) e julho (B).	42
Figura 21 - Ortomosaico inicial (A) e ortomosaico cingido ao leito do rio (B).	43
Figura 22 - Distribuição das áreas de treino e das áreas de validação no troço em estudo.	45
Figura 23 - Estrutura da ferramenta <i>Classification Wizard</i> do ArcGIS Pro.	46
Figura 24 - Processo de segmentação no ArcGIS Pro.	48

Figura 25 - Localização dos setores utilizados para a análise visual das classificações <i>Pixel-based</i>	54
Figura 26 - Setores em detalhe dos quatro algoritmos de classificação <i>Pixel-based</i>	56
Figura 27 - Setores em detalhe dos quatro melhores algoritmos e atributos da segmentação das classificações <i>Object-based</i>	59
Figura 28 - Setores em detalhe da melhor classificação <i>Pixel-based</i> e <i>Object-based</i>	64
Figura 29 - Exemplos de elementos mal classificados.	65
Figura 30 - Localização dos setores (1 a 6) utilizados para o cálculo da variação do nível da água entre fevereiro e julho; as imagens de baixo mostram a situação no setor 6, em fevereiro (A) e julho (B).	68

Índice de Quadros

Quadro 1 - Valores (m ³ /s) do Regime de Caudais Ecológicos (RCE) em vigor na barragem de Salamonde a partir de 1 de novembro de 2016.....	29
Quadro 2 - Volumes afluentes mensais e anual na estação hidrométrica de Salamonde (dam ³).....	30
Quadro 3 - Área (m ²) e número de pixels das áreas de treino e das áreas de validação.	44
Quadro 4 - Atributos utilizados em classificações <i>Pixel-based</i> e <i>Object-based</i>	47
Quadro 5 - Interpretação dos valores do Coeficiente de Kappa (Extraído de Crisógono, 2011, pag. 43).	52
Quadro 6 - Exatidão Global e Coeficiente Kappa das classificações <i>Pixel-based</i>	57
Quadro 7 - Valores de Exatidão do Produtor (EP) e Exatidão do Utilizador (EU) das classificações <i>Pixel-based</i>	57
Quadro 8 - Designações dos algoritmos de classificação e atributos da segmentação utilizados.....	58
Quadro 9 - Valores de exatidão do produtor (EP) das classificações <i>Object-based</i>	61
Quadro 10 - Valores de exatidão do utilizador (EU) das classificações <i>Object-based</i> ...	62
Quadro 11 - Coeficiente Kappa e exatidão global das classificações <i>Object-based</i>	63
Quadro 12 - Valores de exatidão do produtor (EP) e exatidão do utilizador (EU) das melhores classificações <i>Pixel-based</i> e <i>Object-based</i>	66
Quadro 13 - Coeficiente de Kappa e exatidão global das melhores classificações <i>Pixel-based</i> e <i>Object-based</i>	67
Quadro 14 - Resumo dos valores e parâmetros da melhor classificação semiautomática.	72

1. Introdução

1.1 Enquadramento institucional

O presente relatório de estágio resulta de um projeto desenvolvido em conjunto entre a EDP Labelec Estudos, Desenvolvimento e Atividades Laboratoriais, S.A., e o Instituto de Geografia e Ordenamento do Território da Universidade de Lisboa. Este trabalho realizou-se no contexto do Mestrado em Geografia Física e Ordenamento do Território, e foi desenvolvido na Área de Ambiente da EDP Labelec, durante 8 meses, de novembro de 2022 a julho de 2023.

A EDP Labelec – Estudos, Desenvolvimento e Atividades Laboratoriais, S.A., foi criada em agosto de 1994, e é o Centro de Excelência Técnica para toda a cadeia de valor da energia elétrica do Grupo EDP. A Labelec integra quatro áreas de negócio, nomeadamente, Testes & Ensaios, Ambiente, Qualificação & Inspeções, Consultoria Energética e três áreas de suporte, Apoio à Gestão, Desenvolvimento de Negócio, Projeto de Qualidade, Ambiente e Segurança & Melhoria Contínua (Ramos, 2020). A Área de Ambiente da EDP Labelec, onde foram desenvolvidas as atividades deste relatório de estágio, efetua atividades nas áreas do Ambiente, da Química e da Biologia, e fornece serviços como: controlo de qualidade da água destinada ao consumo humano; avaliação da qualidade ecológica de rios e albufeiras; monitorização da qualidade físico-química, biológica e hidromorfológica de rios; avaliação da eficácia de regimes de caudais ecológicos; recolha e análise de macroinvertebrados bentónicos de água doce e fauna piscícola; análises químicas em sedimentos e lamas, incluindo matéria seca, matéria orgânica, granulometria e metais pesados, entre outros.

Para a execução deste trabalho, foram disponibilizados pela EDP Labelec dois Veículos Aéreos não Tripulados (VAnT) para a realização dos levantamentos no troço fluvial em estudo, o DJI Mavic 2 Pro e o DJI Matrice 300 RTK, incorporado com um sensor LiDAR (*Light Detection And Ranging*) de alta precisão.

1.2 Objetivos

Este trabalho tem como objetivo desenvolver procedimentos metodológicos automáticos e semiautomáticos, que permitam identificar e caracterizar alterações nos

troços fluviais a jusante de barragens, que possam, progressivamente, ser aplicados a diferentes troços em contextos diversificados. Para a realização deste objetivo, são efetuadas várias tarefas e procedimentos como: i) a caracterização da geomorfologia do troço fluvial do rio Cávado, entre as albufeiras de Salamonde e da Caniçada; ii) compilação de metodologias e algoritmos para análise e caracterização de condições fluviais (caracterização da metodologia mais eficaz no estudo das condições fluviais com recurso a VAnT em troços como o estudado e comparação com outros métodos); iii) elaboração de mapas, utilizando ferramentas e *software* SIG, provenientes de ortofotos, vídeos e imagens LiDAR, obtidos em dois levantamentos (fevereiro e julho) na área de estudo; iv) utilização dos dados obtidos nas duas recolhas no terreno, para comparar e analisar as características hidrogeomorfológicas e fitogeográficas com o pós-processamento das imagens nos SIG, em condições de Regimes de Caudais Ecológicos diferentes.

1.3 Estrutura do Relatório

No presente relatório de estágio, o estudo das metodologias de avaliação e caracterização das condições fluviais a jusante de barragens com recurso a VAnT, é realizado ao longo de seis capítulos. No presente capítulo é efetuado o enquadramento institucional da empresa onde foi realizado o estágio e a contextualização do projeto e dos objetivos do trabalho. No segundo capítulo, é feita uma revisão bibliográfica dos conhecimentos e estudos sobre caudais ecológicos, processos e métodos utilizados para caracterizar a hidrogeomorfologia dos sistemas fluviais, e da influência dos VAnT e dos SIG na análise e caracterização de condições fluviais. No terceiro e quarto capítulos, é feita a caracterização da área de estudo e são descritos os processos, técnicas, ferramentas e *softwares*, utilizados neste trabalho. No quinto capítulo, são apresentados os resultados deste trabalho, nomeadamente as classificações semiautomáticas e outros *outputs* derivados dos dados obtidos pelos levantamentos. Por fim, no sexto capítulo, são apresentadas as conclusões obtidas com a realização deste trabalho, algumas indicações resultantes desta aprendizagem e identificação de próximos passos que possam ser tidos em consideração em futuros trabalhos e projetos.

2. Enquadramento concetual e estado da arte

Nas décadas anteriores, a consciencialização e consolidação da importância associada à preservação ambiental e ao desenvolvimento sustentável, tem alertado cada vez mais para a problemática da degradação dos ecossistemas fluviais, consequente das modificações verificadas a jusante de barragens (Ferreira et al., 2010).

Um dos principais problemas associados à construção de barragens, resulta da alteração dos caudais naturais imposta nos segmentos lóticos situados a jusante destas infraestruturas (troços fortemente modificados), com consequências nos habitats fluviais, nas comunidades biológicas e no funcionamento ecológico dos ecossistemas aquáticos (Godinho et al., 2014).

2.1 Caudais ecológicos: implementação e avaliação de eficácia

A fixação de caudais ecológicos surge como uma das principais ações para mitigar os impactos ambientais resultantes da construção de barragens. O caudal ecológico pode ser definido como o volume de água mínimo capaz de satisfazer e assegurar as necessidades de conservação e manutenção dos ecossistemas aquáticos e ribeirinhos, assim como aspetos estéticos da paisagem e de interesse científico e cultural (Ferreira et al., 2010). Os caudais ecológicos têm impactos significativos na salubridade do rio, no desenvolvimento económico e na diminuição da pobreza, e permitem assegurar a contínua disponibilidade da maior parte dos benefícios que os rios saudáveis e sistemas subterrâneos de água proporcionam à sociedade (Dyson et al., 2007).

Neste sentido, a implementação de caudais ecológicos em Portugal tem sido assegurada por alguns documentos legais como a Lei da Água, que estabelece cinco Administrações de Região Hidrográfica (ARH) – Norte, Centro, Tejo e Oeste, Alentejo e Algarve, como principais unidades de planeamento e gestão das águas (Schmidt, 2013), e transpõe para a legislação nacional a Diretiva - Quadro da Água (DQA) (Diretiva 2000/60/CE do Parlamento Europeu e do Conselho, de 23 de outubro de 2000). Esta Diretiva estabelece ações comunitárias no domínio da política da água, através da integração e adaptação dos Estados Membros da União Europeia aos princípios gerais de proteção e uso sustentável das águas da Comunidade (Alves et al., 2002), isto é, exige que os estados europeus avaliem e classifiquem o estado ecológico dos rios (Stanca et al.,

2023). Estas leis e medidas são reflexo da nova atitude e preocupação, na implementação e manutenção de caudais ecológicos a jusante dos aproveitamentos hidráulicos (AH).

No seu conjunto, os caudais ecológicos correspondem a séries de valores de caudal aplicáveis em diferentes períodos, designados como regimes de caudais ecológicos (RCE). Estes são variáveis ao longo do ano e têm o objetivo de assegurar a conservação e a manutenção dos ecossistemas aquáticos, a produção de espécies, assim como a conservação e manutenção dos ecossistemas ripícolas e outros valores que lhes estão associados (APA, 2018a).

Para avaliar a eficácia de um determinado RCE, é necessário realizar uma caracterização hidrogeomorfológica da extensão fluvial a jusante do Aproveitamento Hidráulico, para o qual são definidos os caudais ecológicos descritos anteriormente (APA, 2018b). Esta caracterização é efetuada tendo como base orientações de normas europeias, desenvolvidas pelo Comité Europeu de Normalização (CEN), nomeadamente:

- EN 14614:2004 – Norma de orientação para avaliação das características hidromorfológicas dos rios; estabelece quais os aspetos da hidromorfologia fluvial que devem ser avaliados, como planear e realizar pesquisas de campo, como interpretar os resultados e algumas formas de aplicar procedimentos de avaliação de qualidade (Boon et al., 2010);
- EN 15843:2010 – Baseia-se na norma anterior, estabelecendo um protocolo para a avaliação do grau de modificações na hidromorfologia dos sistemas fluviais (Hajdukiewicz et al., 2017). De acordo com esta norma, é possível avaliar a degradação hidromorfológica separadamente para as zonas do leito menor, margens e galeria ripícola e leito maior. Na zona do leito menor ou ordinário (canal fluvial entalhado pela erosão dos cursos de água e delimitado por dois taludes marginais), são avaliados elementos hidromorfológicos como a geometria do leito, substrato, escoamento e continuidade longitudinal (para identificar condicionantes aos RCE); nas margens e galeria ripícola, é avaliada a estrutura e modificação nas margens, assim como, o uso do solo na zona ribeirinha; no leito maior ou de inundação (área submersa pelos cursos de água quando estes transbordam do seu leito ordinário), é avaliado o uso do solo para lá da zona ribeirinha, e também das estruturas ou medidas que impedem a inundação do leito de cheia e de constrangimentos ao movimento lateral natural do rio em situação de cheia (APA, 2018b).

2.2 Caracterização das condições fluviais: o papel dos VAnT e respetivos métodos e técnicas

A caracterização das condições fluviais referidas é tradicionalmente realizada por técnicos que podem ter interpretações ligeiramente distintas dos elementos no terreno, acarretando alguma subjetividade e diminuindo a comparabilidade dos dados obtidos por diferentes técnicos e em diferentes anos (Frias et al., 2023). Além disto, as caracterizações *in situ* revelam limitações de segurança e de acessibilidade em alguns troços de rios, tornando difícil a sua realização com frequência, e a sua reavaliação e comparação com outras caracterizações efetuadas (Rivas et al., 2015).

Nos últimos anos, o avanço tecnológico fez crescer o uso de Veículos Aéreos não Tripulados (VAnT), e de metodologias de caracterização fluvial associadas a estas aeronaves (Alves et al., 2015). Os VAnT, também conhecidos como *drones*, definem-se como aeronaves não tripuladas, equipadas com um ou mais sensores, controladas por um equipamento à distância (Woodget et al., 2017).

A caracterização das condições fluviais com recurso a VAnT providencia várias vantagens técnicas e económicas, pois permite diminuir o risco dos técnicos que elaboram as caracterizações fluviais, resolver o problema da acessibilidade a alguns troços, assim como efetuar análises mais fidedignas das possíveis alterações geomorfológicas presentes e futuras de um troço fluvial, e caracterizações mais rigorosas através da criação de mapas que cartografam diversos elementos fluviais (Woodget, 2015). A utilização de VAnT apresenta outras vantagens: flexibilidade na utilização dos mesmos, isto é, permite personalizar trajetórias de voo e recolher dados a várias escalas; custos de operação por voo relativamente baratos, tornando mais viáveis os levantamentos em locais de estudo de menor dimensão; capacidade de recolher imagens com elevada resolução espacial e temporal e de voar a baixa altitude, o que permite obter imagens sem nuvens (Woodget, 2015).

No entanto, existem algumas desvantagens e limitações no que diz respeito à utilização destas aeronaves: a sua pequena dimensão e o seu peso, sendo afetadas por ventos e limitadas em termos de capacidade de carga (Woodget, 2015); condições de vento adversas, que podem comprometer a segurança do voo e dificultam ou impossibilitam a recolha de imagens (Hardin & Jensen, 2011); imagens distorcidas e

imagens *off-nadir* (imagens que não são obtidas verticalmente ao sensor mas sim em ângulo oblíquo), podem produzir conjuntos de imagens com grandes variações na iluminação, afetando o pós-processamento e análise das imagens; capacidade das baterias, que por serem na sua maioria elétricas (de modo a serem mais leves e silenciosas), limitam o tempo de voo das aeronaves; leis e regulamentos de alguns países que impõem restrições à utilização dos VAnT (Woodget, 2015).

O desenvolvimento dos VAnT conduziu à rápida evolução nos sistemas de visualização, processamento e análise de imagens obtidas por *drone* em computador. A fotogrametria faz parte do conjunto de técnicas que refletem a evolução da análise e pós-processamento de imagens. Assim, a fotogrametria permite recolher informação e reconstruir um objeto tridimensionalmente a partir de medições realizadas em fotografias ou outras imagens do objeto (Sampaio, 2007). Esta técnica permitiu uma grande evolução na aquisição de dados geográficos, sendo possível realizar todo o processamento de imagens digitais, e obter uma série de dados, como mapas topográficos/temáticos, modelos digitais de terreno, fotografias retificadas (ortofotos), assim como interpretação e medição de objetos (Sampaio, 2007).

Para além disso, estes avanços levaram a uma maior disponibilidade de *softwares*, onde são produzidas imagens ortorretificadas, modelos digitais de terreno e de superfície em estrutura *raster*, a partir de imagens de VanT (Woodget et al., 2017). O método *Structure from Motion* (SfM), é um bom exemplo da evolução das técnicas de análise e pós-processamento de imagens, resultantes da popularização e crescente utilização dos VAnT. O princípio deste método consiste na obtenção de informação acerca da geometria tridimensional de um objeto a partir de imagens a duas dimensões (Videira, 2016). Ao contrário da fotogrametria tradicional, o método SfM utiliza algoritmos que identificam características semelhantes em imagens 2D recolhidas e, após a sua sobreposição, são criados modelos e estruturas 3D do objeto ou da superfície fotografada (Carrivick et al., 2016), produzindo, assim, modelos digitais de terreno, modelos digitais de superfície, ortomosaicos e índices de vegetação (Pontoglio et al., 2021).

A caracterização hidrogeomorfológica de sistemas fluviais através de VAnT, tem sido limitada até à data. No entanto, segundo Frias et al. (2017), é possível recolher algumas características e elementos fluviais através dos VAnT, tais como: mapear e obter a batimetria fluvial, através de métodos fotogramétricos ou equipando o *drone* com um

Sonar ou um *Ground Penetrating Radar* (GPR); equipar o *drone* com LiDAR (*Light Detection And Ranging*), para obter a topografia das margens do rio e da planície aluvial; medir o nível da água, utilizando um radioaltímetro com o VAnT.

Detert et al. (2017) demonstraram a possibilidade de determinar a velocidade de escoamento e os tipos de escoamento superficial, através de vídeos capturados por VAnT e do método ótico PIV (*Particle Image Velocimetry*) (Lagogiannis., 2021). Para a modelação de vários tipos de caudais fluviais, Kang et al. (2019), procuraram estimar o fluxo de água em troços de rio, equipando um VAnT com sensores óticos, sensores infravermelhos e sensores de micro-ondas (Frias et al., 2017). Através da utilização de uma câmara de infravermelhos e de um algoritmo PIV, Kinzel e Legleiter (2019) calcularam a velocidade de escoamento superficial, que, combinado com um LiDAR polarizado para obter a batimetria, permitiu estimar a descarga do *Blue River* no Colorado (Lagogiannis, 2021).

3. Área de Estudo

3.1 Localização

A área de estudo deste projeto compreende o troço fluvial do rio Cávado, entre a barragem de Salamonde, a montante, e o regolfo da albufeira de Caniçada, com extensão de 1971 m. A barragem de Salamonde entrou em serviço em 1953 no rio Cávado, 5 km a jusante da confluência com o rio Rabagão, e localiza-se na NUTS II da Região Norte de Portugal continental, entre o distrito de Vila Real (concelho de Montalegre, freguesia de Cabril) e o distrito de Braga (concelho de Vieira do Minho, freguesias de Salamonde e Louredo), na região frequentemente apelidada “Alto Portugal” (figura 1).

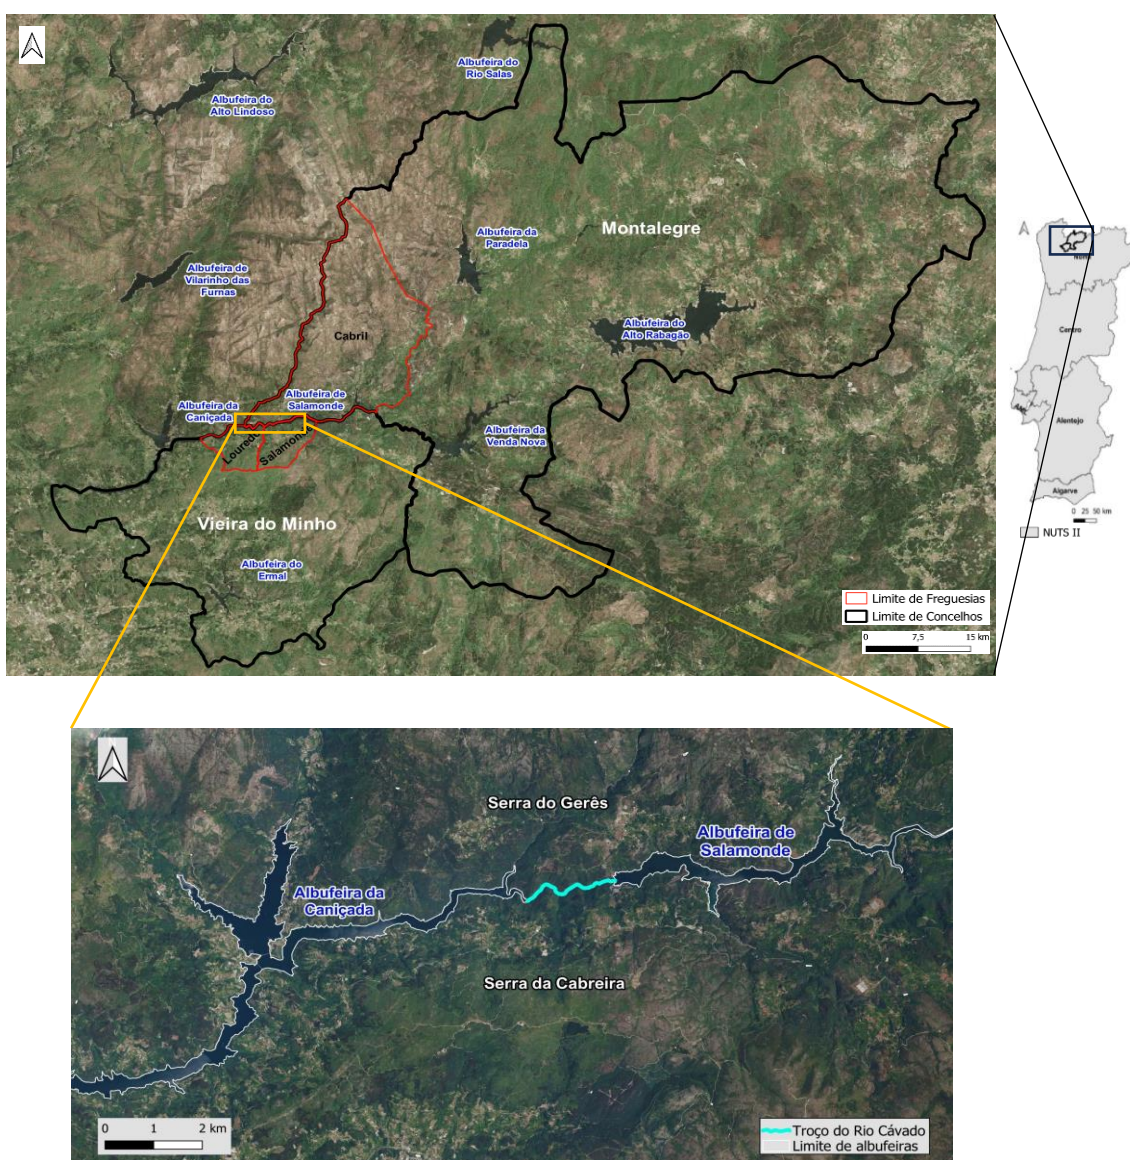


Figura 1 - Enquadramento geográfico da área de estudo do projeto.
Fonte dos dados: DGT (limites administrativos); APA (limite de albufeiras);
ESRI (imagens de satélite).

3.2 Enquadramento climático regional

A posição geográfica e o relevo vigoroso constituído pelas montanhas do Noroeste de Portugal, que se opõem à progressão das massas de ar húmidas provenientes do Atlântico, fazem com que a região onde se insere a área de estudo seja a mais pluviosa de Portugal, registando valores de precipitação anual superiores a 3 000 mm (Profico Ambiente, 2010).

No vale encaixado do rio Cávado, onde se insere a área de estudo, verifica-se uma elevada dissimetria na distribuição da precipitação, com valores de pluviosidade bastante superiores em vertentes expostas a oeste. A morfologia do rio Cávado proporciona condições ideais à formação de fluxos de ar canalizados no seu vale, para além de fomentar a acumulação de ar frio no fundo do vale em situações de estabilidade atmosférica, resultando na formação de nevoeiros (Profico Ambiente, 2010).

