



**montanha
viva**

Intelligent Predictive System for Decision Support in Sustainability



Fundão
Câmara Municipal



E.4.3. Investigação e desenvolvimento do módulo de Inteligência Artificial e suporte à decisão

Abril de 2024

Conteúdo

Conteúdo	2
Sumário.....	3
1. Introdução.....	4
2. Objetivos.....	4
3. Investigaçāo e desenvolvimento do módulo de Inteligēncia Artificial e suporte à decisāo	4
4. Resultados	8
5. Conclusōes	11

Sumário

O Projeto Montanha Viva tem como objetivo desenvolver um sistema de apoio à decisão, inteligente e com funcionamento em tempo real, na exploração económica de plantas de montanha, especialmente em locais remotos (sem ligação à internet), para estimular o aproveitamento económico das plantas existentes, aumentar a produção, reduzir o consumo de recursos naturais, contribuindo para a promoção da biodiversidade e preservação da sustentabilidade ambiental, em particular das plantas silvestres de montanha.

Os seus objetivos são:

- Recolher informação básica e produzir dados de identificação e caracterização de plantas de montanha com propriedades de aplicação na saúde e bem-estar e com características potenciadoras de mitigação natural de pragas e doenças em culturas agrícolas na região montanhosa da Serra da Gardunha, promovendo a sustentabilidade das explorações agroflorestais existentes e o desenvolvimento de novos produtos e novos negócios a partir da utilização da flora silvestre.
- Avaliar e caracterizar as propriedades biológicas das espécies selecionadas com base na recolha de informação proveniente de levantamentos etnobotânicos.
- Adaptar soluções tecnológicas existentes e/ou desenvolver soluções específicas para a monitorização local em zonas remotas e inóspitas (com gradientes Termo higrométricos muito elevados).
- Analisar o potencial da deteção remota de alta resolução para a classificação das espécies e deteção do seu estado fenológico.
- Desenvolver um sistema inteligente de previsão do vigor das plantas de montanha, informação e apoio à decisão em sustentabilidade ambiental, de forma a otimizar o cultivo/exploração de plantas silvestres na região de montanha.
- Promover a sensibilização sustentável, através da instalação de mesas interpretativas e informação digital com identificação e divulgação do valor ambiental, paisagístico e patrimonial da flora que visam a sensibilização e planeamento da visitação às zonas de montanha.
- Dinamizar os percursos turísticos para a promoção da sustentabilidade da montanha através da sensibilização para a biodiversidade local.
- Comunicar, divulgar, transferir dados e tecnologia e disseminar os resultados do projeto.

Este documento tem como objetivo explicar desenvolvimento do módulo de Inteligência Artificial e suporte à decisão, analisar o potencial da deteção remota de alta resolução para a classificação das espécies e deteção do seu estado fenológico para o projeto Montanha Viva.

Palavras-Chave: Redes Neuronais Convolucionais, Classificação de Plantas, Inteligência Artificial, Estado fenológico, Treino do algoritmo, Validação de resultados.

1. Introdução

Nos últimos anos, o fosso entre a agricultura e a tecnologia diminuiu com o desenvolvimento da Agricultura 4.0, que utiliza ferramentas como a Internet das Coisas, a robótica e a inteligência artificial para otimizar vários processos agrícolas.

Esta atividade visa o desenvolvimento de um sistema previsional inteligente do vigor de plantas de montanha e de informação e suporte à decisão em sustentabilidade ambiental.

O sistema previsional é composto por um módulo de deteção e reconhecimento de folhas e flores de plantas, podendo ser usado com sistema de apoio à decisão do momento de realização das mais variadas atividades culturais.

A deteção e reconhecimento das folhas das plantas são realizadas por intermédio de algoritmos de inteligência artificial de processamento de imagem.

Esta subsecção analisa o desenvolvimento da tarefa relativa ao desenvolvimento do módulo de IA e suporte à decisão. Esta tarefa requer tarefas de preparação das imagens para deteção e reconhecimento, treino do algoritmo e validação de resultados.

2. Objetivos

Esta tarefa é relativa ao desenvolvimento do módulo de Inteligência Artificial (IA) e suporte à decisão. Desta forma, os objetivos são a realização de tarefas de preparação das imagens para deteção e reconhecimento, treino do algoritmo e validação de resultados.

