



UNIVERSIDADE  
LUSÓFONA

# Segmentação de Incêndios Florestais

## Trabalho Final de Curso

Relatório Intercalar 1º Semestre

Karim Alibhai, 22402980, Licenciatura em Ciência de Dados

João Carvalho

Houda Harkat

Trabalho Final de Curso | LCD | 30/11/2025

## Direitos de cópia

(Segmentação de Incêncios Florestais), Copyright de (Karim Ali Sadrudin Alibhai),  
Universidade Lusófona.

A Escola de Comunicação, Arquitectura, Artes e Tecnologias da Informação (ECATI) e a Universidade Lusófona (UL) têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objectivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

Este documento foi gerado com o processador (pdf/Xe/Lua)LaTeX e o modelo ULThesis (v1.0.0) [Mat24].

## Resumo

Os incêndios florestais representam um dos maiores desafios ambientais e operacionais em Portugal, exigindo soluções tecnológicas capazes de detetar e caracterizar rapidamente a presença de fogo. Neste contexto, o objetivo deste Trabalho Final de Curso consistiu no desenvolvimento de um sistema de segmentação semântica binária capaz de identificar, com elevada precisão, as regiões de fogo presentes em imagens RGB, distinguindo-as do background.

A metodologia adotada baseou-se em modelos de deep learning orientados para segmentação pixel-a-pixel, recorrendo a arquiteturas consolidadas como U-Net e ResUNet. Para tal, foi construído um dataset composto por imagens RGB e respetivas máscaras binárias anotadas manualmente, representando fogo (classe 1) e background (classe 0). O pipeline incluiu pré-processamento dos dados, implementação e treino dos modelos, experimentação de diferentes funções de perda especializadas e avaliação de desempenho com métricas amplamente utilizadas, como IoU e Dice Score.

Os resultados demonstraram que a abordagem proposta é eficaz na delimitação espacial do fogo, apresentando precisão elevada mesmo em cenários com variação luminosa, vegetação densa ou contornos irregulares das chamas. O trabalho comprova ainda a viabilidade da aplicação destas arquiteturas em ambientes reais, dado o baixo custo computacional, a compatibilidade com hardware comum e a possibilidade de inferência em tempo real.

Conclui-se que o sistema desenvolvido constitui uma solução tecnicamente robusta, cientificamente fundamentada e operacionalmente aplicável para apoio à monitorização de incêndios. A escalabilidade da arquitetura permite o reentrenamento com novos datasets e a evolução futura para modelos multiclasse, reforçando o potencial de continuidade do projeto após a conclusão do TFC.

# Abstract

Wildfires remain one of the most critical environmental and operational challenges in Portugal, demanding technological solutions capable of rapidly detecting and accurately characterizing fire occurrences. In this context, the objective of this Final Degree Project was to develop a binary semantic segmentation system capable of precisely identifying the regions affected by fire in RGB images, distinguishing them from the background.

The proposed methodology relies on deep learning models for pixel-wise segmentation, employing consolidated architectures such as U-Net and ResUNet. A dataset was constructed using RGB images and manually annotated binary masks representing fire (class 1) and background (class 0). The pipeline involved data preprocessing, model implementation and training, experimentation with specialized loss functions, and performance evaluation using established metrics such as Intersection over Union (IoU) and Dice Score.

The results demonstrate that the proposed approach is effective in spatially delineating fire regions, achieving high accuracy even in challenging scenarios with lighting variation, dense vegetation, and irregular flame contours. Moreover, the study confirms the technical viability of deploying these architectures in real-world environments due to their low computational cost, compatibility with standard hardware, and potential for real-time inference.

Overall, the developed system constitutes a robust, scientifically grounded, and operationally applicable solution for supporting wildfire monitoring. Its scalability allows retraining with new datasets and future extension to multiclass models, reinforcing the project's potential for continuation beyond the academic scope.

# Índice

<b>Resumo</b>	<b>2</b>
<b>Abstract</b>	<b>3</b>
<b>Índice</b>	<b>4</b>
<b>Lista de Figuras</b>	<b>5</b>
<b>Lista de Tabelas</b>	<b>6</b>
<b>1 Identificação do Problema</b>	<b>7</b>
<b>2 Benchmarking</b>	<b>9</b>
<b>3 Viabilidade e Pertinência</b>	<b>16</b>
<b>4 Solução Proposta</b>	<b>21</b>
<b>5 Calendário</b>	<b>29</b>
<b>Bibliografia</b>	<b>32</b>

# Lista de Figuras

5.1 Calendário de atividades do Trabalho Final de Curso . . . . . 29

## **Lista de Tabelas**

4.1	Distribuição de píxeis por classe no dataset . . . . .	24
4.2	Métricas utilizadas na avaliação do modelo . . . . .	26
4.3	Configurações experimentais testadas . . . . .	28
4.4	Desempenho do modelo para diferentes valores de learning rate . . . . .	28

# 1 - Identificação do Problema

Os incêndios florestais representam uma ameaça crescente em diversas regiões do mundo, provocando danos severos a ecossistemas, comunidades locais e infraestruturas críticas. A intensificação destes eventos está diretamente associada às alterações climáticas, que aumentam a frequência, severidade e imprevisibilidade dos incêndios. Além dos impactos ambientais de destruição de habitats, perda de biodiversidade e agravamento das emissões de gases com efeito de estufa, estes desastres têm consequências económicas e sociais profundas, afetando a segurança das populações e exigindo elevados custos de reconstrução. A deteção precoce de incêndios é um dos fatores mais determinantes para minimizar danos. Identificar o aparecimento de fogo nas suas fases iniciais permite uma resposta rápida, reduz o tempo de propagação e aumenta substancialmente a eficácia do combate. Contudo, os métodos tradicionais de deteção, como vigilância humana, câmaras fixas ou sensores térmicos, apresentam limitações importantes em termos de alcance, precisão e capacidade de monitorização contínua, especialmente em áreas remotas ou de difícil acesso, onde o tempo de resposta é crítico. Com os avanços recentes em visão computacional e aprendizagem profunda, surgem novas oportunidades para melhorar os sistemas de monitorização e deteção automática de incêndios. Técnicas modernas de segmentação de imagens permitem identificar padrões visuais complexos diretamente ao nível do píxel, distinguindo com elevada precisão regiões que correspondem à presença de fogo. Esta abordagem pode superar limitações dos métodos convencionais, oferecendo deteção rápida, automatizada e consistente. A relevância deste trabalho reside exatamente na exploração destas técnicas avançadas para identificar e segmentar automaticamente o fogo em imagens reais, classificando cada píxel entre duas classes: fogo e background. Ao concentrar-se neste cenário binário, o modelo pode alcançar maior precisão na deteção de regiões críticas, fornecendo um suporte técnico valioso para sistemas de resposta rápida e reduzindo o perigo de falhas humanas ou atrasos operacionais. Assim, este projeto procura contribuir para o desenvolvimento de soluções tecnológicas capazes de reforçar a eficácia da prevenção e combate a incêndios florestais, promovendo deteção precoce, vigilância contínua e monitorização mais eficiente, em linha com os desafios atuais impostos pelas mudanças climáticas e pela necessidade crescente de sistemas inteligentes de apoio à decisão. Para além desta motivação geral, o presente trabalho enquadra-se num case study de aplicação real, sustentado por dados concretos e por necessidades operacionais identificadas por entidades envolvidas no combate a incêndios. A análise baseia-se num conjunto de imagens aéreas recolhidas por sensores de monitorização e complementadas por um dataset personalizado, no qual foram produzidas manualmente máscaras de segmentação que identificam, com precisão píxel a píxel, as regiões contendo fogo. Este processo de anotação rigorosa garante a fidelidade dos dados ao fenómeno real e assegura que o modelo é treinado com informação relevante para o contexto de campo. A solução desenvolvida responde diretamente a desafios enfrentados por terceiros que atuam no terreno, como bombeiros, Proteção Civil, ICNF e equipas de vigilância florestal, que dependem de sistemas de deteção rápidos e fiáveis para minimizar o tempo de resposta inicial. Estes utilizadores constituem potenciais beneficiários diretos da aplicação prática deste trabalho, uma vez que uma segmentação precisa em imagens aéreas pode apoiar operações de reconhecimento, vigilância automatizada e tomada de decisão em tempo real.