O clima da área de estudo foi caracterizado com base nos registos das variáveis climáticas na Ficha Climatológica (1981-2010), disponibilizados pelo Instituto Português do Mar e da Atmosfera (IPMA), da estação climatológica de Montalegre, sendo esta a mais próxima da barragem de Salamonde, a cerca de 22 km do limite montante da respetiva albufeira.




Figura 2 - Regime termopluriométrico de Montalegre (1981-2010).
Fonte dos dados: IPMA.

A temperatura média anual do ar na estação de Montalegre é 10,5 °C. O regime mensal médio apresenta valores máximos nos meses de Verão, destacando-se agosto com 18,2 °C. Os valores mínimos registam-se no Inverno, em janeiro, com temperatura média de 4,1 °C, estabelecendo-se uma amplitude térmica de 14,1 °C (figura 2).

As temperaturas do ar extremas, máximas e mínimas médias, registam-se em agosto com valores de 24,4 °C e em janeiro 0,7 °C, respetivamente. As temperaturas máximas e mínimas absolutas ocorrem em agosto (35,3 °C) e março (-10,2 °C), respetivamente.

A temperatura média anual, registada na albufeira de Salamonde e na respetiva área envolvente, é 11,5 °C (Profico Ambiente, 2010). A precipitação anual média é 1494 mm, repartida por 193 dias. A precipitação diária superior a 10 mm ocorre, em média, em 82 dias por ano.

A análise do regime mensal da precipitação na área de estudo evidencia um período chuvoso, que se estende de setembro a junho, e outro seco, de julho e agosto. Dezembro é, em média, o mês mais pluvioso, com 243,8 mm. Os valores mais baixos, verificam-se no mês de julho com 21,8 mm (figura 2).

3.3 Caracterização geomorfológica

A região onde se localiza a área de estudo deste projeto caracteriza-se pela presença de relevos irregulares predominantemente montanhosos, com variações altimétricas bastante pronunciadas, na ordem dos 1000 m (figura 3). As cotas mais baixas localizam-se nas albufeiras de Salamonde e de Caniçada, e respetivas áreas adjacentes, entre os 160 e 300 m, enquanto as cotas mais elevadas localizam-se na Serra da Cabreira e na Serra do Gerês, entre os 700 e 1190 m de altitude.

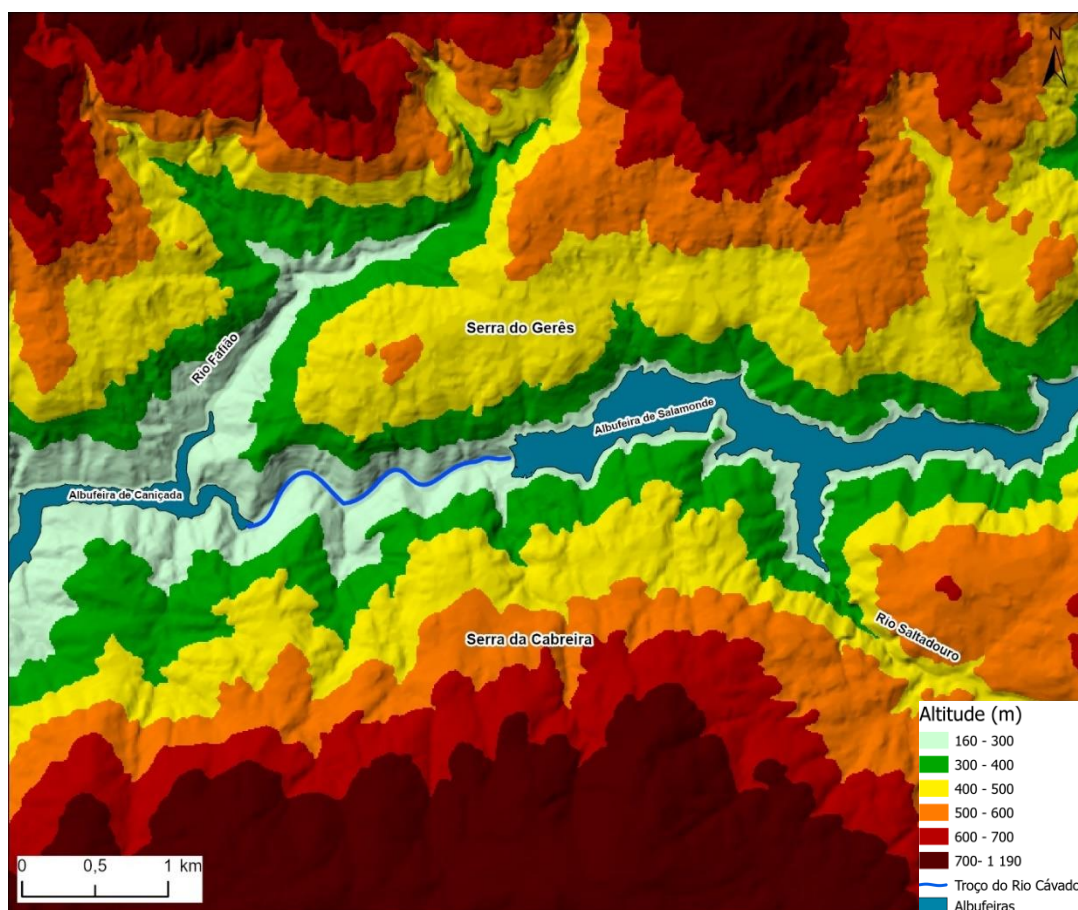


Figura 3 - Distribuição espacial da altitude (m) da região da área de estudo.
 Fonte: A partir de MDT obtido com base na altimetria 1/25000, IGeoE.

Para além disso, observam-se declives muito acentuados, nomeadamente em vales da Serra do Gerês, como o vale do rio Fafião e a vertente direita do troço do rio Cávado em estudo, com valores de declive entre 35° e 62°, e em vales da Serra da Cabreira, com declives entre 25° e 35° na vertente esquerda do troço do rio Cávado em estudo, e encostas com declives entre 25° e 62°, em locais como o vale do Rio Saltadouro (figura 4).

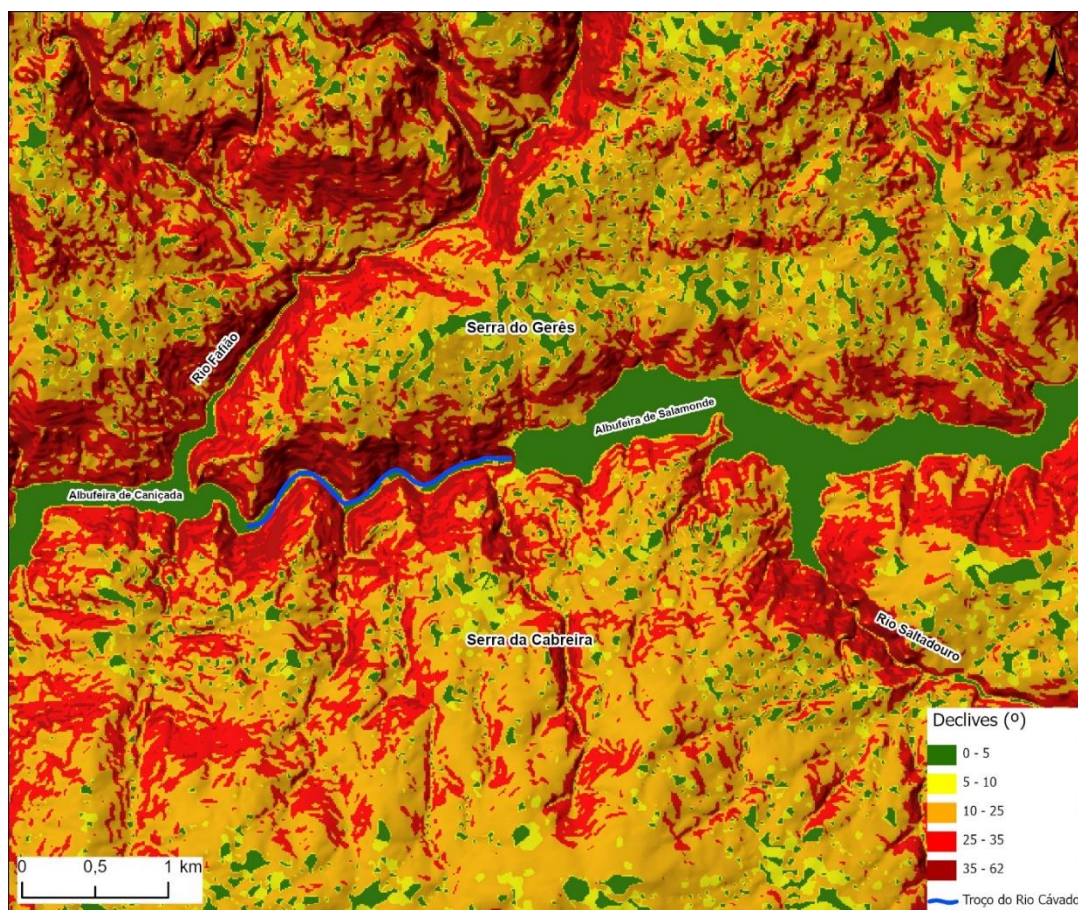


Figura 4 - Distribuição espacial do declive (°) da região da área de estudo.
 Fonte: A partir de MDT obtido com base na altimetria 1/25000, IGeoE.

Ainda neste ponto, verifica-se a presença de talvegues com pequenas linhas de água inseridas num vale encaixado onde se desenvolve o rio Cávado, de ENE para WSW, e a predominância de vertentes expostas a norte e a sul na região onde se localiza a área de estudo, com vertentes maioritariamente expostas a norte/noroeste na Serra da Cabreira e ao longo da margem esquerda do rio Cávado, e a sul/sudeste na Serra do Gerês e ao longo da margem direita do rio Cávado (figura 5).




Figura 5 - Distribuição espacial da exposição de vertentes da região da área de estudo.
 Fonte: A partir de MDT obtido com base na altimetria 1/25000, IGeoE.

A litologia constitui outra condicionante do relevo regional. Os metassedimentos menos resistentes à erosão são responsáveis pela formação de terrenos com menor altitude, e os granitos, por serem mais resistentes, constituem as partes mais elevadas, formando cristas recortadas pela rede hidrográfica bem diversificada e hierarquizada que os atravessa. Esta área é constituída por terrenos de permeabilidade reduzida (rochas intrusivas, hercínicas, predominantemente graníticas) e muito reduzida (xistos e outros metassedimentos, por vezes com quartzitos, do Paleozóico e Precâmbrico, em parte intensamente metamorfizados). A percolação de água faz-se em profundidade ao longo de diáclases, falhas e outros alinhamentos, que proporcionam permeabilidades fissurais (Profico Ambiente, 2010).

Apesar do vale estudado atravessar somente um tipo de litologia granítica (Granito do Gerês), é possível encontrar na área envolvente quatro tipos de granitos: Granito sin-tectónicos de grão médio, de duas micas, com tendência porfiróide (Granito da Cabreira); Granito sin-tectónicos biotíticos de grão grosseiro, de duas micas e com tendência porfiróide (Granito de Ruivães); Granito pós-tectónicos biotíticos, com fácies grosseira na periferia do granito e de fácies porfiróide de grão médio a grosseiro no seu interior (Granito do Gerês); Granito tardi-tectónico porfiróide, biotítico, de grão muito grosseiro, com feldspatos de grandes dimensões (Granito de Cantelães) (Noronha, 1983) (figura 6).

O troço fluvial estudado assenta, segundo a notícia explicativa da folha 6-A Montalegre da Carta Geológica de Portugal (Noronha, 1983), num leito de granito do Gerês com granito porfiróide de grão grosseiro a médio, essencialmente biotítico, composto por quartzo, feldspato potássico rosado, plagioclase e biotite, presentes em ambas as margens (figura 6).

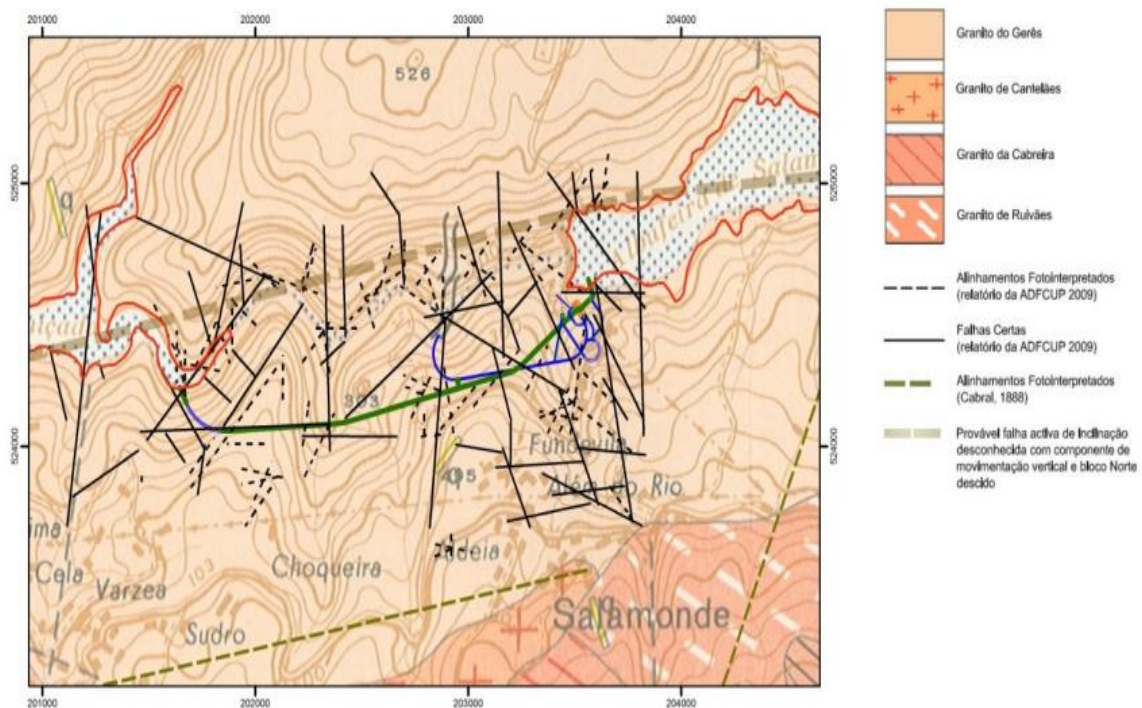


Figura 6 - Extrato da folha 06-A da Carta Geológica de Portugal, na escala 1/50000, da região em análise (extraído de Profico Ambiente, 2010, pag. 86).

3.4 Caracterização hidrográfica

A principal via fluvial da área em estudo, o rio Cávado, nasce na serra do Larouco, a 1520 m de altitude, com um percurso longitudinal de 129 km no sentido nordeste-sudoeste, até à sua foz na cidade costeira de Esposende (figura 7) (APA, 2016). A sua bacia hidrográfica apresenta uma área de 1699 km² com sentido dominante de ENE para WSW, destacando-se as sub-bacias dos afluentes de maior envergadura: o rio Homem, na margem direita, com um comprimento de 45 km, que nasce na Serra do Gerês e drena uma área de 256 km²; o rio Rabagão, na margem esquerda, com um comprimento de 37 km, que nasce entre as serras do Barroso e do Larouco, drenando uma área de 248 km² (Profico Ambiente, 2010).

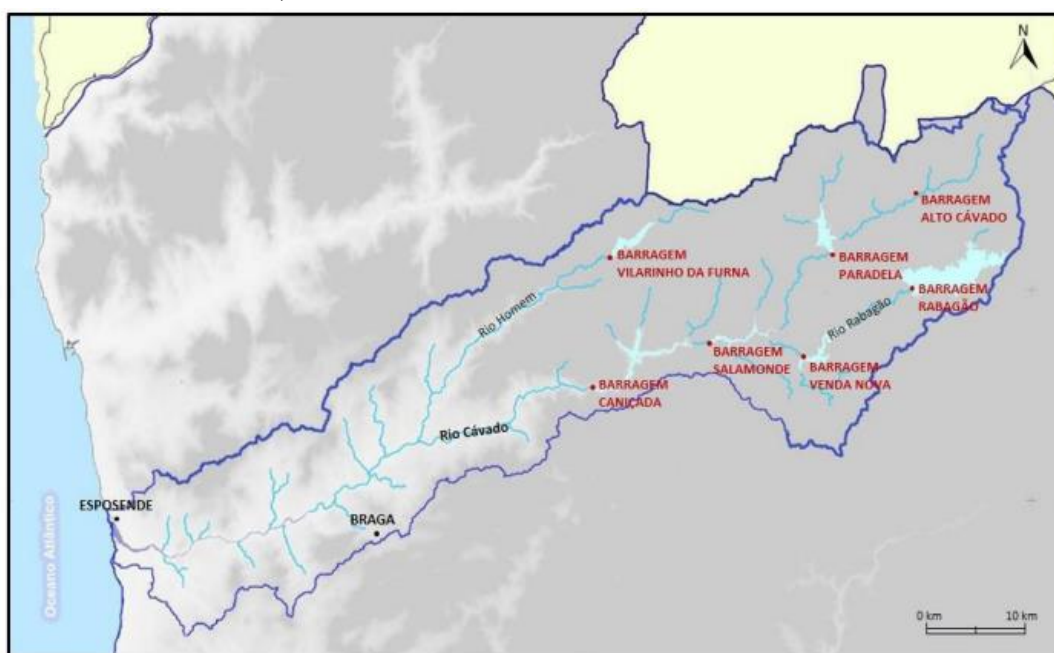


Figura 7 - Localização das barragens construídas na bacia hidrográfica do rio Cávado (extraído de Ferreira, 2018, pag. 10).

As características morfológicas do rio Cávado e a elevada precipitação registada na área da sua bacia hidrográfica, fazem deste curso de água e dos principais afluentes locais privilegiados para a construção de sistemas hidroelétricos, com custos relativamente reduzidos de construção e com altos rendimentos energéticos.

Atualmente, o rio Cávado não dispõe de um caudal natural pois encontra-se controlado pelas barragens construídas ao longo do seu leito e do leito dos seus afluentes.

Assim, na sua bacia hidrográfica existem sete barragens (figura 7), seis das quais para aproveitamento hidroelétrico: barragens de Paradela, Salamonde e Caniçada (no rio Cávado); barragens do Alto Rabagão e Venda Nova (no rio Rabagão); barragem de

Vilarinho das Furnas (no rio Homem); e barragem do Alto Cávado, localizada no rio Cávado, sendo a única não produtora de energia (Ferreira, 2018). Segundo Gonçalves (2015), a construção das barragens referidas teve como principal objetivo a produção de energia hidroelétrica, para além de outros objetivos, como o controlo e laminação de cheias, a regularização do regime do rio, o desenvolvimento turístico e também o abastecimento de água às populações.

3.4.1 Sistema Cávado – Rabagão – Homem

Este aproveitamento hidroelétrico (AH), integra o Sistema Cávado-Rabagão-Homem, em conjunto com as barragens de Paradela, Alto Cávado e Caniçada (rio Cávado), Alto Rabagão e Venda Nova (rio Rabagão) e Vilarinho das Furnas (rio Homem), todas exploradas pela Direção de Produção Hidráulica da EDP Produção, sendo possível observar a planta geral do sistema, nas figuras 7 e 8, bem como a sua configuração (APA, 2023). O conjunto das albufeiras deste sistema têm uma capacidade de armazenamento de aproximadamente 1097 hm³, equivalente a 1642,8 GWh, dos quais 64 % correspondem à albufeira do Alto Rabagão (Palhares, 2015).

A influência das barragens deste sistema, e das aflúências próprias da bacia hidrográfica, na albufeira de Salamonde, é de extrema importância do ponto de vista dos recursos hídricos, sendo os escoamentos gerados na bacia total de Salamonde previamente regularizados nas albufeiras de Alto Rabagão, Venda Nova, Alto Cávado e Paradela, cuja capacidade de armazenamento útil total é bastante elevada, o que permite regularizar de forma significativa as aflúências à albufeira de Salamonde (Profico Ambiente, 2010) (figura 8).

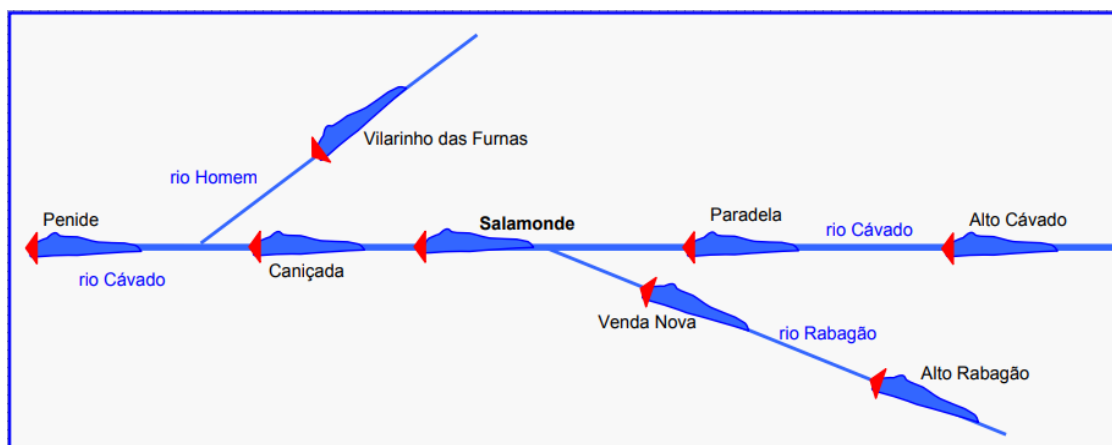


Figura 8 - Esquema simplificado do Sistema Cávado – Rabagão – Homem (extraído de Profico Ambiente, 2010, pag. 125).

3.4.2 Aproveitamento Hidroelétrico de Salamonde

3.4.2.1 Barragem e Albufeira

A barragem de Salamonde é uma estrutura de betão, do tipo abóboda delgada de dupla curvatura. Tem 75 m de altura acima da fundação e a respetiva cota de coroamento a 281 m (Ferreira, 2010). A barragem tem 284 m de comprimento de coroamento, com uma volumetria total de 93.000 m³ de betão (CNPGB, 2016). Dispõe de um Aproveitamento Hidroelétrico, sendo destinada essencialmente à produção de energia elétrica (figura 9), que integra, para além da barragem e respetivos órgãos de segurança, uma série de sistemas implantados na margem esquerda, nomeadamente um circuito hidráulico longo, em túnel, uma central subterrânea e uma subestação (Gonçalves, 2015).




Figura 9 - Aproveitamento Hidroelétrico de Salamonde.
(Fotografia de Pedro Nascimento, dia 07/07/2023).




Figura 10 - Barragem de Salamonde.
(Foto: Labelec, 28/02/2023).