Este trabalho pode ser dividido nas seguintes partes: Aquisição das imagens; Separação das imagens pelo seu nome, estado fenológico e por treino e validação; Treino do algoritmo; e Validação dos resultados.

Este relatório foca-se na explicação destes passos necessários para a Investigação e desenvolvimento do módulo de Inteligência Artificial e suporte à decisão para o projeto Montanha Viva.

3. Investigação e desenvolvimento do módulo de Inteligência Artificial e suporte à decisão

A utilização da classificação e deteção têm como objetivo desenvolver um sistema que permita detetar e identificar rapidamente as plantas. Uma vez detetada a planta, será utilizado um modelo de classificação para determinar o nome da espécie e a fenologia da mesma, por exemplo *Armenia transmontana* com flor.

Inicialmente, o objetivo principal é recolher informação para ter um algoritmo robusto capaz de fornecer a informação necessária para a fase seguinte deste projeto. Isto será conseguido através da recolha de dados, neste caso imagens.

Estes dados serão também utilizados para criar um conjunto de dados que será útil para futuros estudos desta natureza e, mais importante, para o projeto.

Tendo isto em conta, o primeiro passo necessário é a aquisição de imagens das várias espécies em estudo, em locais distintos, com diferentes perspetivas, condições de luminosidade, profundidades e estado fenológico (com e sem flor). No entanto, estas espécies devem estar separadas por fotografias, ou seja, não deve aparecer duas espécies distintas numa só imagem.

De seguida, as imagens capturadas necessitam de ser separadas. Esta divisão deve ser, inicialmente, por nome de espécie e consoante o seu estado fenológico. A Figura 1, ilustra através de pastas a divisão necessária. Na Figura 1. a), uma representação da separação das imagens por nome de espécie e estado fenológico; e na Figura 1.b), a segmentação destas imagens para treino e validação do algoritmo. Temos neste momento uma base de dados com um total de 3665 imagens, sendo 15% para validação, cerca de 592 imagens, e os restantes 85%, cerca de 3073 imagens, para o treino da rede, divididos por 27 classes, ou seja, espécies com e sem flor.

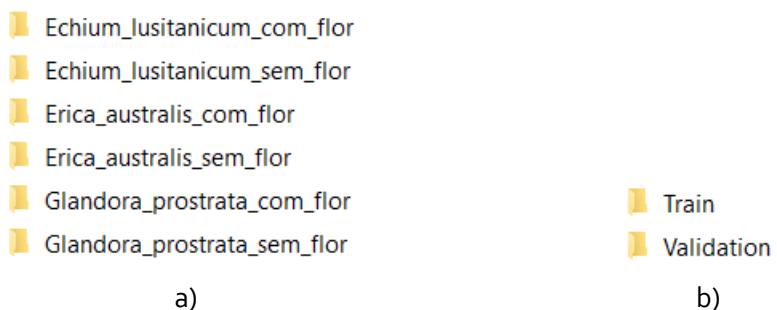
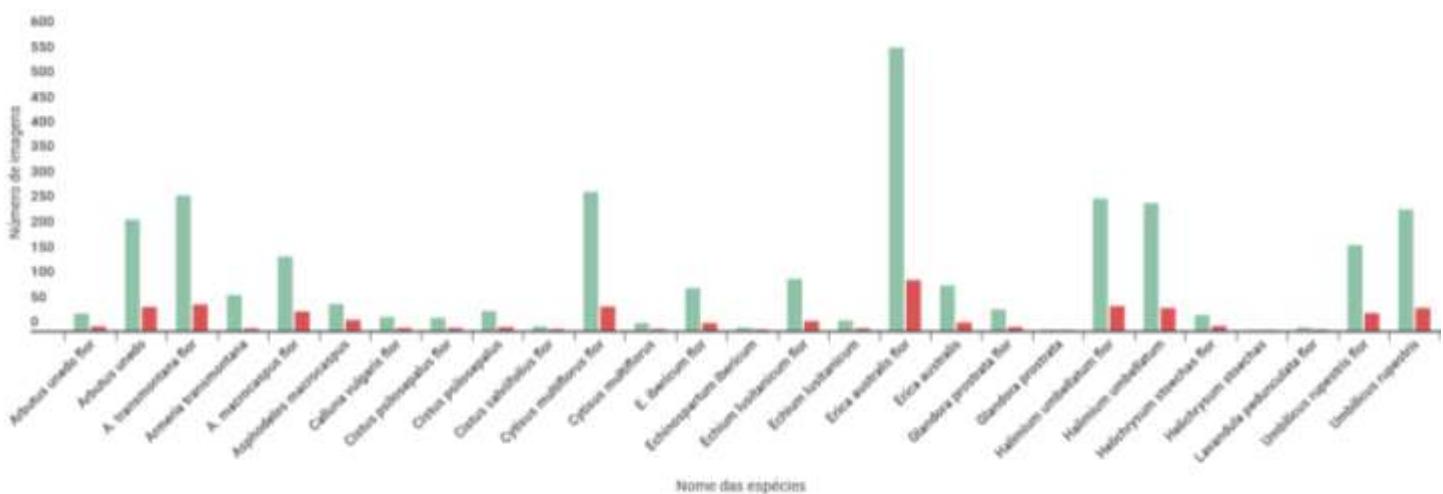