Do ponto de vista técnico e científico, o estudo fundamenta-se em métodos modernos de visão computacional e deep learning, adotando uma arquitetura baseada numa ResUNet adaptada à tarefa de segmentação binária. Esta escolha decorre do desempenho comprovado deste tipo de redes na identificação de padrões complexos em imagens reais, permitindo capturar tanto informação espacial detalhada como características de maior escala relevantes para a deteção de fogo.[Nov21]

## 2 - Benchmarking

A detecção de incêndios florestais conta atualmente com diversas soluções tecnológicas que operam em contextos operacionais distintos, desde sistemas de vigilância humana até plataformas avançadas de análise visual. Apesar da sua importância, a maioria destas abordagens apresenta limitações significativas, sobretudo pela ausência de segmentação pixel-a-pixel, o que compromete a precisão espacial e a capacidade de delimitar de forma clara a área realmente afetada pelo fogo.[NAS00]

Entre as soluções existentes, destacam-se alguns grupos principais de tecnologias.

O EFFIS integra imagens de satélite, dados meteorológicos e índices de risco para identificar áreas potencialmente afetadas por incêndios. Este sistema fornece alertas e relatórios em tempo quase real e é amplamente utilizado em monitorização de larga escala. No entanto, a sua identificação é feita apenas ao nível regional e não inclui qualquer forma de segmentação detalhada. Assim, o EFFIS indica a presença de um incêndio numa zona aproximada, sem delimitar pixel-a-pixel a área em chamas, o que limita a sua aplicabilidade em cenários que exigem maior precisão espacial.[Eur98]

O sistema CICLOPE (Sistema Português de Videovigilância Florestal) utiliza câmaras PTZ instaladas em torres de vigilância e recorre à análise de alterações visuais no ambiente, como movimentos ou colunas de fumo, para identificar possíveis focos de incêndio. Apesar de ser operacionalmente relevante e eficaz na vigilância contínua, o CICLOPE apresenta limitações semelhantes às do EFFIS.[CIC00]

Não segmenta o fogo ao nível do pixel, restringindo-se a sinalizar uma possível ocorrência e a retransmitir a imagem para um operador humano. Esta dependência de intervenção manual e a ausência de segmentação comprometem a automatização e a precisão da deteção.

Algumas empresas têm desenvolvido sistemas comerciais que utilizam algoritmos de visão computacional para detetar padrões visuais de fogo através de câmaras CCTV. Contudo, a maioria destas soluções utiliza classificadores ou detetores de objetos que operam com bounding boxes, em vez de segmentação semântica. Consequentemente, estas abordagens tendem a:

- apresentar menor precisão em cenários complexos;
- ser altamente dependentes das condições de luz;
- gerar falsos positivos em ambientes naturais;
- não conseguir separar o fogo do background a cada pixel, prejudicando a análise espacial da área em chamas.

## Solução proposta

Comparando estas tecnologias com a solução desenvolvida neste projeto, verifica-se que todas as abordagens estudadas, como a EFFIS, CICLOPE e soluções comerciais de IA, falham num ponto crítico: nenhuma realiza segmentação semântica capaz de identificar, com precisão ao nível do pixel, as regiões de fogo numa imagem.

A solução proposta no Trabalho de Final de Curso (TFC) diferencia-se precisamente por superar essa limitação. O modelo desenvolvido realiza segmentação binária pixel-a-pixel, classificando cada pixel como “fogo” ou “background” e produzindo uma máscara detalhada da área afetada.

Adicionalmente, importa destacar que o problema abordado apresenta um elevado grau de dificuldade, decorrente do forte desbalanceamento presente no dataset, onde apenas uma pequena fração dos píxeis corresponde à classe fogo. Neste contexto, a utilização de métricas adequadas, como F1-score e Intersection over Union (IoU), torna-se essencial para avaliar corretamente o desempenho do modelo.

Esta capacidade permite:

- delimitação precisa e automática das regiões em chamas;
- maior sensibilidade a pequenos focos de incêndio;
- redução de falsos positivos associados ao background;
- maior utilidade para sistemas automáticos de combate e monitorização científica;
- independência de operadores humanos;
- potencial de integração em tempo real com sistemas de vigilância existentes.

Assim, a solução proposta neste projeto oferece uma abordagem mais precisa, autónoma e tecnicamente avançada em comparação com as alternativas disponíveis no mercado.

## **Estudo da Arte**

A detecção automática de incêndios florestais tem ganho crescente atenção na comunidade científica, impulsionada pelo aumento da frequência e intensidade destes eventos e pelos avanços recentes em visão computacional e deep learning. Tradicionalmente, a monitorização baseava-se em observação humana, sensores térmicos ou sistemas de videovigilância com análise manual, abordagens que apresentam limitações significativas em termos de precisão espacial, escalabilidade e rapidez de resposta. Estas limitações impulsionaram o desenvolvimento de soluções baseadas em aprendizagem automática e processamento de imagem, capazes de analisar padrões visuais com maior fiabilidade.

### **Visão computacional aplicada a incêndios florestais**

Os primeiros trabalhos de visão computacional aplicados a incêndios concentravam-se na detecção de chamas ou alterações de cor em imagens RGB. Métodos clássicos recorriam a limiares em espaços de cor, como RGB, HSV ou YCbCr, para identificar tonalidades associadas ao fogo. Apesar de simples, estes métodos revelaram elevada sensibilidade a variações de iluminação, reflexos solares e objetos com cores semelhantes, conduzindo a frequentes falsos positivos e desempenho inconsistente em cenários naturais.

Com o avanço das Redes Neurais Convolucionais (CNNs), surgiram abordagens mais robustas, capazes de aprender automaticamente padrões de textura, forma e cor associados ao fogo. No entanto, muitos destes trabalhos iniciais focavam-se apenas na classificação da imagem (“contém fogo” vs. “não contém fogo”) ou na detecção baseada em bounding boxes, que identifica regiões aproximadas mas não delimita com precisão a área em chamas. Estes métodos, embora mais fiáveis do que as abordagens clássicas, não fornecem informação espacial suficiente para uma análise detalhada.