Desde 2005, esta barragem dispõe adicionalmente de uma central hidroelétrica subterrânea de grandes dimensões, intitulada de Salamonde II, construída com o objetivo de reforçar a potência do atual AH de Salamonde, e de melhorar a capacidade de resposta em períodos como horas de cheia e de ponta, onde se verificam uma maior produção de energia. Este reforço de potência beneficia da diferença de altitude entre as albufeiras de Salamonde e da Caniçada, com um desnível médio de cerca de 118 m, e incorpora, para além de uma central subterrânea equipada com um grupo reversível, um circuito hidráulico subterrâneo com 2,2 km de comprimento (Ferreira, 2013), transportando a água desde a albufeira de Salamonde até à sua restituição na albufeira de Caniçada.

Para além disso, esta barragem dispõe, desde 2016, de um dispositivo específico para a libertação de caudais ecológicos, inserido na margem direita no descarregador de

cheias complementar, constituído por uma conduta metálica de seção circular, onde são descarregados caudais entre 0,2 e 3,0 m³/s (APA, 2023) (quadro 1).

Quadro 1 - Valores (m³/s) do Regime de Caudais Ecológicos (RCE) em vigor na barragem de Salamonde a partir de 1 de novembro de 2016.

Fonte dos dados: EDP Produção.

Salamonde - RCE em vigor												
Mês	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set
Caudal (m ³ /s)	0,39	0,96	1,78	2,27	2,77	2,50	2,22	1,62	0,76	0,35	0,17	0,35

A albufeira do AH de Salamonde, criada pela construção da barragem, tem como principal função o armazenamento da água proveniente das chuvas e do processo de bombagem para a produção de energia elétrica. Esta, tem capacidade total de armazenamento de 65 hm³ e capacidade útil de 56,3 hm³, sendo bastante limitada em termos de área e de capacidade de armazenamento (por cobrir apenas 2,4 km²), apresentando uma cota do Nível mínimo de Exploração (NmE) de 259 m, um Nível de Pleno Armazenamento (NPA) de 280 m e um Nível de Máxima Cheia (NMC) de 280,5 m (CNPNG, 2016).

O volume mensal afluente é relativamente regular ao longo do ano, embora maior no semestre húmido, de outubro a março, e mais reduzido no semestre seco, de abril a setembro. A média dos valores mensais do ano hidrológico de 2001/02 a 2007/08, que compreende a série de valores completos do quadro, permite confirmar a tendência para os valores do volume mensal afluente serem mais elevados em janeiro e dezembro e mais reduzidos em abril e setembro, verificando-se dois períodos anuais com volumes mensais afluentes díspares, com valores superiores a 65000 dam³ com tendência a aumentar de outubro a março, e volumes inferiores a 60000 dam³ de abril a setembro, com tendência a diminuir de abril até junho, aumentando gradualmente até setembro (quadro 2). Para além disso, embora a tendência ao longo do ano seja a mesma, no período de 2001/02 a 2007/08, verificam-se volumes médios mensais inferiores à média de valores da série 2001/01 a 2023/24, em todos os meses do ano.

Quadro 2 - Volumes afluentes mensais e anual na estação hidrométrica de Salamonde (dam3).

Fonte dos dados: APA (SNIRH)

Ano Hidrológico	OUT	NOV	DEZ	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	N. Valores	Soma Anual
2000/01	-	-	-	-	-	-	161948	137557	-	68031	51157	45360	5	-
2001/02	63746	63504	49766	64282	38949	59728	32659	57050	48989	52764	28927	37584	12	597948
2002/03	49283	86780	204768	254984	99429	94012	88387	75799	66424	62986	46604	69371	12	1198827
2003/04	93744	106790	113564	104993	69906	63210	41472	38033	52618	53568	64549	71021	12	873468
2004/05	70174	77760	85085	54639	32823	27855	15293	17142	34214	29998	38033	28771	12	491787
2005/06	36694	57542	66692	60800	59028	115975	68429	65889	47174	63478	41247	50803	12	733751
2006/07	126688	151114	179453	128563	144668	102047	85536	70174	88170	85621	55443	36029	12	1213506
2007/08	38301	61171	53032	104029	47682	38301	72576	45533	16848	80620	94280	72835	12	725208
2008/09	48747	41990	91066	100708	85277	44006	31182	31605	38776	35837	-	-	10	-
2009/10	64737	99481	-	291731	210228	206531	155598	112412	85951	76629	59273	73691	11	-
2010/11	86807	124831	167373	185560	93768	69290	49533	52791	50492	41274	52979	50285	12	1024983
2011/12	70094	72680	80191	63773	55374	33373	53654	85709	35277	42185	45265	52436	12	690010
2012/13	71379	99507	128108	167748	94784	-	131466	-	88465	-	72076	91601	9	-
2013/14	97467	-	124492	191613	309730	-	107076	-	-	50006	-	-	6	-
2014/15	-	150206	118975	111823	90623	-	-	-	60990	-	48506	55961	7	-
2015/16	74754	104406	107806	302124	285764	-	235587	196005	-	103118	80781	88828	10	-
2016/17	57880	89968	147767	176748	151732	180283	168480	145410	83151	84075	70549	57853	12	1413898
2017/18	69049	-	216468	188533	175706	-	228925	114261	72213	74085	99583	99455	10	-
2018/19	152963	159849	230985	147928	146652	-	180507	111475	-	38890	-	106998	9	-
2019/20	132045	274130	324997	243065	185414	214433	198884	-	140797	133438	110029	108190	11	-
2020/21	165204	169646	252252	229566	261878	-	116899	-	101762	95565	-	123198	9	-
2021/22	270197	246473	270411	226860	200092	-	252953	250966	112234	-	-	-	8	-
2022/23	240547	178226	200612	316185	-	-	217935	202567	75401	119564	170373	134110	10	-
2023/24	242556	258630	-	-	-	-	-	-	-	-	-	-	2	-
N. Valores	22	21	21	22	21	13	22	18	19	20	18	20		
Min.	36694	41990	49766	54639	32823	27855	15293	17142	16848	29998	28927	28771		
Máx.	270197	274130	324997	316185	309730	214433	252953	250966	140797	133438	170373	134110		
Média	105593	127366	152089	168921	135215	96080	122499	100577	67366	68587	68314	72719		
Des. Padrão	70575	74078	85966	87391	87908	68645	80333	71745	37839	37256	42837	39679		
Coef. Assimetria	1,36	0,97	0,56	0,26	0,72	0,91	0,36	1,04	0,68	0,77	1,69	0,42		
Média 2001-2008	68376	86380	104623	110327	70355	71590	57765	52803	47777	58434	52726	52345		833499

3.4.2.2 Bacia Hidrográfica do AH de Salamonde

A bacia hidrográfica do AH de Salamonde tem uma grande importância do ponto de vista dos recursos hídricos. Esta bacia encontra-se delimitada a nordeste pela Serra do Larouco, a noroeste pela Serra do Gerês, a sudoeste pela Serra da Cabreira e a sudeste pela Serra do Barroso (figura 11). A linha de cumeeada que define o limite NW, N e NE, tem altitudes, em regra, superiores a 1 250 m, atingindo no ponto mais alto na Serra do Gerês, mais especificamente na Garganta das Negras (1548 m). Os principais afluentes do rio Cávado na sub-bacia hidrográfica do AH de Salamonde são, na sua margem direita, o rio de Pincães e a Ribeira de Cabril e, na sua margem esquerda, os rios Saltadouro e Rabagão (APA, 2010). A sub-bacia hidrográfica de Salamonde apresenta uma área total de 622 km², com uma altitude média de 950 m, declive médio de 20 % e escoamento anual médio de 166 hm³ (C.M. de Vieira do Minho, 2011). O troço fluvial em estudo tem uma área de drenagem total de 8 km², e é a única área contributiva para este troço fluvial, que não é controlada pela barragem de Salamonde.

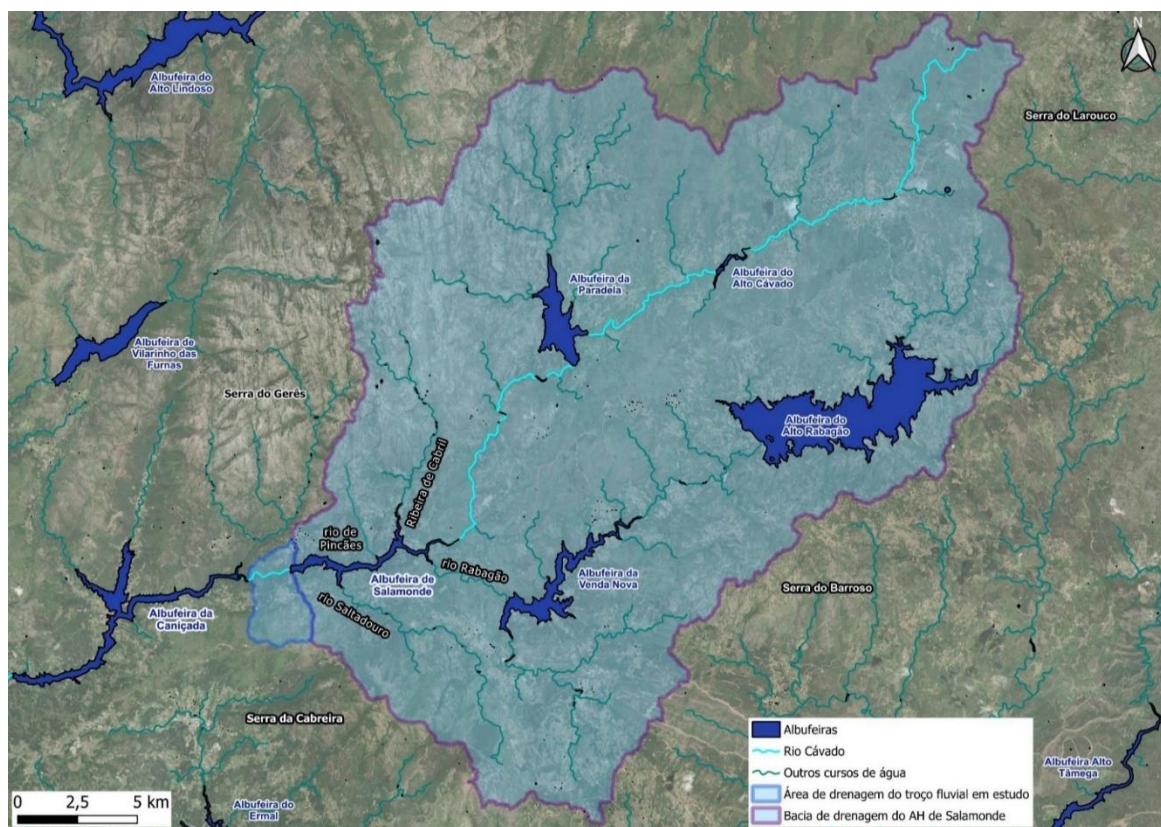


Figura 11 - Bacia de Drenagem do AH de Salamonde.
 Fonte dos dados: APA (limites de albufeiras); ESRI (imagens de satélite).

3.5 Caracterização do troço fluvial

Como referido, a área de estudo compreende o troço fluvial do rio Cávado, desde a barragem de Salamonde, a cerca de 200 m de altitude, até ao regolfo da albufeira de Caniçada, a cerca de 160 m de altitude, com uma distância de 1971 m ao longo do troço, o qual é designado como Massa de Água Fortemente Modificada (MFM). Esta área é circundada pela serra da Cabreira, a sul, e pela serra do Gerês, a norte, sendo a ribeira de Rebolido, localizada na margem esquerda, o único afluente com dimensão relevante (figura 12). A caracterização do troço fluvial em estudo foi realizada com recurso à cartografia obtida pelo MDT 1/25000, retirado do IGeoE, e através do MDT, com uma resolução de 12 cm, obtido através dos levantamentos com VAnT na área de estudo, permitindo a caracterização pormenorizada pretendida do troço fluvial.

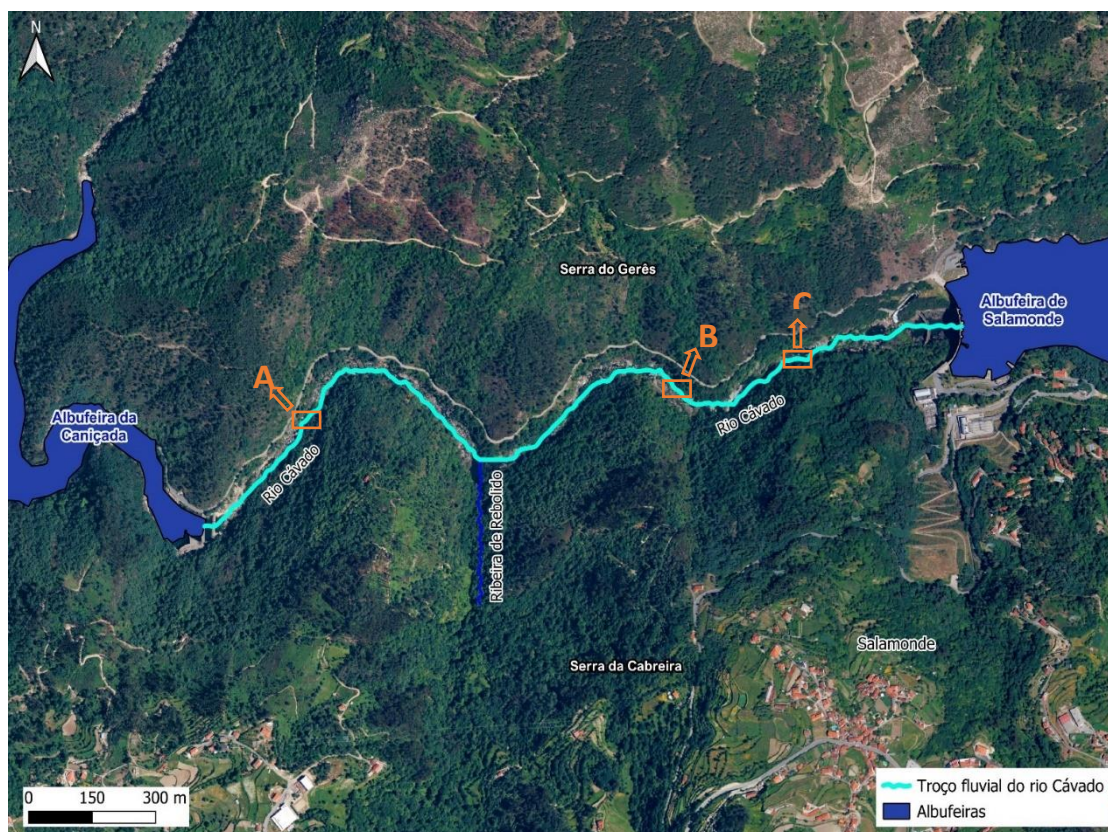


Figura 12 - Enquadramento geográfico do troço fluvial em estudo. Localização dos perfis transversais elaborados.

Fonte dos dados: APA (SNIAmb) e DGT (SNIG).

Neste troço, o relevo encontra-se muito acidentado e recortado por uma rede hidrográfica fortemente encaixada em vales profundos e de traçados, em geral, retilíneos e angulares (Profico Ambiente, 2010) (figura 17). Verifica-se a predominância de terrenos a cotas bastante elevadas e irregulares, com altitudes que podem variar drasticamente em curtas distâncias, como se verifica nos perfis transversais da figura 17, estando o leito do rio a cerca de 160 m e alguns locais relativamente próximos ao troço fluvial, na Serra do Gerês e na Serra da Cabreira, a 1190 m de altitude (figura 13). Para além disso, verifica-se uma variação de 80 m na altitude a que se encontra o leito do rio, desde o limite imediatamente a jusante da barragem de Salamonde com 220 m, até ao regolfo da albufeira de Caniçada com 140 m (figura 16).

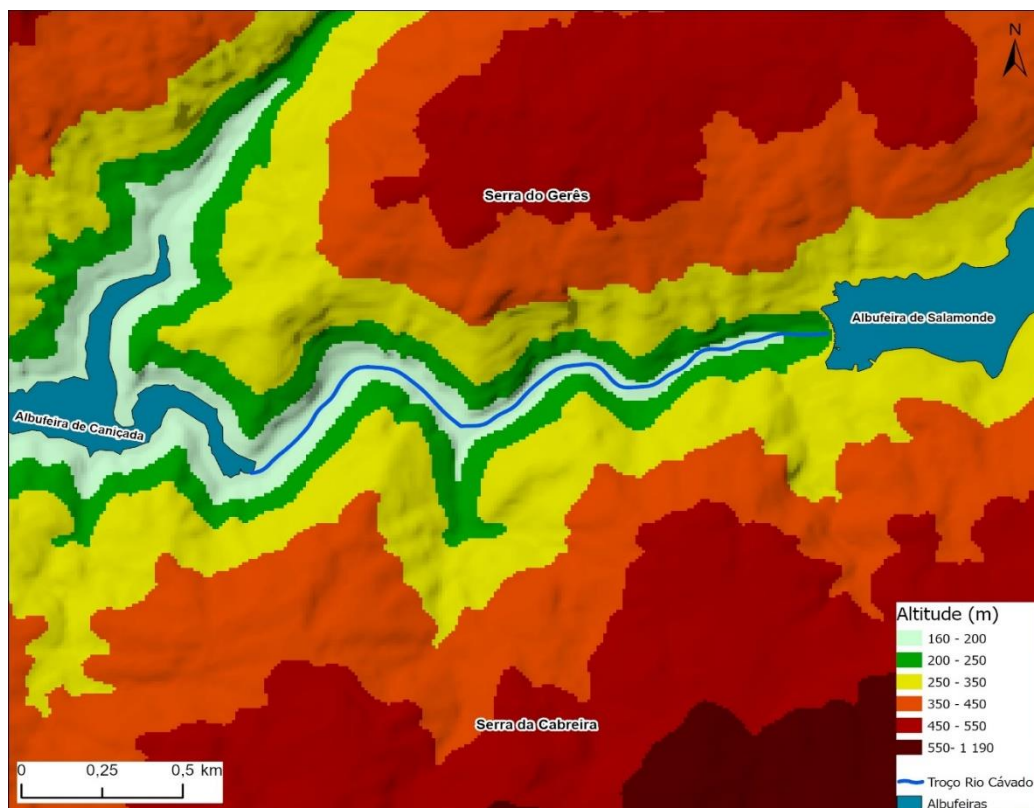


Figura 13 - Altitude (m) do troço fluvial em estudo.
 Fonte: A partir de MDT obtido com base na altimetria 1/25000, IGeoE.

Para além disso, este troço está situado num vale em V fechado, entre as vertentes íngremes e escarpadas das serras da Cabreira e do Gerês, e apresenta um declive longitudinal acentuado, existindo uma variação da altitude do leito do rio de 185 m nos locais mais próximos da barragem de Salamonde (perfil C, figura 17), para 155 m nos setores do troço próximos do regolfo da albufeira de Caniçada (perfil A, figura 17). As vertentes deste troço são plano-côncavas sem rutura de declive e com características que se mantêm no sentido de montante para jusante (Noronha, 1983) (figura 17). Para além disso, os perfis transversais, revelam declives igualmente acentuados, que diminuem gradualmente no sentido montante-jusante. As vertentes do troço em análise apresentam declives bastante elevados, com valores até 62°, sendo registados mais frequentemente na vertente direita do rio Cávado, que apresenta um comando das vertentes (altura medida entre a base e o topo da vertente), superior ao da vertente esquerda (figura 14). No leito fluvial verifica-se uma elevada variação dos declives na distância entre o leito e a berma, com declives de 80° em algumas das margens do canal fluvial (figura 16).

Este canal tem uma orientação geral este-oeste e ENE/OSO, com um traçado em ziguezague marcado pelo contraste entre troços com orientação NE-SO e NO-SE (figura 15 e figura 17). As características deste troço fluvial proporcionam um contraste

acentuado entre as condições umbrófilas da vertente esquerda, com exposição NE e NW, e as condições heliófilas da vertente direita, com exposição SE e SW (figura 15).




Figura 14 - Declives (°) do trecho fluvial em estudo.
Fonte: A partir de MDT obtido com base na altimetria 1/25000, IGeoE.




Figura 15 - Exposição de vertentes do trecho fluvial em estudo.
Fonte: A partir de MDT obtido com base na altimetria 1/25000, IGeoE.

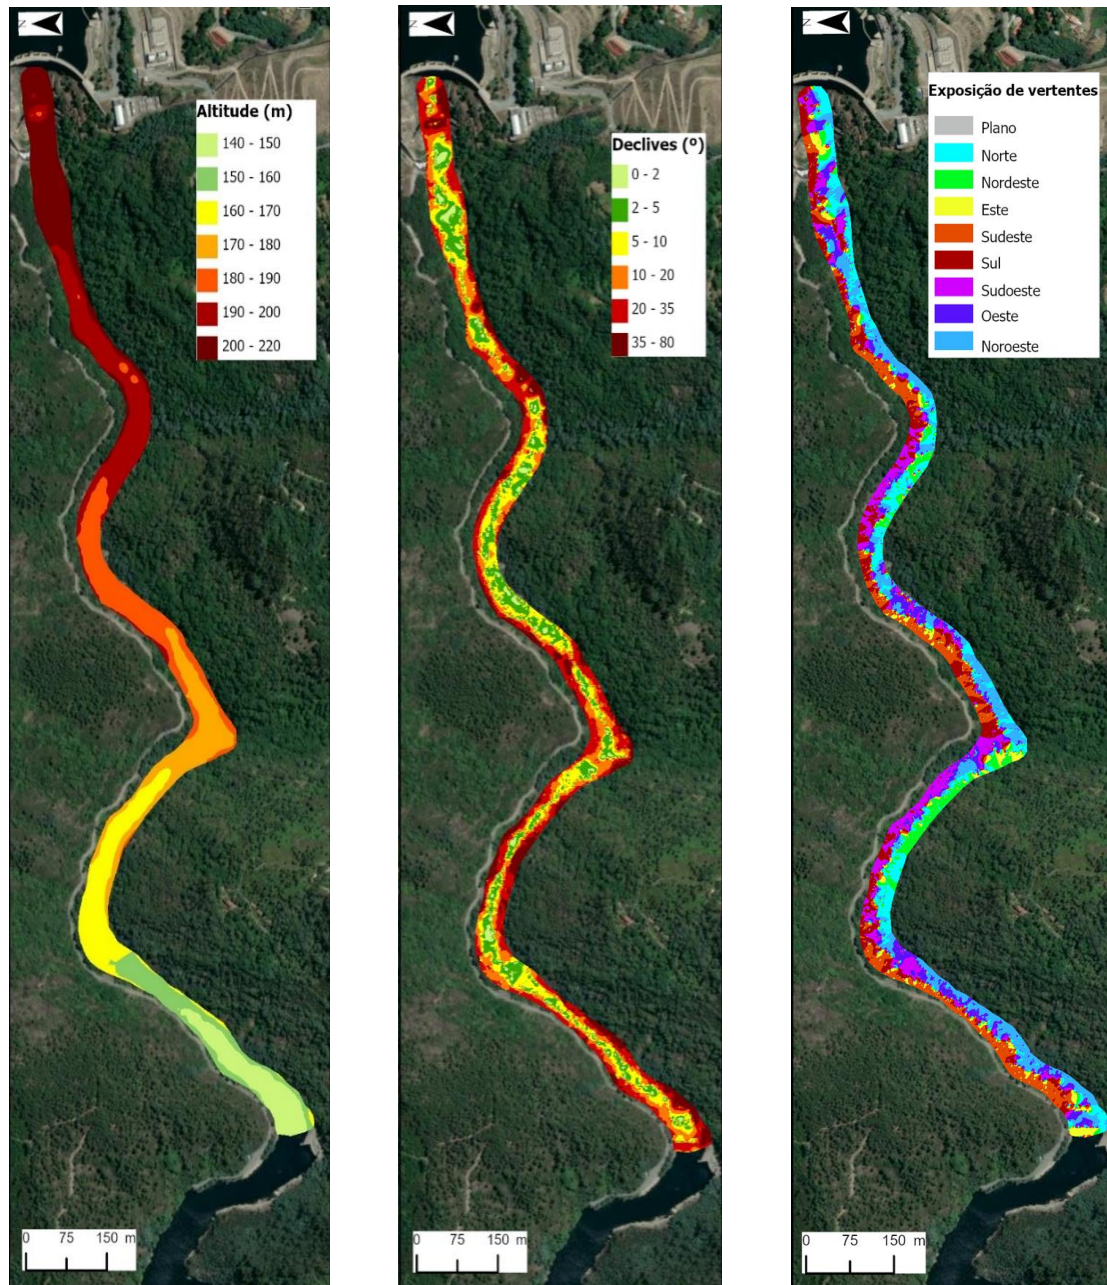


Figura 16 - Altitude, declives e exposição de vertentes do leito fluvial.