Figura 1: Divisão das imagens: a) separação das imagens por nome de espécie e estado fenológico; b) segmentação das mesmas imagens para treino e validação do algoritmo.

A Figura 2 ilustra a divisão das imagens, consoante o número de fotografias adquiridas. Na Figura 2 a) encontra-se exposta a tabela com todas as espécies (1^a coluna) em estudo divididas em flor e sem flor. Na 2^a e 3^a colunas, está apresentado o número de imagens para treino e validação, respetivamente. Na Figura 2 b) é exposta uma representação gráfica desta mesma divisão, sendo o verde o número de imagens para treino, o vermelho para validação. Neste gráfico, as espécies que não contêm a palavra "flor" são as imagens das plantas sem flor.

Espécies	Treino	Validação
<i>Arbutus unedo</i> com flor	34	8
<i>Arbutus unedo</i> sem flor	222	47
<i>Armeria Transmontana</i> com flor	270	52
<i>Armeria Transmontana</i> sem flor	71	4
<i>Asphodelos macrocaspus</i> com flor	148	38
<i>Asphodelos macrocaspus</i> sem flor	53	21
<i>Calluna vulgaris</i> com_flor	27	5
<i>Cistus psilosepalus</i> com flor	25	5
<i>Cistus psilosepalus</i> sem flor	39	7
<i>Cistus salviifolius</i> com flor	8	3
<i>Cytisus multiflorus</i> com flor	277	48
<i>Cytisus multiflorus</i> sem flor	15	3
<i>Echinospartum ibericum</i> com flor	85	15
<i>Echinospartum ibericum</i> sem flor	6	2
<i>Echium lusitanicum</i> com flor	103	19
<i>Echium lusitanicum</i> sem flor	20	4
<i>Erica australis</i> com flor	566	101
<i>Erica australis</i> sem flor	90	16
<i>Glandora prostrata</i> com flor	42	7
<i>Glandora prostrata</i> sem flor	2	1
<i>Halimium umbellatum</i> com flor	264	49
<i>Halimium umbellatum</i> sem flor	255	45
<i>Helichrysum stoechas</i> com flor	31	9
<i>Helichrysum stoechas</i> sem flor	1	1
<i>Lavandula pedunculata</i> com flor	6	2
<i>Umbilicus rupestris</i> com flor	171	35
<i>Umbilicus rupestris</i> sem flor	242	45

a) Divisão das imagens entre as pastas espécie com flor e espécie sem flor, e de seguida o número de imagens divididas para treino e validação de cada espécie.



b) Representação gráfica da divisão das imagens entre as pastas.

Figura 2: Número de espécie com flor e sem flor, número de imagens divididas para treino (verde) e validação (vermelho).

Tendo em conta esta divisão, o conjunto de dados é então utilizado para treinar o modelo, e o grupo de validação, avalia o desempenho do modelo em imagens que não foram utilizadas durante o treino, ou seja, imagens que o modelo nunca viu. Durante este processo é necessária a escolha do modelo que mais se enquadra na tarefa. Como já referido em relatórios anteriores, foram escolhidas as redes neurais convolucionais (CNN), nomeadamente, as arquiteturas, EfficientNet_B5, MaxVit e ShuffleNet V2_x0_5, que, após diversos testes, demonstraram ser as que melhor se comportavam em tarefas com um grande número de imagens e de complexidade.