### **Segmentação de fogo com deep learning**

A necessidade de identificar com rigor as regiões afetadas por incêndios motivou o desenvolvimento de técnicas de segmentação semântica, nas quais cada pixel é classificado como pertencente ou não à classe de interesse. No contexto de incêndios florestais, esta abordagem traduz-se na criação de máscaras binárias que distinguem fogo e background, permitindo uma análise espacial mais precisa e uma detecção mais sensível a pequenos focos.

Entre os modelos de segmentação propostos na literatura destacam-se arquiteturas profundas como a Mask R-CNN, que combina detecção de objetos com segmentação ao nível de instância. Estes métodos apresentam resultados sólidos na delimitação de regiões de fogo, embora impliquem maior complexidade computacional e exigência de dados anotados extensos, o que pode limitar a sua aplicabilidade em cenários de recursos limitados.[Imp23]

## Arquiteturas baseadas em U-Net

Entre as arquiteturas dedicadas à segmentação semântica, a U-Net tornou-se uma das mais utilizadas devido à sua capacidade de combinar contexto global com detalhe local. Originalmente proposta para segmentação biomédica, a U-Net tem sido amplamente adotada em tarefas de observação remota e detecção de incêndios.[U-N95]

A sua estrutura em “U” é composta por:

- um encoder, que reduz progressivamente a resolução espacial enquanto extrai características de alto nível;
- um decoder, que recupera a resolução original através de operações de upsampling e convoluções;
- skip connections, que ligam camadas simétricas do encoder e do decoder, preservando detalhes essenciais para uma segmentação precisa.

Estudos demonstram que versões adaptadas da U-Net, especialmente em tarefas binárias e com datasets desbalanceados, alcançam valores elevados de accuracy, F1-Score e IoU na segmentação de regiões de fogo. A literatura recente evidencia ainda variantes com blocos residuais, como ResUNet e ResUNet-a, que permitem treinar redes mais profundas com maior estabilidade, capturar padrões visuais mais complexos e mitigar problemas de gradientes.[Con10]

Estas variantes revelam-se particularmente eficazes em contextos nos quais o fogo ocupa apenas uma pequena fração da imagem, como no cenário típico em imagens aéreas como no nosso dataset utilizado neste Trabalho Final de Curso.

Neste contexto, variantes da U-Net com ligações residuais, como a ResUNet e a ResUNet-a, apresentam vantagens adicionais, nomeadamente ao nível da estabilidade do treino e da capacidade de generalização. A incorporação de blocos residuais permite mitigar problemas associados ao desaparecimento do gradiente e facilita o treino de redes mais profundas, o que se revela particularmente relevante em cenários complexos como a detecção de incêndios florestais. Estas arquiteturas mostram-se especialmente eficazes quando combinadas com funções de perda adequadas a datasets desbalanceados, reforçando a sua adequação para tarefas de segmentação binária ao nível do pixel.

## **Funções de perda e desafios na segmentação de incêndios**

Um dos principais desafios da segmentação de incêndios é o desbalanceamento entre classes. Na maioria das imagens, a região correspondente ao fogo representa apenas uma pequena parte do total, enquanto o background (vegetação, solo, céu, etc.) domina o número de pixels. Modelos treinados apenas com Cross-Entropy tendem a favorecer a classe majoritária, prejudicando a detecção de pequenas regiões de fogo.

Para superar este problema, diversos trabalhos recomendam o uso de funções de perda especializadas, como Dice Loss, IoU Loss, Tversky Loss e variantes de Generalized Dice, que penalizam erros de forma mais equilibrada e favorecem a segmentação de classes minoritárias. Estudos comparativos mostram que a escolha adequada da função de perda, combinada com um ajuste cuidadoso da learning rate, melhora significativamente a qualidade da segmentação em tarefas binárias fortemente desbalanceadas.

## **Enquadramento teórico e científico do problema**

A detecção automática de incêndios florestais constitui um domínio de investigação cada vez mais relevante, impulsionado pelo aumento da frequência e intensidade das ocorrências, pela maior severidade das condições climáticas extremas e pelas limitações dos métodos tradicionais de monitorização. O desafio central consiste em identificar, de forma rápida, precisa e fiável, as regiões onde o fogo está presente, permitindo acionar mecanismos de resposta antecipada e minimizar os impactos ambientais, sociais e económicos associados aos incêndios.

Historicamente, a detecção de incêndios baseava-se em observadores humanos, patrulhamento terrestre, vigilância em torres e sistemas de videomonitorização operados manualmente. Sensores térmicos, câmaras convencionais e imagens de satélite fornecem alertas complementares, mas estas abordagens apresentam limitações críticas, incluindo baixa precisão espacial, dependência da visibilidade e luminosidade, suscetibilidade a falsos positivos, elevada variabilidade atmosférica e necessidade de interpretação humana. Estas limitações tornam evidente a necessidade de sistemas automatizados com maior autonomia e capacidade analítica.

Neste contexto, a visão computacional tem assumido um papel central na modernização dos sistemas de monitorização de incêndios. A evolução das Redes Neurais Convolucionais (CNNs) permitiu a análise automática de imagens e a detecção de padrões visuais característicos de fogo, como textura, forma, intensidade e variação temporal. Estes modelos superaram métodos heurísticos baseados apenas em regras fixas, tornando possível extrair características discriminativas diretamente a partir dos dados.

Contudo, muitas abordagens existentes continuam limitadas à classificação global da imagem (“fogo”/“não fogo”) ou à detecção por bounding boxes, que identifica apenas a presença aproximada do fogo, sem fornecer uma delimitação espacial precisa da área afetada. Para aplicações de monitorização florestal, estas soluções são insuficientes, uma vez que não indicam a extensão real da zona em chamas, dificultando a tomada de decisão e impedindo o mapeamento rigoroso da evolução do incêndio.

A necessidade de identificar com precisão as regiões atingidas motivou o desenvolvimento de métodos de segmentação semântica, nos quais cada pixel da imagem é classificado individualmente. Esta abordagem permite distinguir de forma clara as regiões de fogo e de fundo, produzindo máscaras segmentadas que representam a área exata das chamas. Entre os modelos mais eficazes para esta tarefa destacam-se as arquiteturas baseadas em U-Net, originalmente propostas para segmentação biomédica, mas amplamente adotadas em aplicações de observação remota devido à sua capacidade de combinar contexto global com detalhe local. Através da sua estrutura encoder–decoder e das skip-connections, a U-Net preserva informação espacial essencial para uma segmentação precisa.

Variantes residuais da U-Net, como a ResUNet, introduzem blocos residuais que facilitam o treino de redes mais profundas, aumentam a estabilidade do gradiente e permitem capturar padrões visuais mais complexos em cenários florestais. Estas propriedades são especialmente relevantes em incêndios, cujas chamas apresentam formas irregulares, variação luminosa acentuada e contrastes subtis em relação ao background.