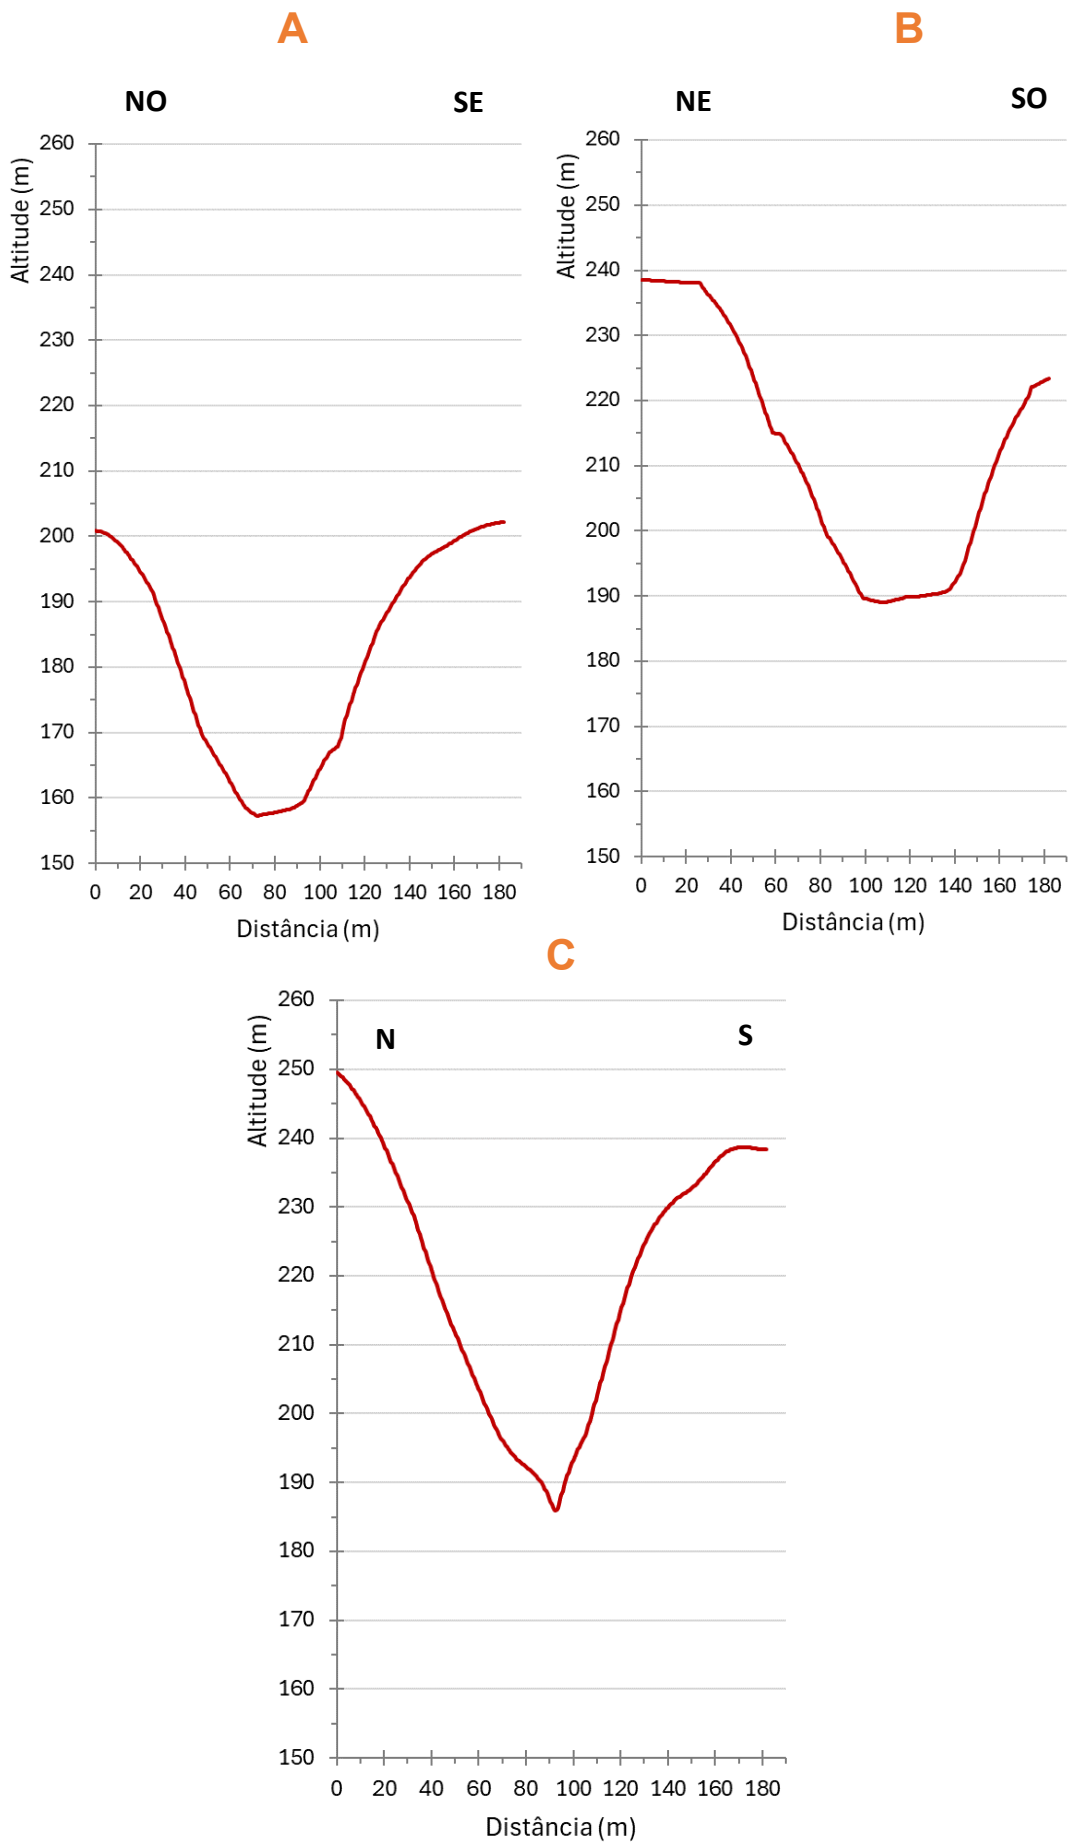


Figura 17 - Perfis transversais em três setores do trecho fluvial.

As condições naturais do leito e das margens, do troço fluvial em análise, são bastante diferentes das características dos planos de água localizados a montante e a jusante da MFM, onde se encontram as albufeiras de Salamonde e de Caniçada. Nestas, observa-se uma faixa quase completamente desprovida de vegetação, na transição terra/água, devido à influência antrópica no corte da vegetação da área da albufeira até ao NPA, por questões de segurança e para evitar a decomposição da matéria vegetal, e manter a qualidade da água, assim como, pela variação intrínseca do nível da água armazenada, que impede a constituição de comunidades vegetais diversificadas que ocorreriam em situações naturais (Alves et al., 2009).

No canal fluvial e no vale estudado, é possível verificar a presença de florestas mistas resinosas e folhosas, e de comunidades vegetais aquáticas e ribeirinhas, nomeadamente galerias arbóreas fragmentadas, comunidades higrófilas, helofíticas e de macrófitos aquáticos, assim como bosques caducifólios, essencialmente *Quercus robur*, e povoamentos florestais de *Eucalyptus globulus* na vertente da margem esquerda, e povoamentos florestais de *Pinus pinaster* ao longo da vertente da margem direita.

Para além disso, observa-se a presença de culturas agrícolas residuais de olival e vinha, na ribeira de Rebolido, e de uma espécie exótica, *Acacia dealbata*, que forma faixas ao longo das margens e manchas nas vertentes, e que representa uma ameaça às comunidades nativas, devido ao ensombramento (podendo atingir 15 m de altura) e aos mecanismos alelopáticos (efeito inibitório sobre o crescimento de outras espécies de plantas), associados à presença desta espécie (Profico Ambiente, 2010).

4. Métodos e Dados

4.1 Metodologia

As metodologias utilizadas neste trabalho foram divididas em quatro etapas. Na primeira etapa está implícita a caracterização dos levantamentos e voos VAnT, efetuados em fevereiro e julho. Na segunda etapa, são descritos os processos efetuados no *software* Pix4Dmapper, para a criação dos ortomosaicos e modelos digitais de superfície. A terceira etapa compreende a caracterização dos métodos e técnicas utilizados na classificação semiautomática dos ortomosaicos no *software* ArcGIS Pro, sendo posteriormente, na quarta etapa das metodologias, apresentadas as métricas de validação utilizadas nos resultados (figura 18).

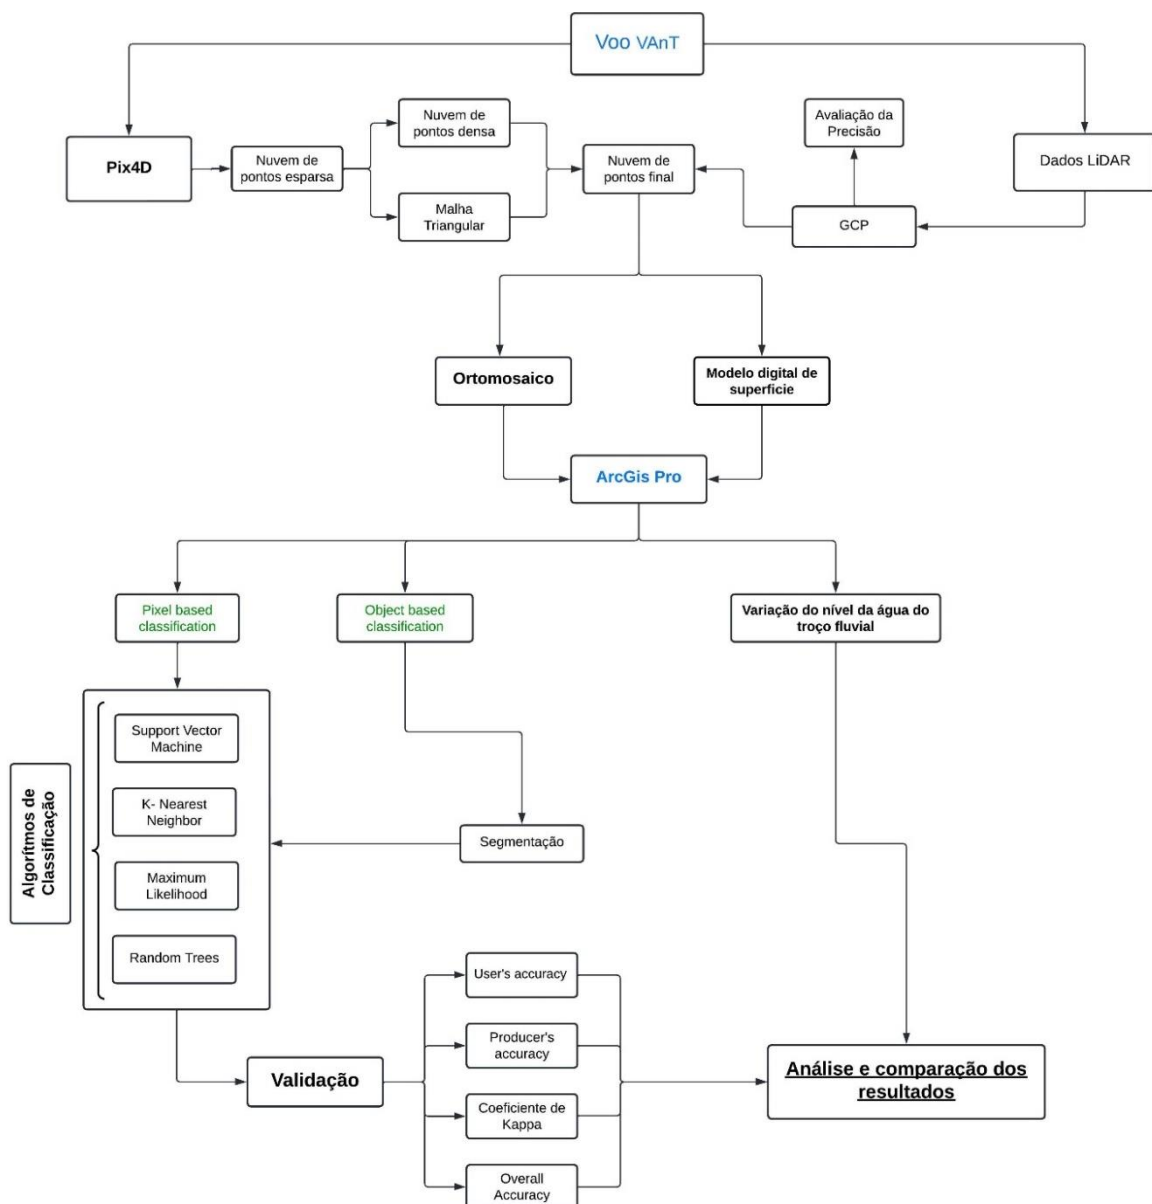


Figura 18 - Fluxo metodológico das várias componentes do trabalho.

4.2 Características dos voos com VAnT

No que diz respeito aos voos com recurso a VAnT, foram realizadas recolhas de dados no troço em estudo, a jusante da barragem de Salamonde, em dois meses distintos: dias 27 e 28 de fevereiro de 2023 e dias 6 e 7 de julho de 2023.

Na primeira recolha de dados, dia 27 de fevereiro às 16 horas, foi realizado um voo com o VAnT DJI Mavic 2 Pro, com um caudal ecológico de 2,68 m³/s. Este equipamento é um VAnT *quadcopter*, ou seja, com quatro motores, que utiliza o sistema de navegação *Global Positioning System* (GPS) e *Global Navigation Satellite System* (GLONASS). Este VAnT pesa cerca de 907 gramas, tem uma bateria de 3950 mAh e uma autonomia de aproximadamente 30 minutos, e está equipado com uma câmara Hasselblad L1D-20c com 20 Megapixels e um sensor CMOS com uma abertura ajustável f/2.8- f/11. Este levantamento, permitiu obter um vídeo com cerca de 16 minutos ao longo dos 1900 m do troço do rio em estudo, no sentido jusante-montante com uma velocidade de 4 m/s, a uma altitude de 90 m e com um ângulo de 90° com a superfície.

No dia 28 de fevereiro, às 11 horas, foi realizado outro levantamento do troço a jusante da barragem em análise, com um caudal ecológico de 2,73 m³/s, utilizando o VAnT DJI Mavic 2 Pro (figura 19). O plano de voo deste levantamento, foi elaborado através da aplicação DJI Pilot, inserida no controlo remoto do VAnT, tendo sido realizado um levantamento com o sistema de navegação por *Waypoints*, ou seja, o VAnT através de coordenadas GPS, opera autonomamente seguindo uma rota ponto a ponto predeterminada. O levantamento, realizou-se ao longo de aproximadamente 7360 m, a uma altitude de 100 m, tendo sido percorridos 95 *Waypoints* a 3,5 m/s, e obtidas 377 fotografias com um ângulo de captura de 90°, com uma sobreposição lateral e frontal padrão de 70 % e 80 %, respetivamente, apresentando uma resolução espacial de 2,5 cm.

Adicionalmente, foi realizado um segundo voo com o VAnT DJI Matrice 300 RTK (figura 19). Por ser um VAnT comercial, pesa cerca de 6,3 kg (com duas baterias), tem um tempo máximo de voo de 55 minutos e um alcance de transmissão de 15 km. Para além disso, oferece um posicionamento cinemático em tempo real (RTK), sendo capaz de atingir uma resolução espacial de 2 cm, e outros sistemas de posicionamento, como o GPS, GLONASS, Galileo, BeiDou. Por permitir que sejam adicionadas cargas até 2,3 kg, é frequentemente complementado com sensores e carga adicional, tendo sido neste trabalho, incorporado um Sensor LiDAR para obter um modelo detalhado da topografia

do trecho do rio analisado e das suas margens. Assim, às 15 horas e com um caudal ecológico de 2,79 m³/s, foi realizado um levantamento para obtenção das imagens LiDAR, com o intuito de melhorar a comparação e futura análise dos dados obtidos em todos os levantamentos. Este voo realizou o mapeamento da área de estudo em 18 minutos, à altitude de 100 m e velocidade de 5 m/s com o sensor posicionado a 90° (nadir).



DJI Mavic 2 Pro



DJI Matrice 300 RTK

Figura 19 - VAnT utilizados na recolha de dados.

Na segunda recolha de dados, em julho, foram realizados três levantamentos e um vídeo da área de estudo com o VAnT DJI Mavic 2 Pro. Devido a um problema técnico com o sensor LiDAR, a recolha de dados, nesta segunda saída, cingiu-se às imagens obtidas pelo VAnT DJI Mavic 2 Pro.

No dia 6 de julho, foram realizados dois levantamentos na área de estudo, às 15 horas e 18 horas, ambos sobre o trecho do rio com um caudal ecológico de 0,37 m³/s. O primeiro voo, efetuado com recurso ao VAnT DJI Mavic 2 Pro, foi planeado novamente através da aplicação DJI Pilot, com as mesmas configurações dos levantamentos efetuados em fevereiro, e com o mesmo sistema de navegação por *Waypoints*, com o objetivo de obter os mesmos *outputs*, mas em alturas do ano diferentes, para fins comparativos. Posto isto, o levantamento realizou-se a uma altitude de cerca de 100 m, tendo sido percorridos 95 *Waypoints* a 3,5 m/s, e obtidas 377 fotografias com um ângulo de captura de 90° e 2,5 cm por *pixel*, ao longo de aproximadamente 7360 m.

Para além disso, em 6 de julho foi também realizado, às 17 horas, um vídeo no sentido jusante-montante do trecho do rio em estudo, com cerca de 16 minutos, a uma altitude de 90 m, uma velocidade de 4 m/s e com a câmara posicionada num ângulo de 90° com a superfície.

Como referido, às 18 horas do dia 6 de julho, efetuou-se outro levantamento com o VAnT DJI Mavic 2 Pro. Ao contrário dos outros levantamentos, este voo foi realizado num setor previamente selecionado, com o objetivo de produzir o melhor ortofoto possível, isto é, minimizando ao máximo os erros derivados da variação na iluminação no leito do rio. Tal como os outros levantamentos, este voo também foi preparado na aplicação DJI Pilot, tendo sido realizado a uma altitude de cerca de 100 m, percorrendo 38 *Waypoints* a 3,5 m/s, e foram obtidas 144 fotografias num ângulo de captura de 90° e com uma resolução de 2,5 cm, ao longo de aproximadamente 3100 m.

No dia 7 de julho, às 9 horas, realizou-se o último levantamento na área de estudo, com um caudal ecológico de 0,36 m³/s, utilizando o VAnT DJI Mavic 2 Pro. Este voo, paralelamente ao levantamento realizado às 18 horas do dia 6 de julho, foi efetuado no mesmo setor e com as mesmas configurações de voo, para que mais uma vez, fosse possível obter posteriormente melhores análises e resultados. Assim, este voo foi novamente realizado a uma altitude de 100 m, ao longo de 38 *Waypoints* e a uma velocidade de 3,5 m/s, tendo sido obtidas 144 fotografias num ângulo de captura de 90° e com 2,5 cm por *pixel*, numa distância de 3100 m.

4.3 Processamento de imagens no Pix4Dmapper

As imagens obtidas em todos os levantamentos efetuados na área de estudo foram processadas no *software* Pix4Dmapper 4.7.5. Este *software* é baseado na deteção automática de características, sobreposição e modelação de imagens utilizando algoritmos SfM (Vieira et al., 2019), sendo possível modelar nuvens de pontos (cenário em 3D), criar ortomosaicos, Modelos Digitais de Superfície (MDS) e Modelos Digitais de Terreno (MDT). O processamento dos modelos no Pix4Dmapper, para a obtenção destes resultados, assenta em três fases: 1 - Processamento inicial; 2 - Nuvem de pontos e malha triangular; 3 - MDS, ortomosaicos e índices espectrais (Freitas, 2018).

Assim, numa primeira fase, as imagens de VAnT são introduzidas no *software*, onde se efetua a sua georreferenciação e ponderação de pontos comuns nos vértices de objetos espaciais de áreas onde se sobrepõem as imagens. Para além disso, é feito o cálculo automático das posições das imagens através da Triangulação Aérea (AAT) e Ajustamento de feixes em Bloco (*Bundle Block Adjustment*, BBA) (Santos et al., 2018).

Por não ter sido utilizado um GPS diferencial para georreferenciar as imagens, foram introduzidos nesta fase do processamento, *Ground Control Points* (GCP) para melhorar a georreferenciação dos ortomosaicos, tendo como referência coordenadas X, Y e Z de alta precisão, provenientes da nuvem de pontos LiDAR obtida pelo voo realizado com o VAnT DJI Matrice 300 RTK, incorporado com o sensor LiDAR. Após a correção da georeferenciação do ortomosaico do levantamento de fevereiro com o auxílio dos dados LiDAR em RTK, recorreu-se a este ortomosaico para criar GCP no ortomosaico do levantamento de julho, e permitir a sua correta e igual georeferenciação. Através do *Quality Report* dos dois levantamentos, criado automaticamente no fim do primeiro processo, verificou-se um erro da raiz do valor quadrático médio (RMS) em ambos os modelos de 0,015 m.

Após a conclusão da primeira fase, o *software* transita de forma automática para a segunda fase do processamento das imagens, sendo densificada a nuvem de pontos, criada uma malha triangular (figura 20) e um modelo 3D que, através da interpolação dos *pixels*, reduz a existência de buracos no modelo (Freitas, 2018).