Para além disto, utilizaram-se os seguintes hiperparâmetros, uma taxa de aprendizagem (*learning rate*) de 0,0001; um tamanho do pacote (*batch size*) de 4; número de iterações igual a 11 de forma a evitar a sobreaproximação (*overfitting*). Estes parâmetros foram decididos após a realização de testes para saber qual a melhor combinação.

Após a fase de treino, o modelo entra na etapa de validação, cujo objetivo é avaliar a eficácia do modelo e da arquitetura utilizada. Neste processo, as métricas de avaliação utilizadas foram a precisão (*accuracy*) e a perda (*loss*). A precisão consiste numa medida que indica a proporção de exemplos classificados corretamente pelo modelo em relação ao número total de exemplos. Quanto mais perto de 100%, mais corretamente o modelo está a executar todas as previsões corretamente, enquanto uma precisão nula indica que o modelo não está a fazer nenhuma previsão correta. Por fim, a perda é uma medida do quanto bem o modelo está a ser realizado durante o treino. Uma perda baixa indica que o modelo está a produzir previsões próximas aos rótulos verdadeiros, enquanto uma perda elevada indica que as previsões são distantes dos rótulos verdadeiros.

A Figura 3 apresenta um fluxograma com todas as etapas necessárias e explicadas anteriormente, para o desenvolvimento do módulo de Inteligência Artificial e suporte à decisão.

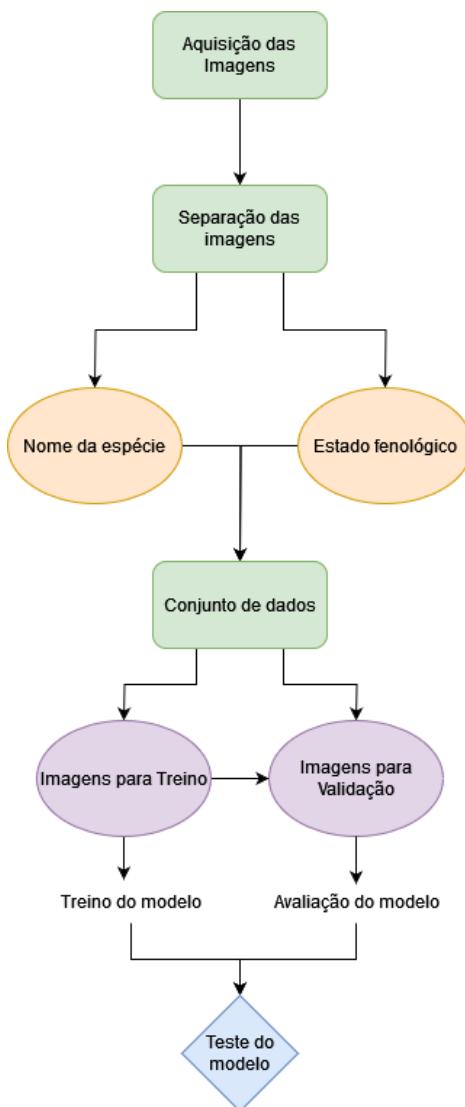


Figura 3: Fluxograma que representa a sequência de passos da tarefa de desenvolvimento do módulo de Inteligência Artificial e suporte à decisão.

4. Resultados

Tendo em conta a quantidade de imagens obtida, bem como as diferentes espécies em estudo, as arquiteturas têm obtido bastante bons resultados. Assim, com 3073 imagens para treino e 592 para validação, os resultados foram os seguintes.

A arquitetura EfficientNet_B5 obteve uma precisão máxima de validação de 90% na iteração 25, e uma perda mínima de 0,0001. A Figura 4 apresenta 3 gráficos distintos dos resultados da validação do EfficientNet_B5. Na Figura 4 a) são expostos os resultados da precisão da arquitetura ao longo de 100 iterações; na Figura 4 b) são apresentados os resultados da perda; Na Figura 4 c) é

apresentada a comparação dos resultados de perda e precisão. Note-se que nestes gráficos os valores de precisão estão apresentados entre 0 e 1.