Outro desafio inerente ao problema é o desbalanceamento da distribuição das classes: em grande parte das imagens, a região correspondente ao fogo representa apenas uma fração reduzida, enquanto o background domina o número total de pixels. Este fenómeno pode levar modelos treinados com funções de perda tradicionais, como a Cross-Entropy, a favorecer a classe dominante, prejudicando a deteção de regiões pequenas de fogo. Para mitigar este problema, a literatura recomenda o uso de funções de perda especializadas, como Dice Loss, Jaccard (IoU) Loss, Tversky Loss e variantes de Generalized Dice, que penalizam de forma mais eficaz erros na classe minoritária e favorecem uma segmentação equilibrada.

Assim, o enquadramento científico do problema demonstra que a segmentação semântica binária constitui uma abordagem tecnicamente fundamentada para a deteção precisa de regiões de fogo. A utilização de redes neuronais profundas, aliada a funções de perda adequadas e a datasets anotados manualmente, representa um avanço significativo relativamente aos métodos tradicionais, permitindo uma identificação rigorosa e uma compreensão fina das áreas efetivamente afetadas pelo incêndio.

Uma abordagem baseada em U-Net/ResUNet adaptada ao problema de segmentação do fogo e background surge, assim, como uma resposta tecnicamente sólida às limitações dos sistemas existentes, alinhando-se com as práticas científicas mais atuais e com as necessidades reais dos sistemas modernos de monitorização florestal.

## **Proposta de Inovação e Mais-Valias**

Com base na análise do estado da arte, verifica-se que muitas das soluções existentes apresentam limitações ao nível da precisão espacial e da capacidade de segmentação detalhada das regiões de fogo.

A principal inovação proposta neste trabalho reside na aplicação de uma arquitetura baseada em ResUNet-a à tarefa de segmentação binária pixel-a-pixel de incêndios florestais, explorando simultaneamente diferentes funções de perda e configurações de learning rate.

Esta abordagem permite:

- melhorar a deteção de regiões de fogo de pequena dimensão;
- aumentar a robustez do modelo face ao desbalanceamento de classes;
- obter segmentações mais precisas ao nível do pixel;
- reduzir a ocorrência de falsos positivos em cenários complexos;

Adicionalmente, a avaliação do modelo é realizada não apenas ao nível do conjunto de validação, mas também considerando o dataset completo, garantindo uma análise mais abrangente e representativa do desempenho global.

## **Identificação de Oportunidade de Negócio**

A crescente frequência e intensidade dos incêndios florestais, associada às alterações climáticas, tem vindo a aumentar a necessidade de soluções tecnológicas eficientes para monitorização e deteção precoce.

Neste contexto, a solução proposta apresenta elevado potencial de aplicação prática, podendo ser integrada em sistemas de vigilância baseados em drones, câmaras fixas ou plataformas de monitorização remota.

Os principais beneficiários incluem:

- entidades de proteção civil;
- corpos de bombeiros;
- organizações de gestão florestal;
- sistemas de monitorização ambiental;

A capacidade de segmentação precisa ao nível do pixel permite não só detetar a presença de fogo, mas também quantificar a área afetada, possibilitando uma melhor tomada de decisão e resposta operacional.

Desta forma, o desenvolvimento de sistemas baseados em deep learning para segmentação de incêndios representa uma oportunidade relevante tanto do ponto de vista tecnológico como económico, contribuindo para a mitigação dos impactos ambientais e sociais destes fenómenos. [Fir24]

## 3 - Viabilidade e Pertinência

A viabilidade do projeto assenta na demonstração de que a solução desenvolvida possui condições reais para ser integrada em sistemas de monitorização de incêndios, podendo evoluir além do contexto académico. A solução proposta baseia-se em segmentação semântica binária, utilizando arquiteturas U-Net ou ResUNet, amplamente reconhecidas na literatura como adequadas a problemas que exigem precisão espacial elevada e baixo custo computacional.

### Viabilidade Técnica

A opção por uma arquitetura do tipo encoder e decoder com skip connections permite que o modelo aprenda padrões de fogo, como as texturas, intensidades, variações de cor e formas, mesmo em cenários desafiantes, como forte variação luminosa, diferentes tipos de vegetação ou contraste reduzido. A classificação binária reduz significativamente a complexidade da tarefa, tornando o treino mais eficiente e menos dependente de grandes volumes de dados.

A opção por uma abordagem baseada em segmentação de incêndios, utilizando arquiteturas como U-Net ou ResUNet, revela-se tecnicamente viável e adequada ao problema em estudo.

Estas arquiteturas apresentam ainda diversas vantagens técnicas:

- conseguem combinar contexto global com detalhe local, essencial para delimitar de forma precisa regiões de fogo;
- são modelos leves quando comparados com arquiteturas mais complexas, permitindo execução em hardware convencional;
- oferecem estabilidade no treino, especialmente com variantes residuais como ResUNet, que mitigam problemas de gradiente e capturam padrões visuais complexos;
- podem ser ajustadas facilmente a diferentes cenários ambientais com simples reentrenamento do modelo.

A implementação do projeto com ferramentas consolidadas no ecossistema de deep learning — como PyTorch, TensorFlow ou bibliotecas equivalentes — reforça a viabilidade técnica, garantindo portabilidade, documentação extensa e compatibilidade com diferentes plataformas.

## **Viabilidade computacional e operacional**

Do ponto de vista computacional, o modelo pode ser treinado e executado em GPUs de gama média, como as presentes em ambientes académicos, mas também em plataformas de execução remota. A baixa complexidade das arquiteturas escolhidas permite inclusive inferência em tempo real em dispositivos de capacidade limitada, como edge devices, câmaras inteligentes ou sistemas de vigilância integrados.

Esta compatibilidade demonstra o potencial de integração do modelo em sistemas reais como:

- redes de videovigilância já instaladas (ex.: CICLOPE);
- drones equipados com câmaras RGB;
- torres de observação distribuídas por zonas florestais;

## **Viabilidade económica**

A viabilidade económica deriva da utilização exclusiva de câmaras RGB, que representam uma solução de baixo custo e dispensam sensores térmicos, hardware especializado ou infraestruturas dedicadas. A possibilidade de executar o modelo em equipamentos já existentes reduz despesas de instalação e manutenção e, adicionalmente, o processo de reentrenamento requer apenas a recolha e anotação de novas imagens, constituindo um custo controlável e escalável. O uso de ferramentas gratuitas e open-source elimina a necessidade de licenciamento, reforçando o rácio custo-benefício da solução e garantindo que a sua adoção por entidades como o ICNF, Proteção Civil ou equipas de vigilância florestal permanece economicamente viável.

## **Viabilidade científica**

A solução desenvolvida está fundamentada na literatura contemporânea de visão computacional e deep learning. Modelos como U-Net e ResUNet são amplamente aceites e validados pela comunidade científica em tarefas de segmentação densa, incluindo áreas biomédicas, agrícolas, industriais e florestais.

A definição do problema como segmentação binária está alinhada com práticas científicas recomendadas, permitindo:

- isolar um fenómeno visual, o fogo, sem interferência de classes adicionais;
- realizar análises mais controladas;
- obter resultados comparáveis com estudos existentes.