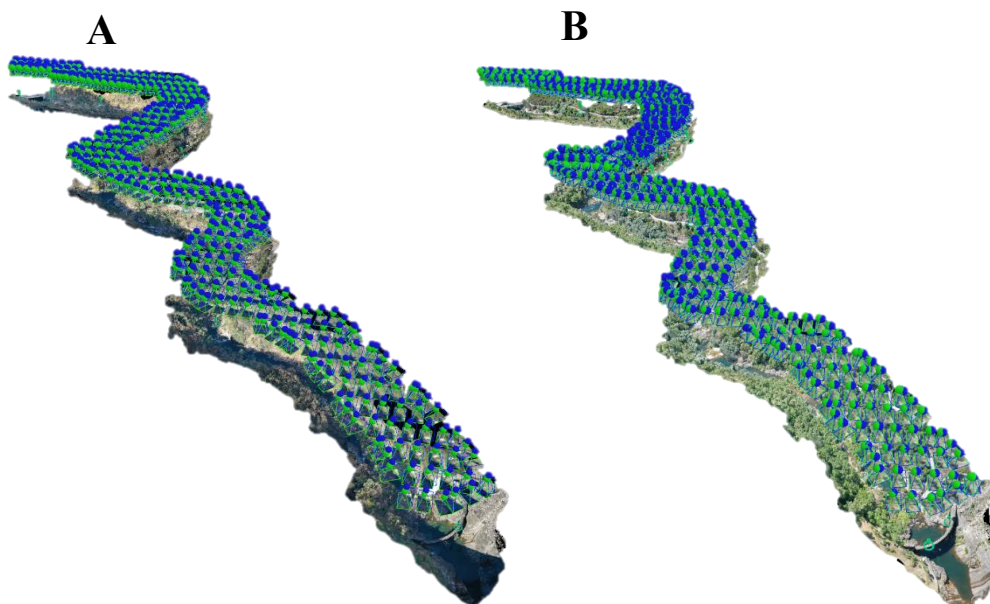


Figura 20 - Resultados do processamento da primeira e segunda fase no Pix4Dmapper, das imagens dos levantamentos de fevereiro (A) e julho (B).

Na terceira fase do processamento das imagens, estes *outputs*, obtidos durante os processos AAT e a BBA anteriores, vão ser utilizados para criar o Modelo Digital de Superfície (MDS) e o Modelo Digital de Terreno (MDT), assim como ortomosaicos e mapas de reflectância. O MDS foi gerado a partir do método de interpolação *Inverse*

Distance Weight (IDW), e através da ligação dos pontos presentes na nuvem, sendo posteriormente criado o ortomosaico a partir da combinação das imagens originais com o MDS (Silva et al. 2014).

4.4 Técnicas de classificação semiautomática de imagens VAnT

Os *outputs* criados pelo Pix4Dmapper, nomeadamente o Ortomosaico e o MDS, foram abertos em *softwares* que permitem a sua visualização e, posteriormente, o desenvolvimento de classificações semiautomáticas com estes dados.

Com o objetivo de reduzir a classificação errada de elementos e a confusão de classes relevantes no troço fluvial com elementos sem interesse para este estudo, como estradas, pontes, entre outros, foi realizado um corte da área de estudo, restringindo o ortomosaico e conseqüentemente todas as classificações desenvolvidas, ao leito do rio (figura 21). Adicionalmente, para facilitar o processamento das classificações, foi realizado um processo de reamostragem (*resample*) do ortomosaico, passando da resolução de 2,5 cm para 10 cm.




Figura 21 - Ortomosaico inicial (A) e ortomosaico cingido ao leito do rio (B).

Segundo Rivas et al. (2015), existem três tipos de técnicas de classificação de imagem: a classificação supervisionada, a classificação não supervisionada e a classificação orientada ao objeto. A classificação de imagens é o processo de extração de classes informativas, como o uso do solo, a partir de imagens com várias bandas, sendo uma tarefa útil para a análise digital de imagens (ESRI, s/d). Assim, foi testada uma abordagem da técnica de classificação semiautomática no *software* ArcGIS Pro 3.2.2.

Em primeiro lugar, para a realização de classificações semiautomáticas neste *software*, foi necessário criar áreas de treino ao longo da área de estudo, através de polígonos de amostragem desenhados sobre áreas homogêneas da imagem, para cada classe criada. Assim, foram definidas 9 classes a partir dos ortofotos: água funda, água rasa, vegetação, sombra na vegetação, fluxo turbulento, rocha clara, rocha, sombra na rocha e sombra na água, e criadas áreas de treino para cada uma destas classes em locais com assinaturas espectrais semelhantes.

Posto isto, foram desenhados 216 polígonos distribuídos ao longo do troço fluvial e pelas classes evidenciadas (figura 22). Foi também necessário criar áreas de treino e áreas de validação a partir daqueles polígonos. Assim, foi assegurado que cada classe possuísse aleatoriamente 50 % dos seus polígonos como áreas de treino e outros 50 % como áreas de validação, registando-se um total de 110 polígonos de treino, e 106 polígonos de validação, correspondendo, para um total de 80 032 m² da área de estudo, 973 m² de área de polígonos de treino, 812 m² de polígonos de validação, e, respetivamente, a 1,2 % e 1 % da área de estudo (quadro 3).

Quadro 3 - Área (m²) e número de *pixels* das áreas de treino e das áreas de validação

Classes	Áreas de Treino		Áreas de Validação	
	Nº de pixels	Área (m ²)	Nº de pixels	Área (m ²)
Água funda	17932	205	16756	192
Água rasa	15193	174	12271	140
Vegetação	9806	112	7783	89
Sombra na vegetação	2910	33	2406	28
Fluxo turbulento	2347	27	2076	24
Rocha clara	9943	107	8932	102
Rocha	17854	204	15562	178
Sombra na rocha	2702	31	2052	24
Sombra na água	6989	80	3146	36

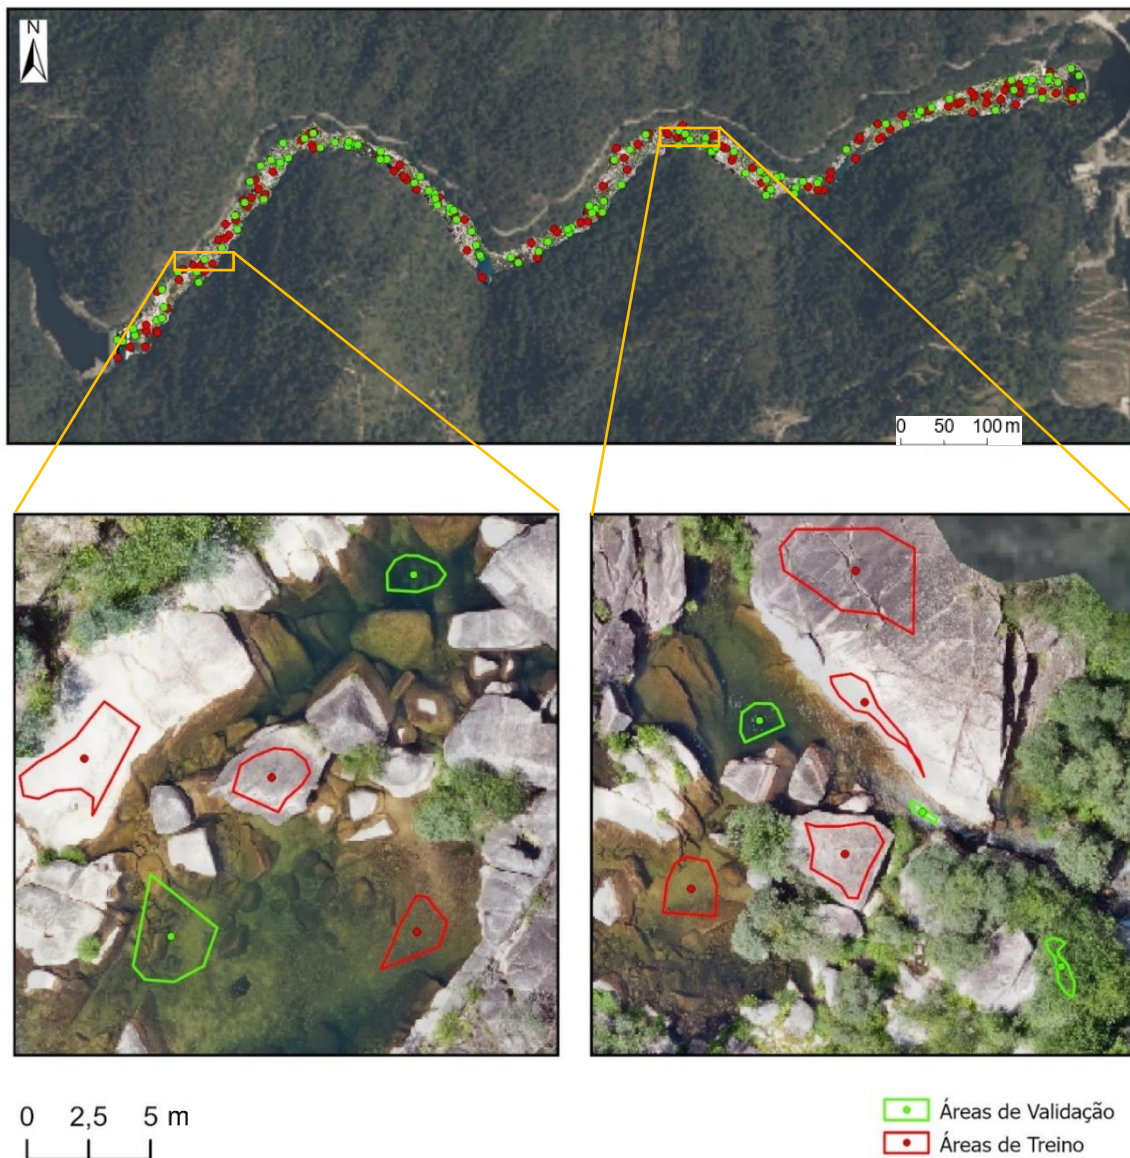


Figura 22 - Distribuição das áreas de treino e das áreas de validação no trecho em estudo.

4.4.1 *Image Classification Wizard*

Após a criação das áreas de treino e de validação, utilizou-se a ferramenta *Classification Wizard* do ArcGIS Pro para realizar a classificação da imagem. Esta ferramenta permite simplificar o processo de classificação, conduzindo o utilizador por todos os passos da classificação, desde a criação de áreas de treino, à escolha dos métodos, técnicas e respetivos algoritmos de classificação (figura 23).

Através desta ferramenta é possível escolher o método de classificação a utilizar, ou o método Não Supervisionado ou o método Supervisionado. No primeiro, não é

necessário um conhecimento prévio do terreno ou fornecer áreas de treino, sendo as classes criadas com base nas diferenças nas características espectrais dos *pixels*, em que são utilizados algoritmos como o ISO-Cluster; o segundo, ao contrário do anterior, depende da utilização de áreas de treino que representem *pixels* ou objetos específicos na imagem, e da sua seleção e divisão em classes, para que sejam utilizados como referência para classificar outros elementos na imagem (Jimoh, 2021).

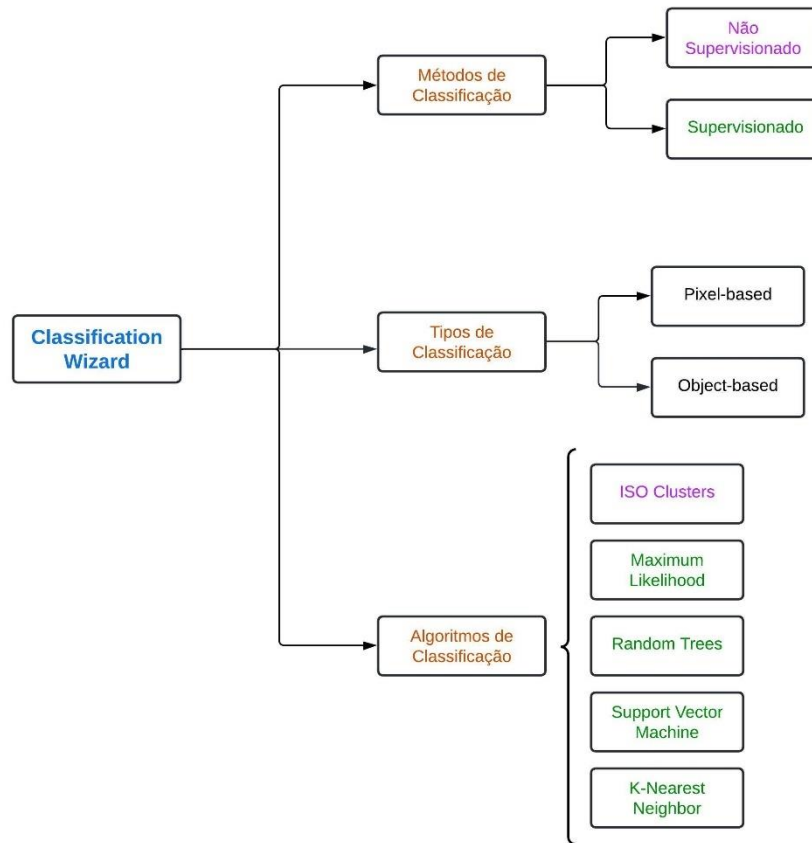


Figura 23 - Estrutura da ferramenta *Classification Wizard* do ArcGIS Pro.

O método de classificação supervisionado no ArcGIS Pro permite escolher qual o tipo de classificação a adotar, isto é, baseada no *pixel* (*Pixel-based*) ou baseada no objeto (*Object-based*). Em todas as classificações supervisionadas foram utilizadas as mesmas áreas de treino para, no final, ser possível fazer uma comparação dos resultados das classificações obtidas.

A classificação *Pixel-based* é realizada *pixel a pixel*, e são as características espectrais de cada *pixel* que determinam a classe a que é atribuído, não sendo tidas em consideração as características dos *pixels* vizinhos (ESRI, s/d). A classificação *Object-*

based oferece algumas vantagens em comparação com a classificação *Pixel-based* (quadro 4), sendo a unidade mínima do processamento de imagem um conjunto de *pixels*, e não um *pixel*, agrupados por um processo denominado segmentação. Assim, um conjunto de *pixels*/objeto numa imagem fornecem consideravelmente mais informações quando comparado com um único *pixel* (Jimoh, 2021).

Quadro 4 - Atributos utilizados em classificações *Pixel-based* e *Object-based*.

	Cor/Espectro	Forma	Área/Tamanho	Textura
Pixel-based	✓	✗	✗	✗
Object-based	✓	✓	✓	✓

A incorporação obrigatória da segmentação neste processo de classificação baseada no objeto, leva à construção uma rede hierárquica de objetos e à sua classificação e delimitação com base nos critérios de homogeneidade, ou seja, objetos e *pixels* vizinhos com informações espectrais, espaciais e outras propriedades como o tamanho, a textura, a forma e a cor semelhantes, são agrupados (Piçarra, 2014).

No *software* ArcGIS Pro existem três parâmetros que controlam a forma como a imagem é segmentada em objetos. O primeiro é o nível de detalhe espectral, que dita o nível de importância que é atribuído às diferenças espectrais nos elementos da imagem. Os valores deste parâmetro variam de 1 a 20, sendo que um valor mais baixo leva a uma maior suavização do detalhe da imagem, e um valor mais elevado leva a uma classificação mais detalhada, útil em áreas onde existem elementos com características espectrais similares, mas que necessitam de ser colocados em classes diferentes. O segundo parâmetro da segmentação é o nível de detalhe espacial, que dita o nível de importância atribuída à proximidade entre elementos na imagem. Assim como o parâmetro anterior, os valores variam de 1 a 20, sendo os valores mais baixos utilizados para criar *outputs* espacialmente mais suaves, e valores mais altos, ideais em áreas onde os elementos a ser classificados, são pequenos e estão agrupados. O terceiro parâmetro da segmentação no ArcGIS Pro refere-se ao tamanho mínimo dos segmentos em *pixels*, com valores de 1 a 9999, onde é feita uma junção dos segmentos que apresentem um tamanho inferior ao colocado, com o segmento adequado mais próximo (ESRI, s/d).

Após vários testes, com diversos valores em cada parâmetro da segmentação, para a área em estudo foi utilizado o valor 20 em ambos os parâmetros detalhe espectral e detalhe espacial, e o valor 30 no parâmetro referente ao tamanho mínimo dos segmentos (figura 24). Esta segmentação foi incorporada no processo de classificação baseada no objeto, e descartada no processo de classificação baseada no *pixel*, sendo esta classificação baseada somente no detalhe espectral (Jimoh, 2021).




Figura 24 - Processo de segmentação no ArcGIS Pro.

4.4.2 Algoritmos de Classificação

Após a escolha do método de classificação, e da criação de áreas de treino e segmentação da imagem, caso se realize uma classificação *Object-based*, a ferramenta *Classification Wizard* indica quatro algoritmos de classificação para a escolha do algoritmo a utilizar: *Support Vector Machine*, *Random Trees*, *Maximum Likelihood* e *K-Nearest Neighbor*. É possível utilizar qualquer um destes algoritmos, independentemente do tipo de classificação escolhida, quer baseada no *pixel* ou no objeto, apesar de ser possível adicionar alguns parâmetros a estes algoritmos, caso se opte por realizar a classificação *Object-based*.

O algoritmo *Support Vector Machine*, é um dos classificadores supervisionados mais populares e utilizados em detecção remota, por proporcionar uma elevada exatidão e bons resultados, em dados com elevada variedade multi-espectral e multi-temporal (Santos, 2021). Este algoritmo tem por objetivo encontrar um hiperplano que permita

separar um conjunto de dados em classes distintas, através de processos iterativos e de áreas de treino que ajustam e adaptam este hiperplano, utilizado como fronteira de decisão (Peixoto, 2016). Neste algoritmo, foi sempre utilizado o valor padrão 1000 no campo do número máximo de amostras por classe.

O algoritmo *Random Trees*, é um classificador supervisionado de elevada precisão, que produz um conjunto de árvores de decisão, baseado num subconjunto aleatório de classes e áreas de treino (Ferreira, 2020). Este algoritmo é construído através do conjunto de árvores de decisão, que ajudam a reduzir o risco de sobreajustamento (*overfitting*) dos dados e erros de cálculo, e melhoram a generalização do modelo, sendo a classificação final deste algoritmo determinada por mecanismos de votação de cada árvore de decisão (Pereira, 2020). Neste algoritmo, foram sempre utilizados os valores padrão de 50 no número máximo de árvores, máxima profundidade da árvore de 30 e o número máximo de amostras por classe de 1000.

O algoritmo *Maximum Likelihood*, ou máxima verosimilhança, é um dos métodos paramétricos tradicionais e um dos algoritmos mais utilizados na classificação supervisionada de imagens (Jimoh, 2021). Este algoritmo é amplamente utilizado, devido à sua simplicidade e robustez no tratamento de *pixels* misturados (Poudel, 2023). Assim, este algoritmo depreende que as estatísticas para cada classe em cada banda seguem uma distribuição normal no cálculo da probabilidade de um determinado *pixel* pertencer a uma classe específica, sendo cada um destes *pixels* atribuído à classe que evidencia maior probabilidade (Saraiva, 2015).

Por fim, o *K-Nearest Neighbor* é um algoritmo não-paramétrico, reconhecido pelos bons resultados na classificação de imagens e por ser fácil de implementar e de computar (Piçarra, 2014). Para além disso, este algoritmo procura classificar os segmentos pela proximidade, medindo a distância entre as observações e aglomerando-as (Pereira, 2020). Esta distância é medida consoante os atributos dos elementos das amostras, como os atributos espaciais, espectrais e de textura. É ainda feito um cálculo dos atributos para todas as classes escolhidas, de modo que estes atributos tenham o mesmo peso na classificação (Piçarra, 2014). Neste algoritmo, foi sempre utilizado o valor padrão 1000 no campo do número máximo de amostras por classe e o valor 1 no campo K vizinhos próximos.

Como referido, caso se escolha realizar uma classificação baseada no objeto, é possível adicionar alguns parâmetros relacionados com os atributos dos segmentos. Os atributos-padrão em todos algoritmos de classificação *Object-based*, são o *Active chromaticity color*, que representa a cromaticidade média de cada segmento na imagem segmentada, e o *Mean digital number*, que consiste no valor médio de brilho em cada *pixel* da imagem (ESRI, s/d). Para além destes parâmetros, existem outros atributos dos segmentos que podem ser seleccionados como: o *Standard Deviation* (desvio padrão), que é uma medida estatística que caracteriza a variabilidade do valor do *pixel* dentro de um segmento da imagem; o *Count of pixels* (contagem de *pixels*), que é um valor que representa o número total de *pixels* existentes num segmento específico da imagem; o *Compactness* (compacidade), que procura quantificar o quão circular ou compacto é um determinado segmento que se encontre na imagem; a *Rectangularity* (retangularidade), que procura quantificar o quão retangular é um determinado segmento que se encontre na imagem (ESRI, s/d).

Tendo em conta as características da área de estudo e alguns testes com a introdução de alguns destes parâmetros na classificação, as classificações baseadas no objeto foram realizadas apenas com a introdução de quatro parâmetros dos atributos dos segmentos, sendo eles os parâmetros *default Active chromaticity color* e *Mean digital number*, e, adicionalmente, os parâmetros *Compactness* e *Rectangularity*.

4.4.3 Processos de validação

A avaliação da exatidão é uma importante componente no processo de construção de classificações semiautomáticas de imagens. Esta avaliação pode ser feita a partir do cruzamento do resultado das classificações com a informação de referência (áreas de validação), o que permite calcular matrizes de erro ou confusão. A partir destas matrizes de confusão pode ser calculado o índice de exatidão do utilizador (*user's accuracy*), o índice de exatidão do produtor (*producer's accuracy*), o índice de exatidão global (*overall accuracy*) e o coeficiente de Kappa (Palma, 2012).

Assim, após a conclusão de todas as classificações *Pixel-based*, através dos quatro algoritmos enunciados, e das classificações *Object-based*, com recurso aos quatro algoritmos referidos, mais os quatro parâmetros adicionais dos atributos dos segmentos, foi utilizada a ferramenta *Tabulate Area* do ArcGIS Pro. Através desta ferramenta foi feito

o cruzamento de cada uma das classificações obtidas, com as áreas de validação, sendo as matrizes de confusão obtidas, exportadas para um documento Excel.

Posto isto, a avaliação da exatidão da classificação de cada classe foi efetuada com recurso à exatidão do produtor e à exatidão do utilizador. A exatidão do produtor (*EP*) compara, por classe, as áreas classificadas corretamente e o peso que representam no mapa de referência (Martins, 2021). A exatidão do utilizador (*EU*) indica a capacidade para classificar corretamente uma determinada classe, isto é, apresenta a razão entre os *pixels* bem classificados e o total de *pixels* classificados (Pinto, 2020). Segundo Martins (2012) estes índices podem ser calculados, respetivamente, pelas seguintes fórmulas:

$$EP_j = \frac{X_{jj}}{n_{i+}} ; EU_j = \frac{X_{jj}}{n_{i+}}$$

onde:

X_{jj} = número de observações da amostra de validação classificadas na classe j do mapa e que corresponde à classe j na informação de referência;

n_{i+} = total de observações da amostra de validação classificadas no mapa com a classe i ;

n_{+i} = total de observações da amostra de validação pertencentes à classe i .

Para avaliar a exatidão da classificação de cada classe, foram ainda calculados o índice de exatidão global e o coeficiente Kappa. O índice de exatidão global diz respeito à concordância entre os dados utilizados para treino e os dados utilizados para validação, sendo demonstrado o grau de confiança da classificação de todas as classes. Este índice calcula-se através da razão entre o número de *pixels* bem classificados e o número total de *pixels* avaliados (Pinto, 2020). Segundo Martins (2012) este índice pode ser calculado pela seguinte fórmula:

$$EG = \frac{\sum X_i}{N} * 100,$$

onde X_i corresponde aos elementos na diagonal e N ao total de amostras.