Em primeiro lugar, a solução desenvolvida está solidamente ancorada na literatura contemporânea em visão computacional e deep learning, integrando conceitos amplamente validados pela comunidade científica, como Redes Neurais Convolucionais (CNNs), segmentação semântica e arquiteturas encoder–decoder. Modelos como U-Net e ResUNet, utilizados neste trabalho, estão entre os mais referenciados na segmentação densa de imagens e demonstram desempenho robusto em diversas tarefas, incluindo aplicações biomédicas, agrícolas, industriais e de observação remota. A adaptação destas arquiteturas ao contexto específico de segmentação binária de fogo é, assim, metodologicamente adequada e teoricamente fundamentada.

O uso de funções de perda especializadas, como Dice Loss, Jaccard (IoU) Loss ou Tversky Loss, demonstra maturidade metodológica e compreensão do desbalanceamento das classes, garantindo rigor.

## **Pertinência**

A pertinência do projeto fundamenta-se diretamente na relevância crescente do problema dos incêndios florestais, que constituem uma das maiores ameaças ambientais, económicas e sociais em Portugal e no mundo. Estes eventos provocam perda de biodiversidade, destruição de património natural, emissões significativas de carbono e elevados custos operacionais associados às operações de combate e monitorização. Qualquer avanço que permita melhorar a deteção precoce e a caracterização espacial das áreas afetadas representa, portanto, um contributo valioso para a mitigação dos impactos destes fenómenos.[Fir13]

## **Contributo para a resolução do problema**

A solução proposta destaca-se pela sua capacidade de fornecer uma máscara segmentada que delimita de forma precisa a região afetada pelo fogo. Esta precisão espacial constitui um avanço face aos métodos tradicionais, que geralmente detetam apenas a presença de fogo sem indicar a sua extensão real.

Esta capacidade de delimitação é particularmente importante nas fases iniciais dos incêndios, quando pequenas ignições podem alastrar rapidamente. A informação detalhada fornecida pelo modelo pode apoiar mecanismos de alerta, resposta imediata e planeamento tático.

## **Superação das limitações dos sistemas existentes**

A solução proposta também se revela pertinente por responder diretamente a limitações existentes em sistemas de monitorização amplamente utilizados, como plataformas públicas (EFFIS, CICLOPE) ou soluções comerciais baseadas em deteção por caixa delimitadora. Embora úteis para identificar ocorrências, estas abordagens não capturam o contorno exato do fogo, o que reduz o seu valor operacional em tarefas como planeamento tático, previsão de progressão das chamas ou integração com modelos de propagação. A metodologia adotada neste projeto ultrapassa estas limitações, fornecendo uma máscara binária detalhada que pode apoiar decisões mais informadas e aumentar a eficácia das operações de vigilância e combate.

Ao fornecer segmentação binária precisa, o projeto supera estas limitações, oferecendo informação granular essencial para operações científicas e de proteção civil.

## **Relevância Científica**

O projeto integra-se numa linha crescente de investigação em visão computacional aplicada à deteção de incêndios. Ao adaptar arquiteturas validadas pela literatura (U-Net e ResUNet) ao contexto específico de segmentação de fogo, contribui para:

- aprofundar o conhecimento sobre segmentação em cenários naturais complexos;
- explorar variação luminosa e ruído visual característicos de chamas;
- fornecer uma base metodológica para futuros modelos multiclases.

O rigor metodológico, uso de funções de perda especializadas, tratamento de desbalanceamento, experimentação com learning rates, reforça o alinhamento do projeto com práticas científicas sólidas.

## **Impacto Social**

O Trabalho Final de Curso demonstra clara relevância ao apoiar um setor crítico como a proteção civil. A capacidade de detetar e delimitar rapidamente o fogo pode integrar-se em sistemas de vigilância existentes, permitindo decisões mais rápidas e fundamentadas por parte de autoridades, bombeiros e equipas florestais.

O seu potencial aplicação em drones, torres de vigilância ou câmaras fixas torna-o adaptável a diferentes cenários, reforçando o impacto na segurança das populações e preservação do território.

Finalmente, a pertinência do projeto evidencia-se na sua adaptabilidade e reprodutibilidade, características essenciais para qualquer solução científica que se pretenda duradoura. O modelo pode ser reentrenado com novos dados, ajustado a diferentes regiões geográficas e ampliado com datasets maiores, assegurando que a solução evolui ao longo do tempo e mantém relevância em distintos contextos operacionais. Esta natureza extensível confirma que o projeto não se esgota na conclusão do TFC, constituindo uma base sólida para futuras melhorias, investigações e aplicações práticas.

## 4 - Solução Proposta

A solução proposta neste projeto assenta na utilização de uma abordagem de segmentação semântica binária, concebida para identificar com elevada precisão a região exata onde o fogo está presente numa imagem RGB. Esta opção metodológica decorre diretamente do problema identificado no capítulo inicial, no qual se verificou a inexistência de sistemas capazes de realizar uma delimitação espacial rigorosa, pixel-a-pixel, do fogo em contextos de monitorização florestal. Assim, o objetivo central da solução é produzir uma máscara segmentada que distinga de forma clara o fogo do respetivo background, permitindo eliminar ambiguidades e fornecendo informação detalhada e operacionalmente útil.

A arquitetura selecionada para implementar esta solução baseia-se em modelos consolidados na literatura de visão computacional, nomeadamente variantes de U-Net e ResUNet. Estas arquiteturas, estruturadas segundo o paradigma encoder–decoder, revelam-se particularmente adequadas ao problema em estudo, uma vez que conseguem preservar simultaneamente o detalhe local e o contexto global da imagem através do uso de skip connections. Esta característica é essencial para capturar as irregularidades espaciais das chamas, que apresentam variações rápidas de forma, intensidade luminosa e textura. Para além disso, trata-se de modelos reconhecidos pela comunidade científica pela sua elevada precisão em tarefas de segmentação densa, aliando desempenho robusto a requisitos computacionais reduzidos, o que viabiliza a sua futura integração em sistemas reais, como câmaras de videovigilância, drones ou dispositivos de baixo consumo energético.

A escolha por uma formulação binária, distinguindo exclusivamente entre fogo e background, foi igualmente motivada por razões metodológicas e operacionais. Ao restringir o conjunto de classes a apenas duas categorias, torna-se possível desenvolver um modelo mais simples, eficiente e rápido de treinar, reduzindo a necessidade de grandes volumes de dados e mitigando a complexidade associada a problemas multiclasse. Esta simplificação permite ainda concentrar toda a capacidade discriminativa da rede na deteção precisa do fenómeno de interesse, garantindo resultados mais controlados e alinhados com os objetivos definidos para este TFC.

Do ponto de vista tecnológico, a implementação recorre a ferramentas amplamente estabelecidas no ecossistema de deep learning, com especial destaque para PyTorch, cuja maturidade, documentação extensa e compatibilidade com diferentes plataformas permitem assegurar reprodutibilidade, portabilidade e facilidade de manutenção. O pipeline desenvolvido contempla ainda etapas fundamentais como pré-processamento das imagens, normalização, criação e anotação manual de máscaras, divisão equilibrada do dataset e definição de funções de perda adequadas ao desbalanceamento intrínseco do problema, como Dice Loss ou Jaccard Loss. Estas escolhas evidenciam não só rigor metodológico, mas também alinhamento com práticas recomendadas na literatura científica em segmentação semântica.

A solução proposta integra igualmente princípios de escalabilidade e adaptabilidade. A arquitetura pode ser reentrenada com novos conjuntos de imagens, ajustada a diferentes regiões geográficas ou ampliada para cenários mais complexos caso, no futuro, se pretenda evoluir para tarefas multiclasse. Do ponto de vista operacional, a compatibilidade com hardware convencional e a possibilidade de inferência em tempo real reforçam a utilidade prática da solução, permitindo a sua integração em sistemas de vigilância já existentes sem necessidade de investimento significativo em sensores ou dispositivos especializados.

Por fim, esta solução articula conhecimentos provenientes de diversas áreas científicas do curso, incluindo visão computacional, redes neurais convolucionais, machine learning, processamento digital de imagem, estatística e análise de dados. Esta interdisciplinaridade garante que o desenvolvimento do modelo assenta em fundamentos sólidos e que o trabalho realizado pode ser replicado, ajustado e expandido em fases futuras, contribuindo de forma efetiva para a resolução do problema identificado e constituindo uma base consistente para evoluções e investigações subsequentes.

## **Descrição do Dataset**

O presente trabalho recorre a dois conjuntos de dados, um público e outro privado, utilizados na área da deteção de incêndios florestais: o Corsican Dataset e o FireFront Gestosa Dataset. Estes datasets fornecem imagens de incêndios capturadas em diferentes condições, contribuindo significativamente para o treino e validação dos modelos de segmentação e deteção.

Adicionalmente, foi criado um dataset personalizado com base em imagens provenientes destes dois conjuntos de dados, ao qual foram adicionadas manualmente máscaras de anotação detalhadas. Estas máscaras incluem a segmentação de áreas de fogo, fumo e fundo (ground truth). A anotação foi realizada manualmente, assegurando um elevado nível de precisão, o que permite ao modelo aprender de forma mais eficaz e adaptar-se melhor às características específicas do cenário em análise.

## **Corsican Dataset**

O Corsican Dataset contém imagens de incêndios florestais capturadas sob diferentes configurações de câmaras, utilizando espectros visíveis e infravermelhos próximos. As imagens apresentam uma resolução de 1024 × 768 pixels e encontram-se no formato PNG.

Este conjunto de dados inclui imagens multimodais obtidas por câmaras como a “JAI AD-080GE”, capazes de captar simultaneamente espectros visíveis e infravermelhos através de óticas alinhadas. Cada imagem do dataset é acompanhada por uma máscara de segmentação correspondente, criada através de técnicas de homografia que permitem um registo preciso entre as diferentes modalidades de imagem.

## **FireFront Gestosa Dataset**

O FireFront Gestosa Dataset é um conjunto de dados desenvolvido para apoiar investigação na detecção e segmentação de incêndios florestais. Este dataset contém imagens aéreas captadas em cenários reais, abrangendo uma ampla variedade de condições ambientais e diferentes intensidades de fogo.

As máscaras de anotação, essenciais para o treino supervisionado dos modelos, foram criadas manualmente utilizando a ferramenta MATLAB Image Labeler [5]. O processo de anotação consistiu na classificação de cada pixel das imagens em três categorias: fogo, fumo ou fundo.

## **Recolha de Dados**

O dataset utilizado é constituído por imagens reais de incêndios, acompanhadas por máscaras binárias que identificam as regiões correspondentes ao fogo. Cada máscara fornece informação ao nível do pixel, permitindo a aplicação de técnicas de segmentação supervisionada. Este tipo de anotação é fundamental para treinar modelos capazes de distinguir entre áreas de interesse e fundo.

## **Pré-processamento dos Dados**

O pré-processamento incluiu a conversão das imagens e máscaras para tensores, bem como a reorganização das dimensões para o formato esperado pelo framework PyTorch (batch, channels, height, width). As máscaras foram ajustadas para o formato adequado às funções de perda utilizadas, garantindo compatibilidade com o processo de treino.

O dataset foi dividido em dois subconjuntos:

- 75 para treino;
- 25 para validação;

Esta divisão permite avaliar a capacidade de generalização do modelo em dados não observados durante o treino.

## Metodologia e Implementação

A abordagem adotada baseia-se num pipeline de aprendizagem supervisionada, estruturado nas seguintes etapas:

- Preparação e organização dos dados;
- Pré-processamento das imagens e máscaras;
- Divisão do dataset em treino e validação;
- Definição e implementação da arquitetura do modelo;
- Treino do modelo com diferentes configurações;
- Avaliação do desempenho com métricas adequadas ao problema;

O processo foi conduzido de forma iterativa, permitindo testar diferentes combinações de hiperparâmetros, com especial foco na variação do learning rate e na análise do impacto de diferentes funções de perda.

Estadísticas do Dataset, o objetivo de caracterizar a distribuição dos dados utilizados no treino e avaliação do modelo, foi realizada uma análise ao nível dos píxeis, considerando a totalidade do dataset. Verificou-se que o dataset contém aproximadamente 13.107.200 píxeis, dos quais:

- 942.195 correspondem à classe fogo;
- 12.165.005 correspondem à classe background;

Em termos percentuais, a distribuição é a seguinte:

- Fogo: 7.19
- Background: 92.81

Estes dados evidenciam um elevado desbalanceamento entre classes, sendo a classe background claramente dominante.

Classe	Nº de píxeis	Percentagem
Fogo	942 195	7.19%
Background	12 165 005	92.81%

Table 4.1: Distribuição de píxeis por classe no dataset

## Descrição do Dataset e Desbalanceamento

As imagens são representadas como tensores RGB, enquanto as máscaras associadas contêm valores binários, indicando a presença ou ausência de fogo em cada pixel. A análise estatística do dataset revelou um forte desbalanceamento entre classes, com aproximadamente:

- 7.19 de pixels correspondentes à classe fogo;
- 92.81 de pixels correspondentes à classe background;

Estes valores evidenciam um forte desbalanceamento entre classes, sendo a classe background claramente dominante.

Este desequilíbrio constitui um desafio significativo, uma vez que pode induzir o modelo a privilegiar a classe dominante, comprometendo a detecção eficaz das regiões de fogo.

## Impacto do desbalanceamento na avaliação

O desbalanceamento observado tem implicações diretas na interpretação das métricas de desempenho do modelo. Em particular, métricas como a accuracy podem apresentar valores elevados mesmo em cenários onde a classe minoritária (fogo) não é corretamente identificada. Neste contexto, torna-se essencial recorrer a métricas mais robustas e informativas, tais como o F1 Score, o Jaccard Index (IoU) e a Balanced Accuracy, que permitem uma avaliação mais equilibrada do desempenho do modelo. Adicionalmente, a utilização da função de perda Generalized Dice revela-se adequada, uma vez que foi especificamente concebida para lidar com cenários de desbalanceamento entre classes. [Acc13]

## Resultados no Dataset Inteiro

Após a conclusão do processo de treino, foi realizada uma avaliação global do modelo recorrendo à totalidade do dataset, permitindo obter métricas mais representativas do seu desempenho global. Os dados obtidos para diferentes valores de learning rate encontram-se apresentados na Tabela que desenvolvi.

A implementação do projeto com ferramentas consolidadas no ecossistema de deep learning, como PyTorch, TensorFlow ou bibliotecas equivalentes, reforça a viabilidade técnica, garantindo portabilidade, documentação extensa e compatibilidade com diferentes plataformas.