Um índice alternativo para avaliar a qualidade da classificação é o Coeficiente Kappa, que é uma técnica multivariada discreta usada na avaliação da exatidão temática, que avalia a concordância real entre a classificação e os dados de referência (Martins, 2012). Este índice permite ainda avaliar se a concordância entre a classificação e os dados de referência é melhor do que numa classificação aleatória, apresentando-se como uma

medida de avaliação rigorosa, na medida em que conta com toda a informação existente na matriz de confusão e não só com a informação contida na diagonal principal (Crisógono, 2011). O Coeficiente de Kappa (K) é calculado pela seguinte fórmula:

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} x_{+i}}{N^2 - \sum_{i=1}^c x_{i+} x_{+i}},$$

onde:

N = número total de observações;

r = número de linhas da matriz de confusão;

x_{ii} = observações na linha i e coluna i ;

x_{i+} = total marginal da linha i ;

x_{+i} = total marginal da coluna i .

O Coeficiente Kappa pode ter valores entre -1 e 1, sendo que maior que 0 indica algum grau de concordância entre os valores e 1 indica uma concordância perfeita. Landis e Koch (1997) desenvolveram uma escala empírica para o índice, onde fazem a correspondência de intervalos de Kappa e os níveis de concordância (quadro 5).

Quadro 5 - Interpretação dos valores do Coeficiente de Kappa (Extraído de Crisógono, 2011, pag. 43).

Valores de Kappa	Níveis de concordância
< 0	Ausente
]0.0, 0.20[Baixo
[0.20, 0.40[Razoável
[0.40, 0.60[Moderado
[0.60, 0.80[Substancial
[0.80, 1.00[Quase perfeito
= 1	Perfeito

5. Resultados

No que diz respeito aos resultados deste trabalho, foram divididos por quatro secções: (1) a primeira descreve os resultados de todas as classificações baseadas no *pixel*, utilizando quatro algoritmos em conjunto com quatro métricas de validação, para analisar e comparar os resultados dos algoritmos de classificação; (2) a segunda descreve os resultados das classificações baseadas no objeto, comparando os resultados dos quatro algoritmos de classificação, utilizados em conjunto com quatro parâmetros dos atributos da segmentação diferentes, e respectivas métricas de validação utilizadas para analisar e comparar o desempenho de cada um destes algoritmos; (3) na terceira secção procura-se analisar e comparar a melhor classificação baseada no *pixel* e a melhor classificação baseada no objeto, com o objetivo de definir, através da análise das métricas de validação utilizadas, a melhor classificação conseguida; (4) na quarta secção são feitas algumas estimativas da variação espacial do nível da água no troço fluvial, e providenciadas algumas informações sobre o cálculo do volume de água em cada local do leito a partir das alturas de água registadas.

É importante referir que todas as classificações semiautomáticas deste trabalho, foram produzidas através do ortomosaico derivado do levantamento efetuado no dia 6 de julho de 2023 às 15 horas, por ter sido o levantamento completo do troço fluvial em análise, onde se verifica a menor presença de sombras e de erros associados a este e outros fatores, no leito do rio em estudo.

5.1 Classificações *Pixel-based*

Para efetuar a análise e comparação das classificações *Pixel-based* realizadas, foram escolhidos três setores ao longo do troço fluvial em análise, permitindo uma visualização mais simplificada e detalhada dos elementos do troço classificados (figura 25).

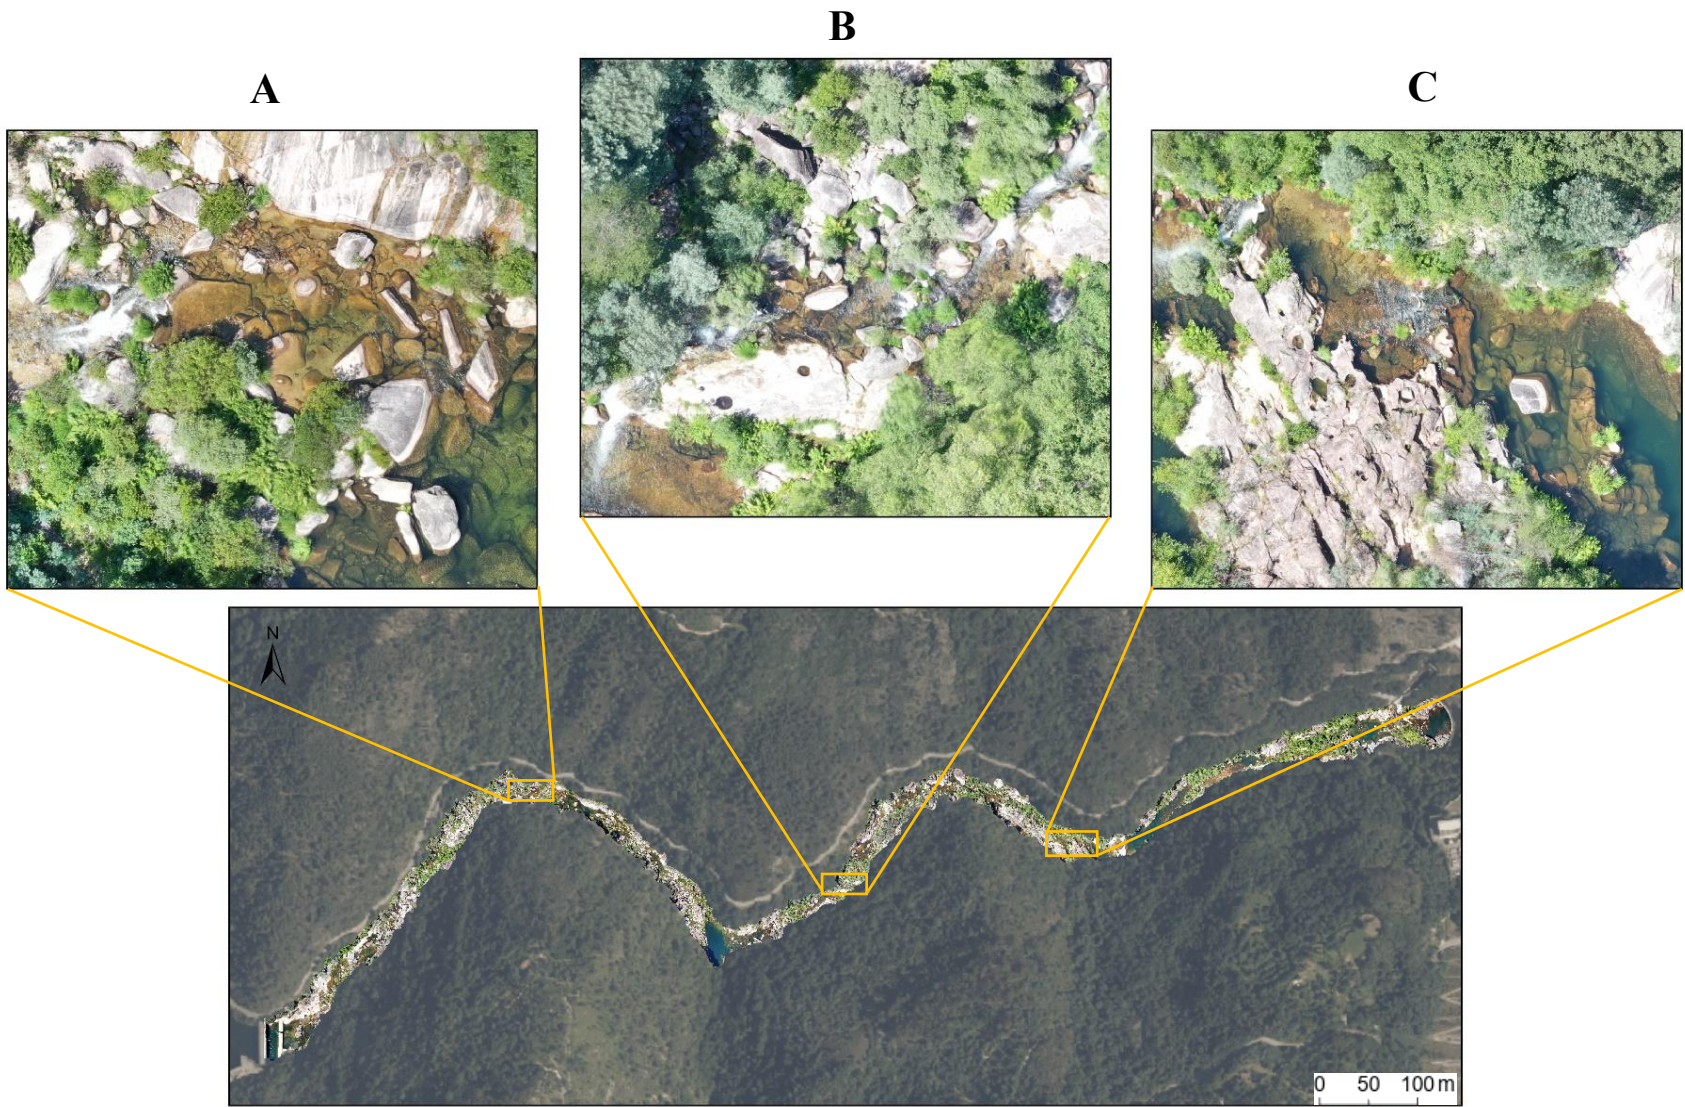


Figura 25 - Localização dos setores utilizados para a análise visual das classificações *Pixel-based*.

Através da análise e comparação visual dos resultados das classificações nos três setores da figura 26, é possível verificar que todos os algoritmos foram capazes de produzir classificações com resultados satisfatórios, apesar de existir sempre alguma confusão entre classes como o fluxo turbulento e a rocha clara, que faz com que algumas classificações, como a produzida pelo algoritmo *Maximum Likelihood* (ML), fossem incapazes de identificar fluxos turbulentos nestes três setores. Existem também alguns problemas associados à confusão entre as classes das sombras, sendo evidente o problema característico das classificações baseadas no *pixel*, chamado efeito *Salt and Pepper* (*pixels* isolados ou pequenos aglomerados com algum erro de processamento associado, que assumem ou o valor de intensidade máximo de 255 ou o valor mínimo de 0), e que está presente, em algum grau, em todas as classificações *Pixel-based* realizadas.

No entanto, em regra geral, os algoritmos foram capazes de classificar corretamente as classes da água funda, água rasa, rocha e vegetação, e alguns algoritmos como o SVM e o *Random Trees* (RT), com resultados bastante satisfatórios na classificação de classes com valores espectrais muito parecidos, tendo sido classificados corretamente a maioria dos fluxos turbulentos presentes nestes setores.

Apesar da importância da avaliação e comparação visual dos resultados, para efetivamente se verificar a qualidade do algoritmo na classificação baseada no *pixel* do trecho fluvial, foi necessário recorrer a métricas de validação, que quantifiquem o respectivo desempenho, em cada classe, nas diversas classificações (quadro 6 e quadro 7).




Figura 26 - Setores em detalhe dos quatro algoritmos de classificação *Pixel-based*.

Quadro 6 - Exatidão Global e Coeficiente Kappa das classificações *Pixel-based*.

PIXEL BASED		
	Exatidão Global	Kappa
Support vector machine	0,92	0,9
Random Trees	0,84	0,81
Maximum Likelihood	0,89	0,87
K-Nearest Neighbors	0,82	0,78

Quadro 7 - Valores de Exatidão do Produtor (EP) e Exatidão do Utilizador (EU) das classificações *Pixel-based*.

PIXEL BASED														
Exatidão do Produtor & Exatidão do Utilizador														
		Água funda	Água rasa	Vegetação	Sombra na vegetação	Fluxo turbulento	Rocha clara	Rocha	Sombra na rocha	Sombra na água	Mínimo	Máximo	Média	Desvio Padrão
Support vector machine	EP	0,92	0,99	0,99	0,96	0,82	0,78	0,94	0,98	0,86	0,78	0,99	0,91	0,08
	EU	1,00	0,99	0,92	0,61	0,41	0,91	0,98	0,77	0,99	0,41	1,00	0,84	0,21
Random Trees	EP	0,79	0,86	0,95	0,90	0,63	0,77	0,94	0,93	0,55	0,55	0,95	0,81	0,14
	EU	0,92	0,96	0,92	0,38	0,39	0,86	0,98	0,61	0,71	0,38	0,98	0,75	0,24
Maximum Likelihood	EP	0,89	0,91	0,96	0,92	0,24	0,93	0,96	0,96	0,54	0,24	0,96	0,81	0,25
	EU	0,96	0,96	0,92	0,54	0,54	0,83	0,98	0,59	0,95	0,54	0,98	0,81	0,19
K-Nearest Neighbors	EP	0,75	0,82	0,92	0,89	0,58	0,78	0,93	0,85	0,54	0,54	0,93	0,78	0,14
	EU	0,93	0,95	0,85	0,31	0,38	0,83	0,98	0,57	0,85	0,31	0,98	0,74	0,25
Mínimo		0,75	0,82	0,85	0,31	0,24	0,77	0,93	0,57	0,54				
Máximo		1,00	0,99	0,99	0,96	0,82	0,93	0,98	0,98	0,99				
Média		0,89	0,93	0,93	0,69	0,50	0,84	0,96	0,78	0,75				
Desvio Padrão		0,08	0,06	0,04	0,26	0,18	0,06	0,02	0,17	0,19				

Analisando os resultados das quatro métricas de validação, calculadas a partir da matriz de confusão proveniente do cruzamento de cada uma das classificações obtidas com as áreas de validação, no quadro 6, é possível verificar uma clara tendência para o algoritmo SVM apresentar os melhores resultados de precisão, com valores de Kappa e exatidão global de 0,90 e 0,92 respetivamente, integrando o nível de classificação quase perfeita do quadro 5. No entanto, e tendo em conta estes métodos de validação, os outros classificadores também se mostraram capazes na elaboração de classificações baseadas no *pixel*, proporcionando em regra geral, bons resultados.

A utilização dos métodos de validação de exatidão do produtor (EP) e exatidão do utilizador (EU) (quadro 7) permitiram complementar a análise visual feita anteriormente. Os valores de precisão mais elevados foram registados nas classificações do algoritmo SVM, com média de valores de EP de 0,91 e EU de 0,84. No entanto, através da análise do quadro 7, é possível comparar o desempenho de cada um dos algoritmos na classificação de cada uma das nove classes. Assim, destaca-se a classificação quase perfeita das classes designadas como rocha, água rasa, água funda e vegetação, nas classificações de todos os algoritmos. Foram registados piores resultados e um maior desvio padrão, nas classes das sombras, que por representarem os locais com água,

vegetação e rocha à sombra, podem ser bastante desafiadoras para os classificadores, tendo sido inicialmente separada em três classes para precisamente os testar, assim como, a classe do fluxo turbulento onde se verificam os valores mais baixos de todas as classes, indo ao encontro do que foi referido na breve prospeção visual realizada anteriormente, registando o valor mais baixo no EP do classificador ML, com um valor de 0,24.

5.2 Classificações *Object-based*

Para efetuar a análise e comparação das classificações *Object-based* realizadas, foram novamente utilizados os três setores escolhidos ao longo do troço fluvial (figura 25), para permitir uma visualização mais simplificada e detalhada dos elementos do troço classificados. Ao contrário das classificações *Pixel-based*, as anteriores necessitam de uma segmentação para efetuar o processo de classificação, o que permite adicionar vários parâmetros aos atributos desta segmentação. Assim, foram realizadas classificações *Object-based* com recurso aos quatro algoritmos já apresentados, com quatro diferentes atributos da segmentação adicionados (quadro 8), tendo sido analisados e comparados em cada um dos três setores escolhidos, os resultados das classificações dos algoritmos com os respetivos atributos da segmentação, que apresentaram os valores mais elevados do Coeficiente Kappa e exatidão global, nomeadamente o SVM (ACC+MDN), o RT (ACC+MDN+COMP+RECT), ML (ACC+MDN) e KNN (ACC+MDN) (quadro 11).

Quadro 8 - Designações dos algoritmos de classificação e atributos da segmentação utilizados.

Support Vector Machine	SVM
Random Trees	RT
Maximum Likelihood	ML
K-Nearest Neighbor	KNN
Active chromaticity color + Mean digital number	ACC+MDN
Active chromaticity color + Mean digital number + Compactness	ACC+MDN+COMP
Active chromaticity color + Mean digital number + Compactness + Rectangularity	ACC+MDN+COMP+RECT
Active chromaticity color + Mean digital number + Rectangularity	ACC+MDN+RECT




Figura 27 - Setores em detalhe dos quatro melhores algoritmos e atributos da segmentação das classificações *Object-based*.

A prospeção visual realizada nos resultados obtidos pelos classificadores e respectivos parâmetros de segmentação (figura 27), aparentam um melhor desempenho na classificação baseada no objeto efetuada neste troço fluvial. Este tipo de classificação faz com que o efeito *Salt and Pepper* verificado nas classificações *Pixel-based* seja extinto, sendo possível verificar uma maior exatidão e menores erros visuais nos resultados destas classificações. Assim, verifica-se a correta identificação de elementos difíceis de classificar, com características espectrais semelhantes, como o fluxo turbulento em que é feita a classificação correta desta classe em todos os classificadores, à exceção da sua excessiva identificação e confusão com a classe da rocha clara em alguns setores classificados pelos algoritmos e atributos de segmentação RT (ACC+MDN+COMP+RECT) e KNN (ACC+MDN). Regra geral, foi feita uma correta identificação de todas as classes à exceção de alguns algoritmos que tiveram alguma dificuldade em classificar corretamente o fluxo turbulento referido, e em conseguir diferenciar os três tipos de classes de sombra. Visualmente, os algoritmos e atributos de segmentação SVM (ACC+MDN) e ML (ACC+MDN), parecem produzir as classificações onde se registam os melhores resultados, com a classificação quase perfeita de todos os elementos da imagem.

Para se verificar qual o algoritmo que apresentou melhores resultados na classificação baseada nos objetos do troço fluvial, foram utilizadas quatro métricas de validação, para quantificar o desempenho de cada algoritmo e atributos da segmentação, e o desempenho de cada classe nas diversas classificações (quadro 9, quadro 10 e quadro 11).

O primeiro método de validação utilizado para avaliar a exatidão dos resultados obtidos pelas classificações *Object-based*, foi o EP (quadro 9). Através da análise deste método, é possível verificar que a classificação obtida pelo algoritmo e atributos de segmentação SVM (ACC+MDN), foi a que apresentou a média dos valores de exatidão do produtor mais elevada, com 0,85. À exceção do algoritmo e atributos de segmentação RT (ACC+MDN+COMP+RECT), os algoritmos com melhores resultados, foram os que utilizaram os parâmetros de segmentação *default*, ou seja, o ACC+MDN. Para além disso, é importante realçar a classificação quase perfeita da classe da vegetação e da rocha, em todos os classificadores utilizados, tendo sido registada uma média de valores de EP nestas classes de 0,96 e 0,97 respetivamente, e os menores desvios padrões de todas as classes, de 0,3 na classe da vegetação e sem variação significativa na classe da rocha

registrando um desvio padrão de 0. No entanto, verifica-se novamente a dificuldade em classificar corretamente as classes dos fluxos turbulentos e rocha clara, existindo uma confusão entre estas classes com características espectrais idênticas, e na classe de identificação da sombra na água, tendo sido as classes mais mal classificadas com valores de exatidão do produtor de 0,50 em ambas as classes de fluxo turbulento e sombra na água, e onde se verificou a maior média de desvio padrão registrado na classe da rocha clara (0,29), e com o valor de EP (0,22) mais baixo, na classe da rocha clara do algoritmo e atributos de segmentação ML (ACC+MDN+COMP).

Quadro 9 - Valores de exatidão do produtor (EP) das classificações *Object-based*.

OBJECT BASED													
Exatidão do Produtor													
	Água funda	Água rasa	Vegetação	Sombra na vegetação	Fluxo turbulento	Rocha clara	Rocha	Sombra na rocha	Sombra na água	Mínimo	Máximo	Média	Desvio Padrão
SVM (ACC+MDN)	0,92	0,94	0,97	0,92	0,47	0,95	0,98	0,90	0,62	0,47	0,98	0,85	0,18
SVM (ACC+MDN+COMP)	0,91	0,95	0,97	0,93	0,34	0,97	0,97	0,90	0,61	0,34	0,97	0,84	0,22
SVM (ACC+MDN+COMP+RECT)	0,92	0,94	0,96	0,90	0,67	0,33	0,98	0,95	0,62	0,33	0,98	0,81	0,22
SVM (ACC+MDN+RECT)	0,91	0,94	0,97	0,92	0,33	0,68	0,97	0,91	0,53	0,33	0,97	0,80	0,23
RT (ACC+MDN)	0,83	0,88	0,92	0,83	0,28	0,97	0,96	0,73	0,46	0,28	0,97	0,76	0,24
RT (ACC+MDN+COMP)	0,82	0,90	0,93	0,83	0,28	0,97	0,97	0,78	0,44	0,28	0,97	0,77	0,24
RT (ACC+MDN+COMP+RECT)	0,83	0,95	0,94	0,81	0,28	0,94	0,97	0,73	0,46	0,28	0,97	0,78	0,24
RT (ACC+MDN+RECT)	0,83	0,91	0,90	0,84	0,28	0,97	0,97	0,74	0,46	0,28	0,97	0,77	0,24
ML (ACC+MDN)	1,00	0,87	0,99	0,91	0,60	0,60	0,97	0,92	0,45	0,45	1,00	0,81	0,21
ML (ACC+MDN+COMP)	1,00	0,89	0,99	0,91	0,60	0,22	0,97	0,91	0,44	0,22	1,00	0,77	0,28
ML (ACC+MDN+COMP+RECT)	1,00	0,89	0,99	0,90	0,59	0,30	0,97	0,91	0,44	0,30	1,00	0,78	0,26
ML (ACC+MDN+RECT)	1,00	0,89	0,99	0,91	0,59	0,38	0,97	0,88	0,47	0,38	1,00	0,79	0,24
KNN (ACC+MDN)	0,86	0,82	0,99	0,90	0,71	0,95	0,97	0,76	0,56	0,56	0,99	0,84	0,14
KNN (ACC+MDN+COMP)	0,86	0,84	0,96	0,90	0,70	0,95	0,97	0,76	0,46	0,46	0,97	0,82	0,16
KNN (ACC+MDN+COMP+RECT)	0,86	0,80	0,95	0,87	0,73	0,94	0,97	0,78	0,51	0,51	0,97	0,82	0,14
KNN (ACC+MDN+RECT)	0,86	0,83	0,94	0,90	0,58	0,94	0,98	0,78	0,43	0,43	0,98	0,80	0,18
Mínimo	0,82	0,80	0,90	0,81	0,28	0,22	0,96	0,73	0,43				
Máximo	1,00	0,95	0,99	0,93	0,73	0,97	0,98	0,95	0,62				
Média	0,90	0,89	0,96	0,89	0,50	0,75	0,97	0,83	0,50				
Desvio Padrão	0,07	0,05	0,03	0,04	0,17	0,29	0,00	0,08	0,07				

O segundo método de validação utilizado para avaliar a exatidão dos resultados obtidos pelas classificações *Object-based*, foi o EU (quadro 10). Através da análise deste método, é possível verificar que a classificação obtida pelo algoritmo e atributos de segmentação SVM (ACC+MDN), foi a que apresentou, à semelhança com o EP, a média dos valores de exatidão do utilizador mais elevados, registrando um valor de 0,87. Os melhores resultados dentro de cada algoritmo foram diferentes em alguns classificadores, isto é, os algoritmos SVM e KNN registaram melhores resultados com a incorporação dos atributos de segmentação *default* ACC+MDN, e a classificação com melhores

resultados dentro dos algoritmos RT e ML, foi a que utilizou os parâmetros dos atributos de segmentação ACC+MDN+RECT.