## Configuração Experimental e Critérios

Verifica-se que o modelo apresenta um desempenho global elevado, registando valores de accuracy superiores a 0.95 para todas as configurações testadas. Contudo, tendo em conta o desbalanceamento do dataset, a análise deve centrar-se sobretudo em métricas mais exigentes, como o F1 Score e o IoU. O melhor desempenho global foi observado para um learning rate de 0.0001, com:

- F1 Score: 0.8933;
- IoU: 0.8072;

Estes dados sugerem uma elevada capacidade do modelo em identificar corretamente as regiões de fogo, mesmo na presença de um forte desbalanceamento entre classes.

Dado o desbalanceamento do dataset, foram selecionadas métricas mais robustas e adequadas ao problema de segmentação, como o F1 Score e o Intersection over Union (IoU), para além da accuracy.

Foram testados diferentes valores de learning rate (0,0001, 0,001 e 0,01), permitindo analisar o comportamento do modelo em diferentes regimes de aprendizagem.

Para o learning rate intermédio (0,001), observa-se uma ligeira redução no desempenho, mantendo ainda resultados consistentes e estáveis.

Por outro lado, para valores mais elevados (0,01), verifica-se uma degradação significativa nas métricas mais sensíveis, particularmente no F1 Score e no IoU, indicando uma menor estabilidade no processo de aprendizagem.

A implementação do projeto com ferramentas consolidadas no ecossistema de Deep Learning reforça a viabilidade técnica, garantindo portabilidade, documentação extensa e compatibilidade com diferentes plataformas.

Métrica	Justificação
Accuracy	Avaliação global do desempenho
Balanced Accuracy	Considera o desempenho em ambas as classes
F1 Score	Sensível à classe minoritária (fogo)
IoU (Jaccard)	Avaliação da qualidade da segmentação espacial

Table 4.2: Métricas utilizadas na avaliação do modelo

## **Relacao entre Métricas**

Apesar dos elevados valores de accuracy, verifica-se que as métricas F1 Score e IoU apresentam valores inferiores, o que confirma o impacto do desbalanceamento do dataset. Este comportamento evidencia que a accuracy, quando analisada isoladamente, não constitui uma métrica suficientemente robusta para avaliar o desempenho em tarefas de segmentação binária com classes desbalanceadas.

Assim, a análise conjunta de múltiplas métricas revela-se fundamental para uma avaliação rigorosa e completa do modelo.

## **Análise Exploratória dos Dados**

A análise exploratória evidenciou características importantes do dataset, nomeadamente:

- Forte predominância da classe background;
- Presença de regiões de fogo com formas irregulares e dimensões variadas;
- Distribuição espacial não uniforme dos pixels de interesse;

Estas características justificam a necessidade de utilizar abordagens robustas, tanto ao nível das métricas de avaliação como das funções de perda.

## **Modelos e Algoritmos Escolhidos**

A solução baseia-se na utilização da arquitetura ResUNet-A, uma evolução da arquitetura U-Net que integra residual connections. Estas ligações permitem melhorar a propagação do gradiente e reduzir problemas associados ao treino de redes profundas.

Adicionalmente, foi explorada uma nova variante arquitetural, designada ResUNetConcat, que introduz operações de concatenação no decoder. Esta abordagem permite preservar informação proveniente das camadas intermédias do encoder, contribuindo potencialmente para uma melhor reconstrução espacial das regiões de interesse.

Relativamente ao processo de otimização, foi utilizado o algoritmo Adam, conhecido pela sua eficiência e estabilidade em problemas de aprendizagem profunda.

Foram testadas diferentes funções de perda, nomeadamente:

- Cross Entropy Loss, adequada para problemas de classificação;
- Jaccard Loss, alinhada com a métrica IoU;
- Generalized Dice Loss, especialmente concebida para lidar com desbalanceamento entre classes;

A escolha destas funções permitiu analisar o impacto de diferentes estratégias de otimização no desempenho do modelo.

Learning Rate	Loss Function	Métricas de Avaliação
$1 \times 10^{-4}$	Generalized Dice	Accuracy, Balanced Accuracy, F1 Score, IoU
$1 \times 10^{-3}$	Generalized Dice	Accuracy, Balanced Accuracy, F1 Score, IoU
$1 \times 10^{-2}$	Generalized Dice	Accuracy, Balanced Accuracy, F1 Score, IoU

Table 4.3: Configurações experimentais testadas

## Abrangência

A solução proposta permite a segmentação automática de regiões de fogo em imagens, sendo aplicável a cenários de monitorização e deteção precoce de incêndios.

Adicionalmente, a abordagem desenvolvida possibilita a análise do impacto de diferentes configurações de treino, incluindo variações no learning rate, funções de perda e arquitetura do modelo.

No entanto, a sua aplicação encontra-se limitada ao dataset utilizado, sendo necessária validação adicional em dados externos para garantir robustez em cenários reais mais diversificados.

Learning Rate	Métrica	Generalized Dice
$4 \times 10^{-4}$	Accuracy	0.9857
	Balanced Accuracy	0.9446
	F1 Score	0.9002
	IoU	0.8185
$4 \times 10^{-3}$	Accuracy	0.9831
	Balanced Accuracy	0.9500
	F1 Score	0.8860
	IoU	0.7954
$4 \times 10^{-2}$	Accuracy	0.9824
	Balanced Accuracy	0.9392
	F1 Score	0.8787
	IoU	0.7836

Table 4.4: Desempenho do modelo para diferentes valores de learning rate

## 5 - Calendário

O calendário de atividades apresenta a organização e distribuição das tarefas necessárias para a conclusão do Trabalho Final de Curso, estruturando o plano de ação para o período remanescente do projeto.

Este planeamento segue uma lógica de gestão de projeto, procurando garantir uma sequência coerente de atividades, o cumprimento dos objetivos definidos e a capacidade de ajustar o desenvolvimento consoante dificuldades ou necessidades identificadas ao longo do percurso.

O cronograma centra-se nas fases do projeto, detalhando as tarefas que ainda necessitam de ser realizadas para completar o projeto. Complementarmente, apresenta também estimativas relativas ao trabalho posterior, nomeadamente a preparação e organização das etapas de avaliação e consolidação dos resultados.

Até ao momento, foram cumpridas as tarefas iniciais previstas no plano de trabalho, incluindo a Identificação do problema, revisão da literatura, a definição metodológica, a revisão bibliográfica, entre outras tarefas.

O desenvolvimento encontra-se em progresso, com a parte de implementação e observação do modelo já realizada.

O cronograma apresentado na figura detalha as etapas principais do projeto. Este plano de trabalho organiza-se em atividades principais: pesquisa científica, desenvolvimento do algoritmo U-Net, desenvolvimento do algoritmo ResUNet-a e Consolidação do Relatório.



Figure 5.1: Calendário de atividades do Trabalho Final de Curso

## **Pesquisa Científica**

Esta fase inicial concentrou-se na revisão da literatura e análise de abordagens existentes para a deteção de incêndios florestais.

Foram estudados sistemas como EFFIS, CICLOPE e soluções comerciais baseadas em visão computacional, bem como arquiteturas de segmentação relevantes, a U-Net e a ResUNet. Identificaram-se limitações dos métodos atuais e definiram-se as métricas, a metodologia e o enquadramento teórico que sustentam o desenvolvimento do projeto.

## **Desenvolvimento do Algoritmo U-Net**

Nesta fase procedeu-se à implementação, treino e avaliação de uma arquitetura baseada em U-Net, adaptada à tarefa de segmentação semântica binária de regiões de fogo em imagens RGB. A escolha desta arquitetura baseia-se na sua eficácia comprovada na preservação de informação espacial, através da combinação de um encoder que captura contexto global e de um decoder que permite a reconstrução detalhada das regiões de interesse.

O pipeline de desenvolvimento incluiu várias etapas fundamentais, nomeadamente a preparação e normalização dos dados, a definição das máscaras binárias (fogo vs. background) e a implementação do modelo no framework PyTorch. Foram ainda definidos mecanismos de treino supervisionado, recorrendo ao otimizador Adam e à utilização de batches para garantir estabilidade no processo de aprendizagem.

A avaliação do modelo foi realizada com base em múltiplas métricas de desempenho, como a Accuracy, a Balanced Accuracy, a F1 Score e a Intersection over Union (IoU), permitindo uma análise abrangente do comportamento do modelo, particularmente relevante em cenários de forte desbalanceamento entre classes.

Durante esta fase, foram testadas diferentes configurações de treino, com especial foco na variação da learning rate e na escolha da função de perda. Verificou-se que abordagens baseadas apenas em Cross-Entropy apresentam limitações na deteção da classe minoritária (fogo), conduzindo à necessidade de explorar funções de perda mais adequadas ao problema.

## Desenvolvimento do Algoritmo ResUNet-a

Com base nas limitações observadas na arquitetura U-Net, procedeu-se ao desenvolvimento de uma arquitetura mais avançada, designada ResUNet-a, que incorpora blocos residuais com o objetivo de melhorar a propagação do gradiente e permitir o treino de redes mais profundas e expressivas.

A introdução de residual connections revelou-se particularmente relevante para capturar padrões visuais mais complexos associados às regiões de fogo, caracterizadas por elevada variabilidade de forma, intensidade e textura. Esta arquitetura mantém a estrutura encoder-decoder típica da U-Net, mas beneficia de uma maior capacidade de generalização e estabilidade durante o treino.

Adicionalmente, explorei uma nova variante arquitetural (ResUNetConcat), baseada na utilização de operações de concatenação no decoder, permitindo preservar informação proveniente das camadas intermédias do encoder. Esta abordagem visa melhorar a reconstrução espacial das máscaras segmentadas, especialmente em regiões com fronteiras pouco definidas.

No processo de treino, foi adotada a função de perda Generalized Dice Loss, tendo em conta o elevado desbalanceamento do dataset. Esta escolha revelou-se fundamental para mitigar o enviesamento do modelo para a classe dominante, promovendo uma aprendizagem mais equilibrada.

Os resultados obtidos demonstraram que a arquitetura ResUNet-a apresenta um desempenho superior em métricas mais exigentes, como o F1 Score e o IoU, evidenciando uma maior capacidade de identificar corretamente regiões de fogo, mesmo em cenários complexos.

Por fim, o processo de desenvolvimento foi conduzido de forma iterativa, permitindo testar diferentes configurações de hiperparâmetros, nomeadamente a learning rate, e analisar o impacto destas escolhas na estabilidade e desempenho do modelo.[Rem25]

## Bibliografia

- [Mat24] João P. Matos-Carvalho. *The Lusófona L<sup>A</sup>T<sub>E</sub>X Template User's Manual*. Lusófona University. 2024. URL: <https://github.com/jpmcarvalho/UL-Thesis>.
- [Nov21] Novas Metodologias. *Novas Metodologias para a Prevenção de Incêndios Florestais*. 2021. URL: <https://webgate.ec.europa.eu/life/publicWebsite/project/LIFE18-ENV-PT-000361/life-landscape-fire-project-new-methodologies-for-forest-fire-prevention>.
- [NAS00] NASA. *NASA Fire Information for Resource Management System*. <https://firms.modaps.eosdis.nasa.gov/map/#d:24hrs;@-4.6,0.3,2.9z>. 2000.
- [Eur98] European Forest Fire Information System. *EFFIS - European Forest Fire Information System*. <https://forest-fire.emergency.copernicus.eu/>. 1998.
- [CIC00] CICLOPE. *CICLOPE – Sistema Português de Videovigilância Florestal*. [https://www.ciclope.com.pt/index\\_pt.html](https://www.ciclope.com.pt/index_pt.html). 2000.
- [Imp23] Improving wildland fire spread prediction using deep U-Nets. *Improving wildland fire spread prediction using deep U-Nets*. 2023. URL: <https://www.sciencedirect.com/science/article/pii/S2666017223000263>.
- [U-N95] U-Net SB. *Arquitetura U-Net | Encoder-Decoder*. 1995. URL: [https://sebastianraschka.com/pdf/lecture-notes/stat453ss21/L16\\_autoencoder\\_slides.pdf](https://sebastianraschka.com/pdf/lecture-notes/stat453ss21/L16_autoencoder_slides.pdf).
- [Con10] Convolutional Network. *Arquitetura U-Net - Convolutional Network*. 2010. URL: <https://lmb.informatik.uni-freiburg.de/people/ronneber/u-net/>.
- [Fir24] Fire Detection with Deep Learning. *Fire Detection with Deep Learning*. 2024. URL: <https://www.mdpi.com/2073-445X/13/10/1696>.
- [Fir13] Fire Project. *LIFE Landscape Fire Project, European Commission*. 2013. URL: [https://books.google.pt/books?hl=pt-PT&lr=&id=bR0rZTkqUeMC&oi=fnd&pg=PR3&dq=LIFE+Landscape+Fire+Project&ots=LZjRFnCqWh&sig=LV2aBX64hjo9Q8is0pTAFqiPXL0&redir\\_esc=y#v=onepage&q=LIFE%20Landscape%20Fire%20Project&f=false](https://books.google.pt/books?hl=pt-PT&lr=&id=bR0rZTkqUeMC&oi=fnd&pg=PR3&dq=LIFE+Landscape+Fire+Project&ots=LZjRFnCqWh&sig=LV2aBX64hjo9Q8is0pTAFqiPXL0&redir_esc=y#v=onepage&q=LIFE%20Landscape%20Fire%20Project&f=false).
- [Acc13] Accuracy. *Limitations on the accuracy of model predictions of wildland fire behaviour*. 2013. URL: [https://www.researchgate.net/publication/277369148\\_Limitations\\_on\\_the\\_accuracy\\_of\\_model\\_predictions\\_of\\_wildland\\_fire\\_behaviour\\_A\\_state-of-the-knowledge\\_overview](https://www.researchgate.net/publication/277369148_Limitations_on_the_accuracy_of_model_predictions_of_wildland_fire_behaviour_A_state-of-the-knowledge_overview).
- [Rem25] Remote<sub>wild</sub>. *Remote Sensing for Wildfire Mapping*. 2025. URL: <https://www.mdpi.com/2571-6255/8/8/316>.