Posto isto, é importante realçar a classificação quase perfeita da classe da água rasa e da vegetação, em todos os classificadores utilizados, tendo sido registada uma média de valores de EU nestas classes de 0,96, e dos mais baixos desvios padrões registados, de 0,01 na classe da água rasa e 0,03 na classe da vegetação. É possível verificar novamente a dificuldade em classificar corretamente as classes dos fluxos turbulentos e dos diversos tipos de sombra. Estas foram as classes mais mal classificadas, com valores médios de exatidão do utilizador de 0,57 na classe da sombra na rocha (sendo também nesta classe registado o valor de EU mais baixo (0,28), no algoritmo e atributos de segmentação RT (ACC+MDN+COMP+RECT)), e 0,60 na classe da sombra na vegetação. Este acontecimento pode ser explicado por serem regiões essencialmente opacas e com pouca informação espectral, o que dificulta a classificação e diferenciação entre as três classes de sombra. A classificação incorreta da classe fluxo turbulento em alguns classificadores pode ser explicada pela sobre-exposição solar, que leva, por vezes, a que alguns elementos como fluxos turbulentos, rochas com maior erosão e vegetação mais clara e seca, apareçam nos ortomosaicos com uma cor quase branca, dificultando o trabalho do classificador e consequentemente reduzindo a qualidade dos resultados obtidos.

Quadro 10 - Valores de exatidão do utilizador (EU) das classificações *Object-based*.

OBJECT BASED													
Exatidão do Utilizador													
	Água funda	Água rasa	Vegetação	Sombra na vegetação	Fluxo turbulento	Rocha clara	Rocha	Sombra na rocha	Sombra na água	Mínimo	Máximo	Média	Desvio Padrão
SVM (ACC+MDN)	0,93	0,98	0,99	0,55	0,85	0,91	0,96	0,73	0,91	0,55	0,99	0,87	0,14
SVM (ACC+MDN+COMP)	0,93	0,98	1,00	0,54	0,96	0,88	0,96	0,70	0,91	0,54	1,00	0,87	0,15
SVM (ACC+MDN+COMP+RECT)	0,94	0,98	0,99	0,55	0,37	0,89	0,79	0,70	0,92	0,37	0,99	0,79	0,21
SVM (ACC+MDN+RECT)	0,92	0,98	0,99	0,50	0,38	0,84	0,88	0,70	0,92	0,38	0,99	0,79	0,22
RT (ACC+MDN)	0,90	0,96	0,95	0,63	0,74	0,89	0,94	0,29	0,77	0,29	0,96	0,79	0,22
RT (ACC+MDN+COMP)	0,92	0,95	0,96	0,65	0,71	0,89	0,94	0,29	0,78	0,29	0,96	0,79	0,22
RT (ACC+MDN+COMP+RECT)	0,95	0,95	1,00	0,63	0,61	0,88	0,94	0,28	0,78	0,28	1,00	0,78	0,23
RT (ACC+MDN+RECT)	0,91	0,95	0,99	0,63	0,84	0,89	0,94	0,29	0,77	0,29	0,99	0,80	0,22
ML (ACC+MDN)	0,90	0,96	0,97	0,70	0,59	0,94	0,83	0,71	0,94	0,59	0,97	0,84	0,14
ML (ACC+MDN+COMP)	0,91	0,96	0,96	0,70	0,59	0,89	0,70	0,69	0,95	0,59	0,96	0,82	0,15
ML (ACC+MDN+COMP+RECT)	0,92	0,96	0,96	0,70	0,58	0,89	0,72	0,69	0,95	0,58	0,96	0,82	0,14
ML (ACC+MDN+RECT)	0,91	0,96	0,97	0,70	0,88	0,91	0,72	0,72	0,93	0,70	0,97	0,85	0,11
KNN (ACC+MDN)	0,87	0,97	0,92	0,61	0,84	0,94	0,98	0,56	0,56	0,56	0,98	0,81	0,18
KNN (ACC+MDN+COMP)	0,88	0,95	0,92	0,55	0,83	0,94	0,98	0,57	0,51	0,51	0,98	0,79	0,19
KNN (ACC+MDN+COMP+RECT)	0,86	0,95	0,91	0,55	0,84	0,92	0,98	0,58	0,50	0,50	0,98	0,79	0,19
KNN (ACC+MDN+RECT)	0,87	0,95	0,95	0,44	0,81	0,97	0,94	0,56	0,75	0,44	0,97	0,80	0,19
Mínimo	0,86	0,95	0,91	0,44	0,37	0,84	0,70	0,28	0,50				
Máximo	0,95	0,98	1,00	0,70	0,96	0,97	0,98	0,73	0,95				
Média	0,91	0,96	0,96	0,60	0,71	0,90	0,89	0,57	0,80				
Desvio Padrão	0,03	0,01	0,03	0,08	0,18	0,03	0,10	0,18	0,16				

Quadro 11 - Coeficiente Kappa e exatidão global das classificações *Object-based*.

OBJECT BASED		
	Exatidão Global	Kappa
SVM (ACC+MDN)	0,92	0,9
SVM (ACC+MDN+COMP)	0,91	0,9
SVM (ACC+MDN+COMP+RECT)	0,85	0,82
SVM (ACC+MDN+RECT)	0,87	0,85
RT (ACC+MDN)	0,86	0,83
RT (ACC+MDN+COMP)	0,87	0,84
RT (ACC+MDN+COMP+RECT)	0,87	0,85
RT (ACC+MDN+RECT)	0,86	0,84
ML (ACC+MDN)	0,88	0,85
ML (ACC+MDN+COMP)	0,83	0,8
ML (ACC+MDN+COMP+RECT)	0,84	0,81
ML (ACC+MDN+RECT)	0,85	0,82
KNN (ACC+MDN)	0,88	0,86
KNN (ACC+MDN+COMP)	0,87	0,86
KNN (ACC+MDN+COMP+RECT)	0,87	0,84
KNN (ACC+MDN+RECT)	0,87	0,85

O terceiro e quarto métodos de validação dos resultados obtidos pelas classificações do ortomosaico, foram a exatidão global e o Coeficiente Kappa. Através da análise dos valores destes dois métodos de validação (quadro 11), é possível verificar que todos os algoritmos e respectivos atributos de segmentação produziram resultados com nível de classificação satisfatório, ou seja, acima de 0,80. No entanto, os resultados obtidos pela validação dos resultados através destes dois métodos revelam uma evidente superioridade do algoritmo e atributos de segmentação SVM (ACC+MDN), em relação aos outros classificadores, com valores de Kappa e exatidão global de 0,90 e 0,92, respetivamente. Para além disso, é importante realçar a clara tendência dos valores mais elevados destes dois métodos de validação, se encontrarem em algoritmos com os atributos de segmentação padrão, ou seja, os atributos ACC+MDN, sendo o algoritmo e atributos de segmentação RT (ACC+MDN+COMP+RECT) o único caso onde não foi verificada esta tendência.

5.3 Melhor classificação *Pixel-based* e *Object-based*

Neste subcapítulo é feita a análise e comparação da melhor classificação *Pixel-based* e *Object-based*, de acordo com os resultados obtidos nos subcapítulos anteriores. Através desta análise, é definido qual o classificador e tipo de classificação em que se verificam os melhores resultados, e o que foi mais eficaz na caracterização e classificação dos elementos da área de estudo. Para isso, foram novamente utilizados os três setores em detalhe do troço fluvial (figura 25), para permitir uma visualização mais simplificada e detalhada dos resultados da melhor classificação *Pixel-based* (*Support Vector Machine*) e *Object-based* (SVM (ACC+MDN)). A escolha da melhor classificação é feita a partir da prospeção visual de ambas as classificações e pela análise e comparação dos resultados obtidos pelas métricas de validação utilizadas anteriormente.

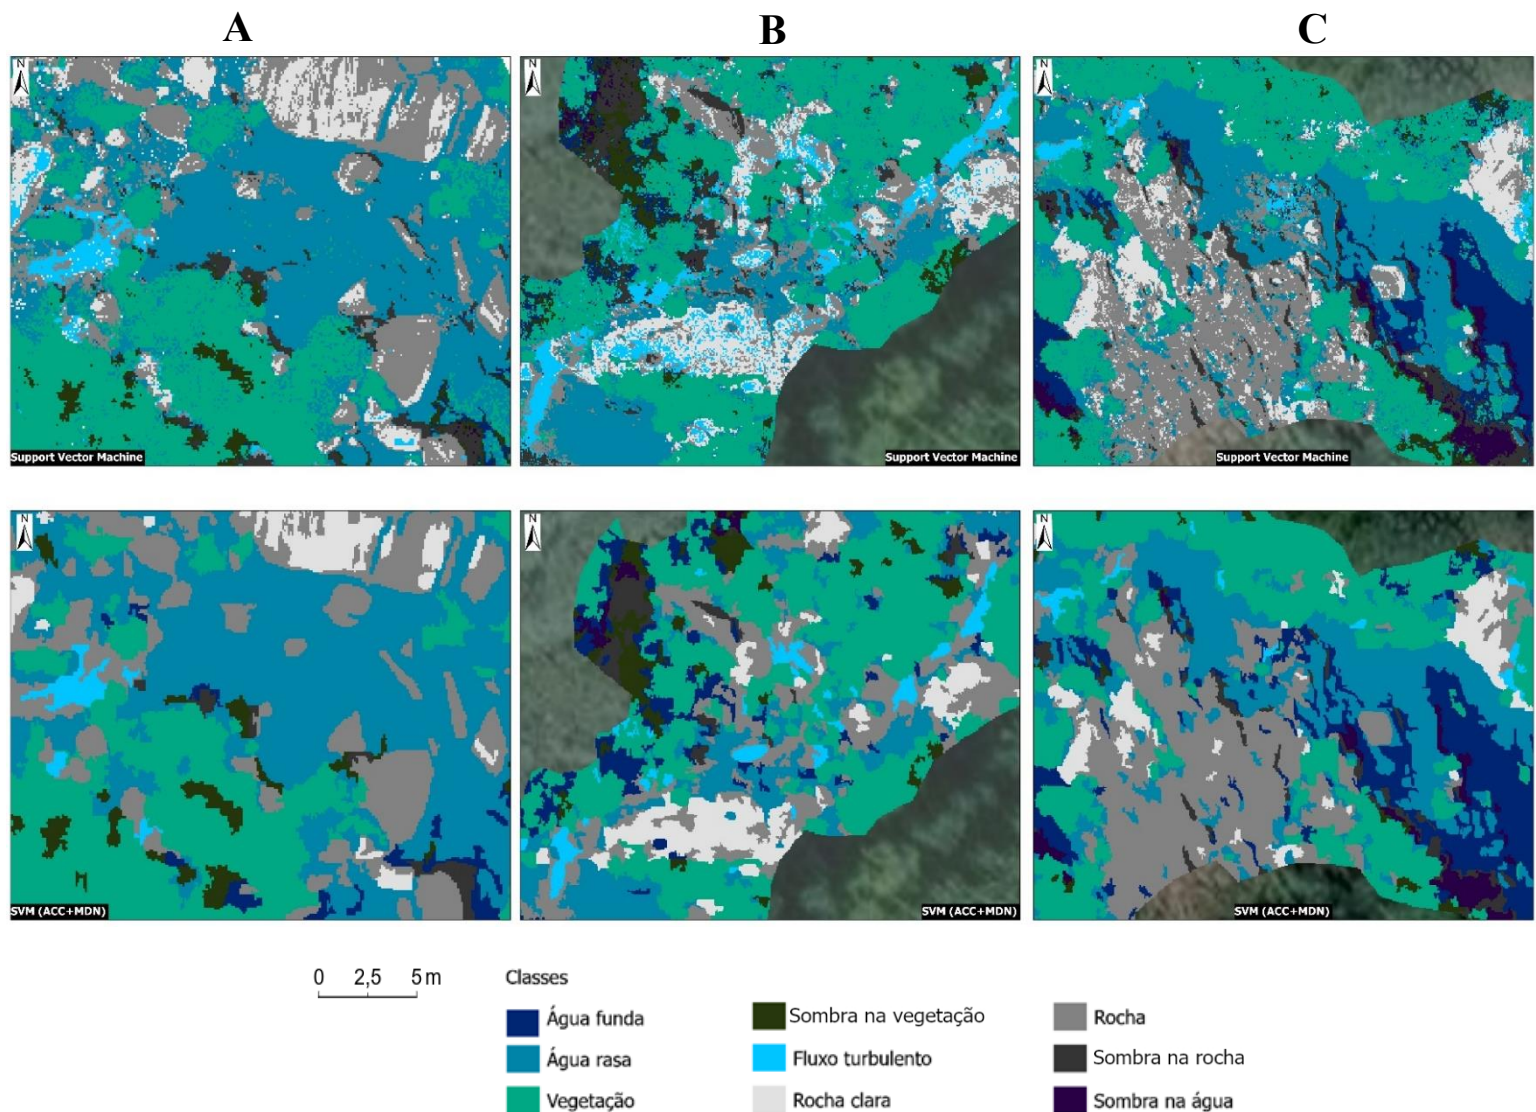


Figura 28 - Setores em detalhe da melhor classificação *Pixel-based* e *Object-based*.

A primeira análise a partir da prospeção visual das classificações nos três setores em detalhe, revela um excelente desempenho de ambos os algoritmos na correta classificação dos elementos na imagem. Através da análise dos três setores da figura 28, é possível verificar que ambos os classificadores fizeram um ótimo trabalho em classificar a maioria dos elementos do leito do rio, até mesmo em classes que geralmente estão mal classificadas como o fluxo turbulento, conseguiram classificar corretamente todos os fluxos turbulentos existentes nos setores A e B. Para além disso, o desempenho de ambas as classificações foi bastante positivo na identificação de outros elementos como a rocha, a vegetação, a água rasa e até mesmo a água funda no setor C.

No entanto, é possível verificar que existe um maior número de setores e elementos mal classificados, na classificação *Pixel-based* com o algoritmo *Support Vector Machine*, devido ao efeito *Salt and Pepper* presente nas classificações *Pixel-based*. As consequências deste efeito são claras nos três setores, com a presença de *pixels* isolados mal classificados, como por exemplo no setor B, em que existem *pixels* isolados classificados como fluxo turbulento na rocha clara, o que acaba por diminuir a qualidade da classificação e pôr em causa a utilização deste tipo de classificação nesta área de estudo. A classificação *Object-based* com o algoritmo SVM (ACC+MDN) evidencia os benefícios da utilização da segmentação neste tipo de locais, acabando por apresentar uma classificação mais suave e com menos erros por não ser afetada pelo efeito *Salt and Pepper*. Apesar destes algoritmos terem sido os que apresentaram melhores resultados em classificar a área de estudo, existem ao longo do troço algumas falhas na identificação de elementos, como por exemplo nas regiões circundadas a vermelho representadas na figura 29, confundindo a classe do fluxo turbulento com a rocha clara, não sendo possível elaborar classificações semiautomáticas em troços com estas características, sem que haja qualquer tipo de erro associado.



Figura 29 - Exemplos de elementos mal classificados.

A segunda análise feita para ser definida qual a melhor classificação produzida, foi realizada com base em quatro métricas de validação, para quantificar o desempenho dos dois algoritmos, e de cada classe nas diversas classificações (quadro 12 e quadro 13).

Os primeiros métodos de validação utilizados para avaliar e comparar a exatidão dos resultados obtidos pela melhor classificação *Object-based* e *Pixel-based*, foram o EP e o EU (quadro 12). Através da análise destes métodos, verifica-se que a classificação *Pixel-based* obtida pelo algoritmo *Support Vector Machine*, foi a que apresentou a média dos valores de exatidão do produtor mais elevada (0,91), e a classificação *Object-based* obtida pelo algoritmo SVM (ACC+MDN), a que registou a média de valores de exatidão do utilizador mais elevada (0,87). Para além disso, é importante realçar a classificação quase perfeita em ambas as classificações, das classes da vegetação, água rasa e rocha, tendo sido registada uma média de valores de exatidão do produtor e exatidão do utilizador nestas classes de 0,97, 0,98 e 0,96, respetivamente. Como referido na análise visual efetuada, o principal problema destas duas classificações encontra-se na identificação correta da classe do fluxo turbulento, sendo a classe que apresenta a média de valores de EP e EU mais baixa (0,64). Todas as outras classes foram relativamente bem classificadas pelos algoritmos, e a diferença de valores de EP e EU entre os dois algoritmos é bastante reduzida. Apesar disso, a classificação *Object-based* com o algoritmo SVM (ACC+MDN) apresenta uma ligeira superioridade em conseguir classificar corretamente as classes em que normalmente existe mais erro, como o fluxo turbulento e a rocha clara, e a classificação *Pixel-based* com o algoritmo *Support Vector Machine*, a que melhor conseguiu classificar e diferenciar os tipos de sombras.

Quadro 12 - Valores de exatidão do produtor (EP) e exatidão do utilizador (EU) das melhores classificações *Pixel-based* e *Object-based*.

PIXEL BASED & OBJECT BASED														
Exatidão do Produtor & Exatidão do Utilizador														
		Água funda	Água rasa	Vegetação	Sombra na vegetação	Fluxo turbulento	Rocha clara	Rocha	Sombra na rocha	Sombra na água	Mínimo	Máximo	Média	Desvio Padrão
Pixel-based Support vector machine	EP	0,92	0,99	0,99	0,96	0,82	0,78	0,94	0,98	0,86	0,78	0,99	0,91	0,08
	EU	1,00	0,99	0,92	0,61	0,41	0,91	0,98	0,77	0,99	0,41	1,00	0,84	0,21
Object-based SVM (ACC+MDN)	EP	0,92	0,94	0,97	0,92	0,47	0,95	0,98	0,90	0,62	0,47	0,98	0,85	0,18
	EU	0,93	0,98	0,99	0,55	0,85	0,91	0,96	0,73	0,91	0,55	0,99	0,87	0,14
Mínimo		0,92	0,94	0,92	0,55	0,41	0,78	0,94	0,73	0,62				
Máximo		1,00	0,99	0,99	0,96	0,85	0,95	0,98	0,98	0,99				
Média		0,94	0,98	0,97	0,76	0,64	0,89	0,96	0,85	0,85				
Desvio Padrão		0,04	0,03	0,03	0,21	0,23	0,08	0,02	0,11	0,16				

O terceiro e quarto métodos utilizados na validação e comparação quantitativa do melhor algoritmo *Pixel-based* (*Support Vector Machine*) e do melhor algoritmo *Object-based* (SVM (ACC+MDN), foram a exatidão global e o Coeficiente de Kappa (quadro 13). Através da análise dos valores destes dois métodos de validação, é possível verificar que ambos os algoritmos registaram valores de Kappa e de exatidão global iguais, com 0,90 no valor de Kappa, o que coloca estas classificações no nível de quase perfeitas, e 0,92 de exatidão global.

Quadro 13 - Coeficiente de Kappa e exatidão global das melhores classificações *Pixel-based* e *Object-based*.

	Exatidão Global	Kappa
Pixel-based Support vector machine	0,92	0,9
Object-based SVM (ACC+MDN)	0,92	0,9

Por terem sido registados os mesmos valores de Kappa e de exatidão global nas classificações dos dois algoritmos em comparação, o algoritmo que foi capaz de produzir a melhor classificação foi definido segundo vários fatores. Assim, tendo em consideração todos os resultados fornecidos pelos quatro métodos de validação e a prospeção visual realizada nos três setores indicados e no resto do troço fluvial em estudo, decidiu-se que o algoritmo que, no geral, melhor classificou o troço fluvial, foi o SVM com os atributos da segmentação padrão (ACC+MDN), através do tipo de classificação *Object-based*. Apesar do excelente desempenho do algoritmo *Support Vector Machine* na classificação baseada no *pixel*, a utilização de uma classificação baseada no objeto, que permita a introdução de uma segmentação na imagem, que não se baseie somente nas informações espectrais e que não tenha os problemas derivados do efeito *Salt and Pepper*, como as classificações baseadas no *pixel*, revela-se como o melhor método para classificar locais com características semelhantes às do troço fluvial estudado neste projeto.

Assim, para uma área total classificada de 80030 m², a classificação baseada no objeto elaborada através do algoritmo SVM (ACC+MDN), apresentou uma área de 10499 m² classificada como água funda, 19756 m² classificada como água rasa, 19768 m² como vegetação, 2413 m² como sombra na vegetação, 851 m² como fluxo turbulento, 5104 m² como rocha clara, 18599 m² como rocha, 2291 m² como sombra na rocha e 748 m² como sombra na água.

5.4 Variação temporal e espacial do nível da água do trecho fluvial

Adicionalmente, através da utilização dos DSM provenientes dos levantamentos realizados em fevereiro e julho, foi possível realizar uma estimativa da variação espacial do nível da água em seis locais ao longo do trecho fluvial em estudo (figura 30).




Figura 30 - Localização dos setores (1 a 6) utilizados para o cálculo da variação do nível da água entre fevereiro e julho; as imagens de baixo mostram a situação no setor 6, em fevereiro (A) e julho (B).

Com recurso ao *software* ArcGIS Pro, foram utilizados os valores de elevação provenientes dos DSM de ambos os levantamentos, em rochas planas sem aparentes variações drásticas de altitude, para se efetuar a subtração do valor de altitude verificado na linha do nível da água marcada no ortomosaico de fevereiro (linha a azul) e na linha do nível da água marcada no ortomosaico de julho (linha a vermelho) (figura 30).

Segundo esta metodologia verificou-se que o nível da água em julho em comparação com o nível da água no mês de fevereiro: no local 1 diminuiu 90 cm; no local 2 diminuiu 77 cm; no local 3 diminuiu 78 cm; no local 4 diminuiu 97 cm; no local 5 diminuiu 93 cm e no local 6 diminuiu 130 cm (figura 30).

A identificação das alturas de água pode, ainda, possibilitar o cálculo do volume de água em cada local. Para isso, há duas condições essenciais: 1) conhecer o perfil transversal detalhado de cada secção; 2) que exista homogeneidade do perfil imediatamente a montante e/ou imediatamente a jusante da anterior, ou então que se conheçam, também, esses perfis de forma detalhada.

Como o volume é a multiplicação de uma área pela profundidade, a condição 1) permite obter a área e a condição 2) permite acrescentar essa profundidade, para uma determinada extensão a montante e/ou a jusante.

Sabendo, ainda, que a multiplicação da área (m^2) por uma velocidade (m/s) do fluxo permite obter o caudal (m^3/s), então o conhecimento da condição 1) é essencial para esse cálculo.

Obviamente, todos estes procedimentos exigem a combinação dos dados obtidos através dos VAnT com dados de levantamento de campo, sempre que necessário.

6. Conclusão

O estudo e caracterização das condições fluviais a jusante de barragens, fornece elementos fulcrais utilizados nas avaliações de eficácia dos Regimes de Caudais Ecológicos em AH, que visam minimizar os impactes da alteração do regime hidrológico a jusante de barragens. O presente trabalho, desenvolvido durante um estágio curricular na EDP Labelec, apresentou-se como um projeto exploratório e de teste, no âmbito da caracterização das condições fluviais através de VAnT, tendo sido possível evidenciar as vantagens e limitações encontradas no desenvolvimento dos procedimentos metodológicos. Devido a alguns fatores e limitações encontrados ao longo do trabalho, derivados das diversas orientações das vertentes do vale e, conseqüentemente, da variabilidade da incidência da radiação solar, e alguns percalços com o sensor LiDAR, que não estava disponível para ser utilizado nos levantamentos de julho, e registou alguns erros na nuvem de pontos, com locais sem valores, proveniente do levantamento de fevereiro, impossibilitaram a elaboração de caracterizações pormenorizadas do troço fluvial através de dados LiDAR. Estes problemas não permitiram a realização de comparações inicialmente pretendidas entre os dados recolhidos em fevereiro e julho com RCEs diferentes, sendo os resultados cingidos aos dados obtidos no levantamento de 6 de julho às 15 horas pela câmara RGB do *drone*, o que impediu a caracterização de alguns elementos do troço fluvial presentes na norma EN 15843, como o tipo de substrato, geometria do leito, tipo de escoamento, continuidade da zona ripícola, seções naturais críticas em termos de conectividade fluvial.

Devido às limitações apresentadas, durante o desenvolvimento deste trabalho, alguns destes objetivos foram substituídos por outros, optando-se por desenvolver e comparar metodologias e algoritmos, com o intuito encontrar as melhores opções que permitissem caracterizar as condições fluviais com recurso a VAnT em troços fluviais como o estudado.

Este trabalho revelou-se importante na avaliação da eficácia de uma possível introdução das caracterizações efetuadas através de levantamentos com VAnT, nas técnicas de caracterização fluviais tradicionais asseguradas por técnicos no terreno. Isto permitirá reduzir a subjetividade na recolha de elementos no terreno, inerente à falta de acessibilidade e segurança em alguns troços fluviais. Para além disso, será possível

realizar análises temporais das alterações ocorridas nos troços fluviais, e cartografar os elementos presentes nestes locais através da criação de mapas.

Posto isto, para ser efetuada a caracterização das condições fluviais no troço do rio em estudo, foram realizadas classificações semiautomáticas no *software* ArcGIS Pro. Apesar da preferência pela utilização de *softwares* gratuitos como o SagaGIS e o QGIS, as várias classificações realizadas nestes *softwares* não produziram resultados com qualidade suficiente para classificar corretamente o troço fluvial em análise. Por se tratar de um troço fluvial meandrizado com bastantes sombras e sobre-exposição solar sobre vários elementos, existe uma maior dificuldade em classificar corretamente a área de estudo, tornando-se inviável a aplicação desta técnica nestes dois *softwares*.

Ao contrário destes dois *softwares*, o programa ArcGIS Pro foi capaz de produzir classificações semiautomáticas com bastante qualidade na área de estudo, tendo sido realizados testes com vários algoritmos para determinar qual o mais eficaz na caracterização este troço fluvial. Assim, a partir do ortofoto obtido às 15h do dia 6 de julho, onde se verificaram menos sombras, foram definidas 9 classes: água funda, água rasa, vegetação, sombra na vegetação, fluxo turbulento, rocha clara, rocha, sombra na rocha e sombra na água, e criadas áreas de treino para cada uma destas classes em locais com assinaturas espectrais semelhantes. Posteriormente, foram criadas áreas de treino e de validação, para serem utilizadas na ferramenta *Classification Wizard* do ArcGIS Pro, e elaboradas classificações *Pixel-based* e *Object-based* com diferentes algoritmos.

Após a análise e comparação dos dois tipos de classificação (*Pixel-based* e *Object-based*), de quatro algoritmos de classificação (*Support Vector Machine*, *Random Trees*, *Maximum Likelihood* e *K-Nearest Neighbor*), de parâmetros obrigatórios nas classificações *Object-based*, nomeadamente os parâmetros da segmentação (detalhe espacial, detalhe espectral e tamanho mínimo de segmentos) e os atributos da segmentação (ACC+MDN, ACC+MDN+COMP, ACC+MDN+COMP+RECT, ACC+MDN+RECT), todas as classificações foram validadas segundo quatro métricas de validação (índice de exatidão do utilizador, índice de exatidão do produtor, índice de exatidão global e o coeficiente de Kappa).

Comparando todas as classificações e respetivos algoritmos de classificação, é possível concluir que para a área de estudo em causa, os tipos de classificação que apresentaram melhores resultados, foram a classificação *Pixel-based* o algoritmo *Support*

Vector Machine e na classificação *Object-based* o algoritmo *Support Vector Machine* com os atributos da segmentação ACC+MDN. Ambas as classificações produziram resultados muito competentes, mas a classificação baseada no objeto, que permite a introdução de uma segmentação na imagem, não se baseando somente nas informações espectrais, e por não dispor dos problemas derivados do efeito *Salt and Pepper*, como as classificações baseadas no *pixel* que originaram vários erros de classificação, verificou-se como o melhor método para classificar locais com características semelhantes às do trecho fluvial estudado neste projeto. Assim, após uma análise visual e quantitativa dos resultados, a melhor classificação obtida foi através do tipo de classificação *Object-based*, com os parâmetros da segmentação com o valor 20 no detalhe espectral e espacial e com o valor 30 no parâmetro referente ao tamanho mínimo dos segmentos e os atributos da segmentação ACC+MDN, apresentando, no cômputo geral, os melhores valores na média da exatidão do utilizador (0,87), na média da exatidão do produtor (0,85), na exatidão global (0,92) e de coeficiente de Kappa (0,90) (quadro 14).

Quadro 14 - Resumo dos valores e parâmetros da melhor classificação semiautomática.

Tipo de Classificação	Algoritmo de Classificação	Parâmetros da segmentação	Atributos da segmentação	Média da exatidão do utilizador	Média da exatidão do produtor	Exatidão global	Kappa
Object-based	Support Vector Machine	Detalhe espectral - 20 Detalhe espacial - 20 Tamanho mínimo dos segmentos - 30	ACC + MDN	0,87	0,85	0,92	0,9

De forma geral, os parâmetros da melhor classificação enunciados (quadro 14), revelaram ser os mais indicados para classificar o ortomosaico, tendo sido feita uma boa classificação em geral das classes, principalmente na classe da vegetação, água rasa e rocha, e das classes dos vários tipos de sombra, que foram criadas precisamente para pôr à prova o desempenho do classificador. Após uma prospeção visual da classificação, esta foi a que melhor conseguiu classificar as classes do fluxo turbulento e rocha clara, onde normalmente existe mais erro e confusão. A sobre-exposição solar faz com que estes elementos sejam confundidos com outros como a rocha clara, e os locais onde existe sombra também são confundidos com alguns elementos de rochas e vegetação mais escuras, tornando o processo de classificação mais difícil, principalmente na classificação de locais com sombra opaca.

Apesar de ser complicado minimizar problemas derivados da variabilidade da incidência da radiação solar em troços fluviais meadrizados, nomeadamente a sobre-exposição solar de alguns elementos, é aconselhável escolher bem a altura e hora do dia em que são realizados os levantamentos, evitando os meses que se seguem ao solstício de inverno, em que existe mais sombra durante o dia, sendo aconselhado a realização destes levantamentos nos meses após o solstício de verão, no Hemisfério Norte, perto das 12h no zênite solar, para evitar ao máximo o problema das sombras. Outra solução passa por escolher dias nublados e com luz difusa, que permitam obter imagens relativamente homogéneas em termos de luminosidade e sombras, precavendo os problemas derivados das várias orientações das vertentes dos vales.

Em suma, através das classificações semiautomáticas *Pixel-based* com o algoritmo SVM e *Object-based* com o algoritmo SVM e os atributos da segmentação indicados, é possível saber rapidamente e com rigor qual a área e localização de cada elemento presente no troço fluvial, sendo variável a escolha do tipo de classificação e dos parâmetros utilizados, consoante os objetivos do trabalho e as características topográficas da área de estudo.

Em futuros trabalhos, é aconselhável que os levantamentos sejam feitos com outros sensores acoplados ao VAnT, como uma câmara multiespectral. Mais bandas para além das utilizadas (azul, verde e vermelha), conseguem uma melhor discriminação das diferentes coberturas do solo e estimar diferentes variáveis biofísicas, como o vigor vegetativo, *stress* hídrico e a qualidade da água. Apesar do objetivo do projeto ter sido cumprido, sendo possível e eficaz serem introduzidas as caracterizações das condições fluviais através de VAnT nas caracterizações tradicionais, a caracterização dos troços fluviais não deve ser feita apenas por dados provenientes da câmara RGB do *drone*, caso se queira aumentar o leque e a qualidade das opções de estudos para a empresa em áreas similares.

Bibliografia

Alves, M. H., Bernardo, J. M., Figueiredo, H. D., Martins, J. P., Pádua, J., Pinto, P., & Rafael, M. T. (2002). Directiva-Quadro da Água: Tipologias de rios segundo o sistema A e o sistema B em Portugal, 347-354.

Alves, A. K. A., da Silva, N. M., & Paranhos Filho, A. C. (2015). Imagens de Alta Resolução Espacial de Veículos Aéreos Não Tripulados (VANT) no Planejamento do Uso e Ocupação do Solo, 147-156. http://dx.doi.org/10.11137/2015_1_147_156.

Alves, J. M.; Espírito-Santo, M. D.; Costa, J. C.; Gonçalves, J. C.; Lousã, M. F. (2009). Habitats Naturais e Seminaturais de Portugal Continental. Tipos de Habitats Mais Significativos e Agrupamentos Vegetais Característicos, ISBN: 978-972-37-1380-0.

APA (2010). Reforço de potência do aproveitamento hidroeléctrico de Salamonde – Salamonde II - Projeto de Execução - Parecer da Comissão de Avaliação.

APA (2016). Plano de Gestão de Região Hidrográfica – Parte 2 | Caracterização e Diagnóstico - Região hidrográfica do Cávado, Ave e Leça (rh2).

APA (2018a). Guia Metodológico para a Definição de Regimes de Caudais Ecológicos em Aproveitamentos Hidráulicos de Portugal Continental Disponível em: https://apambiente.pt/sites/default/files/_SNIAMB_Agua/DRH/Licenciamento/RegimeCaudaisEcologicos/01_GuiaRCE.pdf (Acedido dia 23/08/2023).

APA (2018b). Guia Metodológico para a Definição de Regimes de Caudais Ecológicos em Aproveitamentos Hidráulicos de Portugal Continental | Anexo 2. Disponível em: https://www.apambiente.pt/sites/default/files/_Agua/DRH/ParticipacaoPublica/PGRH/2022-2027/3_Fase/03_Anexo2_GuiaRCE.pdf (Acedido dia 24/08/2023).

APA (2023). Plano de Gestão de Região Hidrográfica – 3.º Ciclo | 2022 – 2027 – Cávado, Ave e Leça (RH2) – Parte 2 – Volume A | Caracterização e Diagnóstico.

Boon, P. J., Holmes, N. T., & Raven, P. J. (2010). Developing standard approaches for recording and assessing river hydromorphology: the role of the European Committee for Standardization, 20, S55-S61.

Carrivick, J. L., Smith, M. W., & Quincey, D. J. (2016). *Structure from Motion in the Geosciences*. ISBN:9781118895849.

CNPGB (2016). Barragens de Portugal. http://cnpgb.apambiente.pt/gr_barragens/gbportugal/ (Acedido dia 11/01/2024).

Câmara Municipal de Vieira do Minho (2011). Volume II - Estudos de caracterização e diagnóstico. <https://cm-vminho.pt/wp-content/uploads/2019/04/RPDM-VM-diagn%C3%B3stico-2011.pdf> (Consultado em 09/02/2024)

Crisógono, P. J. B. M. (2011). Detecção remota em meio urbano: teste com classificadores supervisionados a nível do pixel sobre imagens de alta resolução espacial aplicados numa lógica hierárquica de classes. Dissertação de Mestrado em Gestão do Território, Universidade Nova de Lisboa.

Detert, M., Johnson, E. D., & Weitbrecht, V. (2017). Proof-of-concept for low-cost and non-contact synoptic airborne river flow measurements. *International Journal of Remote Sensing*, 38, 2780-2807.

Dyson, M., Bergkamp, G., Scanion, J. (2007). Fluxo: Elementos essenciais de fluxos ambientais. ISBN 978-2-8317-1013-6.

ESRI, (s/d). Image Classification Wizard - ArcGIS Pro. Acedido a 22 de maio, 2024. Disponível em: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/image-analyst/the-imageclassification-wizard.htm>

Ferreira, A., Maia, R., & da Silva, J. D. (2010). Problemática e soluções para a descarga de caudais ecológicos em aproveitamentos hidráulicos existentes. Exemplos. 5.^{as} Jornadas de Hidráulica, Recursos Hídricos e Ambiente, FEUP. ISBN 978-989-95557-4-7

Ferreira, R. F. R. G. (2013). Acompanhamento do reforço de potência Salamonde II. Dissertação de Mestrado em Engenharia Civil, Instituto Superior de Engenharia de Lisboa.

Ferreira, C.S.C. (2018). Indicadores dos processos morfodinâmicos na bacia do rio Cávado. Dissertação de Mestrado em Geociências, Universidade do Minho.

Ferreira, A. I. D. S. (2020). Identificação automática de zonas de floresta e de alteração de floresta utilizando plataformas disponíveis e dados do Sentinel 2. Dissertação de Mestrado em Engenharia de Informação Geoespacial, Faculdade de Ciências e Tecnologia, Universidade de Coimbra.

Freitas, P. A. F. (2018). Avaliação de novas plataformas de deteção remota para monitorização de lagoas termocársicas (subártico canadiano). Dissertação de Mestrado em Mestrado em Sistemas de Informação Geográfica e Modelação Territorial Aplicados ao Ordenamento, Instituto de Geografia e Ordenamento do Território, Universidade de Lisboa.

Frias, M. C., Vesterhauge, A. R., Olesen, D. H., Bandini, F., Grosen, H., Nielsen, S., & Bauer-Gottwein, P. (2023). Combining UAS LiDAR, sonar and radar altimetry for river hydraulic characterization. <https://doi.org/10.5194/egusphere-gc8-hydro-27>.

Godinho, F. N., Costa, S. C., Pinheiro, P. J., Alvarez, T., & Reis, F. M. (2014). Metodologia integrada para determinação de regimes de caudais ecológicos aplicada em rios ibéricos-aqualogus-eflow, *Journal of Water Resources/Recursos Hídricos*, 35, pp.19. DOI: 10.5894/rh35n2-2.

Gonçalves, J. D. (2015). Dispositivos de descarga de caudal ecológico nos grandes aproveitamentos hidroelétricos portugueses. Dissertação de Mestrado em Engenharia Civil, Faculdade de Engenharia, Universidade do Porto.

- Gualtieri, F. (2019). – Bacia Hidrográfica do Cávado a 36% da sua capacidade máxima. *Jornal Vilaverdense*. <https://ovilaverdense.pt/bacia-hidrografica-do-cavado-a-36-da-capacidade-maxima/> (Consultado em 09/02/2024).
- Hajdukiewicz, H., Wyżga, B., Zawiejska, J., Amirowicz, A., Oglęcki, P., & Radecki-Pawlik, A. (2017). Assessment of river hydromorphological quality for restoration purposes: an example of the application of RHQ method to a Polish Carpathian river. *Acta Geophysica*, 65, 423-440. DOI: 10.1007/s11600-017-0044-7.
- Hardin, P. J., & Jensen, R. R. (2011). Small-scale unmanned aerial vehicles in environmental remote sensing: Challenges and opportunities. *GIScience & Remote Sensing*, 48, 99-111. DOI: 10.2747/1548-1603.48.1.99.
- Jimoh, S. O. (2021). Mapping and monitoring slums using geoinformation technologies. Dissertação de Mestrado em Digital Earth, Universidade Paris Lodron Salzburg e Universidade Palacký Olomouc.
- Kang, B., Kim, J. G., Kim, D., & Kang, D. H. (2019). Flow estimation using drone optical imagery with non-uniform flow modeling in a controlled experimental channel. *KSCE Journal of Civil Engineering*, 23, 1891-1898. <https://doi.org/10.1007/s12205-019-1438-7>.
- Kinzel, P. J., & Legleiter, C. J. (2019). sUAS-based remote sensing of river discharge using thermal particle image velocimetry and bathymetric Lidar. *Remote Sensing*, 11, pp.2317. <https://doi.org/10.3390/rs11192317>.
- Lagogiannis, S., & Dimitriou, E. (2021). Discharge estimation with the use of unmanned aerial vehicles (UAVs) and hydraulic methods in shallow rivers. *Water*, 13, pp.2808. <https://doi.org/10.3390/w13202808>.
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 159-174. <https://doi.org/10.2307/2529310>.
- Martins, C. L. (2021). Geographic Object Based Image Analysis aplicada a dados Sentinel 2 MSI. Dissertação de Mestrado em Gestão do Território, Universidade Nova de Lisboa.
- Martins, F. D. (2012). Utilização de técnicas de Detecção Remota na identificação de *Acacia* sp. na Região Centro Sul de Portugal Continental. Dissertação de Mestrado em Sistemas de Informação Geográfica em Recursos Agro-Florestais e Ambientais, Instituto Politécnico de Castelo Branco.
- Noronha, F., & Ribeiro, M. L. (1983). Notícia explicativa da folha 6-A Montalegre da Carta Geológica de Portugal, Serviços Geológicos de Portugal.
- Palhares, D. B. (2015). Avaliação Técnico Económica de Aproveitamentos Hidroelétricos-Reforço de Potência de Salamonde. Dissertação de Mestrado Integrado em Engenharia Eletrotécnica e de Computadores, Faculdade de Engenharia da Universidade do Porto.
- Palma, J. P. A. (2012). Espacialização da exatidão da classificação automática de imagens multiespectrais usando medidas de incerteza e classificadores não rígidos. Dissertação de Mestrado em Engenharia Geográfica, Faculdade de Ciências e Tecnologia, Universidade de Coimbra.

Piçarra, J. F. R., & Geográfica, (2014). Análise comparada da classificação “pixel a pixel” e orientada por objecto de uma imagem WorldView 2 de Maputo, Moçambique. Trabalho de Projeto de Mestrado em Gestão do Território, área de especialização em Detecção Remota e Sistemas de Informação Geográfica.

Peixoto, E. B. D. A., Araki, D. H., & Centeno, D. J., (2016). Utilização do algoritmo svm (Support Vector Machine) e árvores de decisão para classificação de imagens de alta resolução do sensor ads-40. *VI Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação*.

Pereira, P. M. P. (2020). Análise de Risco de Crédito usando algoritmos de Machine Learning. Dissertação de Mestrado em Matemática Financeira, Faculdade de Ciências, Universidade de Lisboa.

Pinto, I. S. M. (2020). Cartografia de Ocupação do Solo da Ilha de Santiago, Cabo Verde, usando imagens do satélite Sentinel-2. Dissertação de Mestrado em Sistemas de Informação Geográfica – Tecnologias e Aplicações, Faculdade de Ciências, Universidade de Lisboa.

Profico Ambiente, (2010). Reforço da Potência do Aproveitamento de Salamonde – Salamonde II – Estudo de Impacte Ambiental – Relatório Técnico – Volume II. EDP – Gestão da Produção de Energia, S.A.

Pontoglio, E., Dabove, P., Grasso, N., & Lingua, A. M. (2021). Automatic features detection in a fluvial environment through machine learning techniques based on UAVs multispectral data. *Remote Sensing*, 13, pp. 3983. <https://doi.org/10.3390/rs13193983>.

Poudel, A., Bhatti, S., & Bevilacqua, E. (2023). Assessment of Image Classification Algorithms for Land Cover Classifications in Tully, NY. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 48, 183-187. <https://doi.org/10.5194/isprs-archives-XLVIII-M-3-2023-183-2023>.

Ramos, A. R. M. (2020). Efeitos das alterações hidrológicas decorrentes de aproveitamentos hidroelétricos em comunidades piscícolas do norte de Portugal. Relatório de estágio de mestrado em Ecologia e Gestão Ambiental, Faculdade de Ciências, Universidade de Lisboa.

Rivas Casado, M., Ballesteros Gonzalez, R., Kriechbaumer, T., & Veal, A. (2015). Automated identification of river hydromorphological features using UAV high resolution aerial imagery. *Sensors*, 15, 27969-27989. <https://doi.org/10.3390/s151127969>.

Sampaio, E. (2007). Noções básicas de detecção remota, fotogrametria e fotointerpretação em pedologia. Departamento de Geociências, Universidade de Évora.

Santos, M. J. G. (2021). Classificação de Culturas Agrícolas de Inverno com Recurso à Plataforma Google Earth Engine e Imagens dos Satélites Sentinel-1 e Sentinel-2. Trabalho de projeto de Mestrado em Sistemas de Informação Geográfica – Tecnologias e Aplicações.

Santos, O. L., Padolfi, A. S., & Ramaldes, G. P. (2018). Análise de índice de vegetação através de imagens obtidas por VAnT. *Revista Científica FAESA*, 14, 145-165. DOI: 10.5008/1809.7367.143.

Saraiva, C. S. A. (2015). Avaliação do Potencial das Imagens Sentinel-1 para Identificação de Culturas Agrícolas. Dissertação de Mestrado em Engenharia Geográfica, Faculdade de Ciências, Universidade de Lisboa.

Schmidt, L., & Ferreira, J. G. (2013). A governança da água no contexto de aplicação da Directiva Quadro da Água. *VIII Congresso Iberico de Gestão e Planeamento da Água*. pp 6-7.

Silva, D. C., Toonstra, G. W. A., Souza, H. L. S., & Pereira, T. A. J. (2014). Qualidade de ortomosaicos de imagens de VANT processados com os softwares APS, Pix4D e Photoscan. *V Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação*. pp 749.

Stanca, S. C. (2023). Methodology for determining hydromorphological indicators for rivers with hydropower uses. *14th International Conference on Hydroinformatics*. DOI:10.1088/1755-1315/1136/1/012032.

Vieira, B. M. D. S. (2016). Verificação da Aplicabilidade da Técnica Structure From Motion na Modelação 3D de Componentes Mecânicos. Dissertação de Mestrado em Engenharia Mecânica, Universidade Nova de Lisboa.

Vieira, G., Mora, C., Pina, P., Ramalho, R., & Fernandes, R. (2021). UAV-based very high resolution point cloud, digital surface model and orthomosaic of the Chã das Caldeiras lava fields (Fogo, Cabo Verde). *Earth System Science Data*, 13, 3179-3201. <https://doi.org/10.5194/essd-13-3179-2021>.

Woodget, A. (2015). Quantifying physical river habitat parameters using hyperspatial resolution UAS imagery and SfM-photogrammetry. Tese de Doutoramento em Filosofia, Universidade de Worcester.

Woodget, A. S., Austrums, R., Maddock, I. P., & Habit, E. (2017). Drones and digital photogrammetry: from classifications to continuums for monitoring river habitat and hydromorphology. *WIREs Water*, 4, pp. 1222. DOI: 10.1002/wat2.1222.