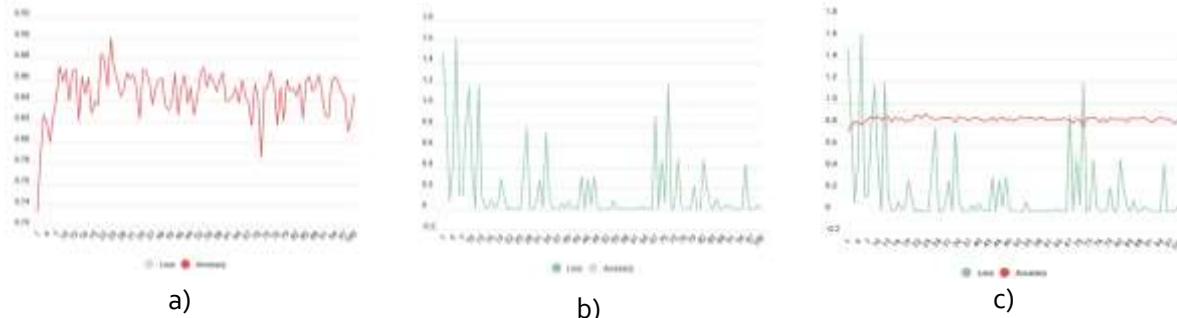


Figura 2: Resultados durante a validação do EfficientNet_B5; a) Resultados de precisão; b) Resultados de perda; c) Comparação de ambos os resultados num só gráfico.

A arquitetura MaxVit obteve uma máxima precisão de validação de 90.2% na iteração 12, e uma perda mínima de 0,0002. A Figura 5 apresenta três gráficos distintos dos resultados do MaxVit durante a validação. Na Figura 5 a) são expostos os resultados da precisão da arquitetura ao longo de 100 iterações; Na Figura 5 b) são apresentados os resultados da perda; e na Figura 5 c) é exposta a comparação dos resultados de perda e precisão. Note-se que nestes gráficos os valores de precisão estão apresentados entre 0 e 1.

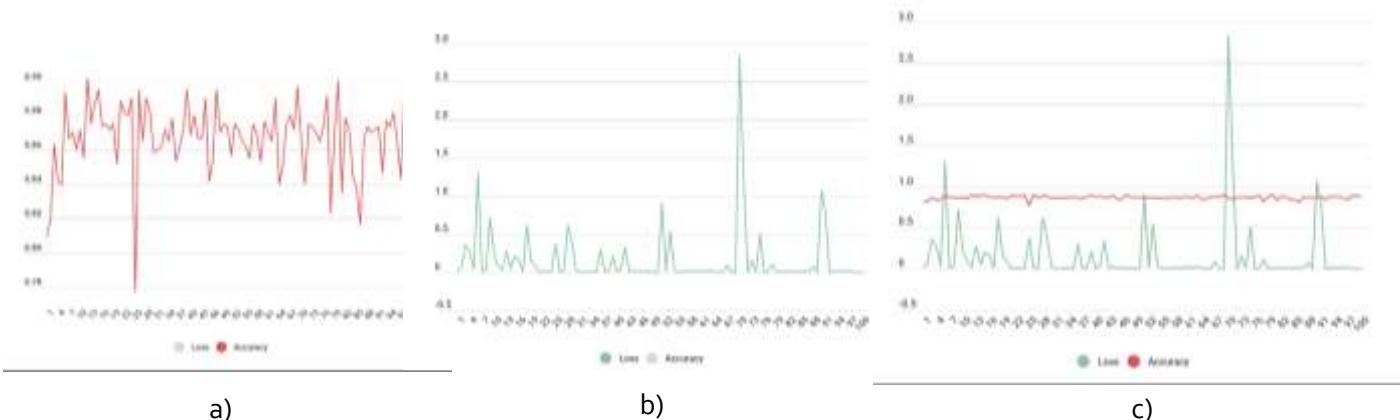


Figura 3: Resultados da fase de validação do MaxVit; a) Resultados de precisão; b) Resultados de perda; c) Comparação de ambos os resultados num só gráfico.

A arquitetura ShuffleNet V2_x0_5 obteve uma máxima precisão de validação de 86.66% na iteração 96, e uma perda mínima de 0,0015. A Figura 6 apresenta três gráficos distintos dos resultados do ShuffleNet V2_x0_5 na fase de validação. Na Figura 6 a) são expostos os resultados da precisão da arquitetura ao longo de 100 iterações; Na Figura 6 b) encontram-se os resultados da

perda; Na Figura 6 c) é exposta a comparação dos resultados de perda e precisão. Note-se que nestes gráficos os valores de precisão estão apresentados entre 0 e 1.

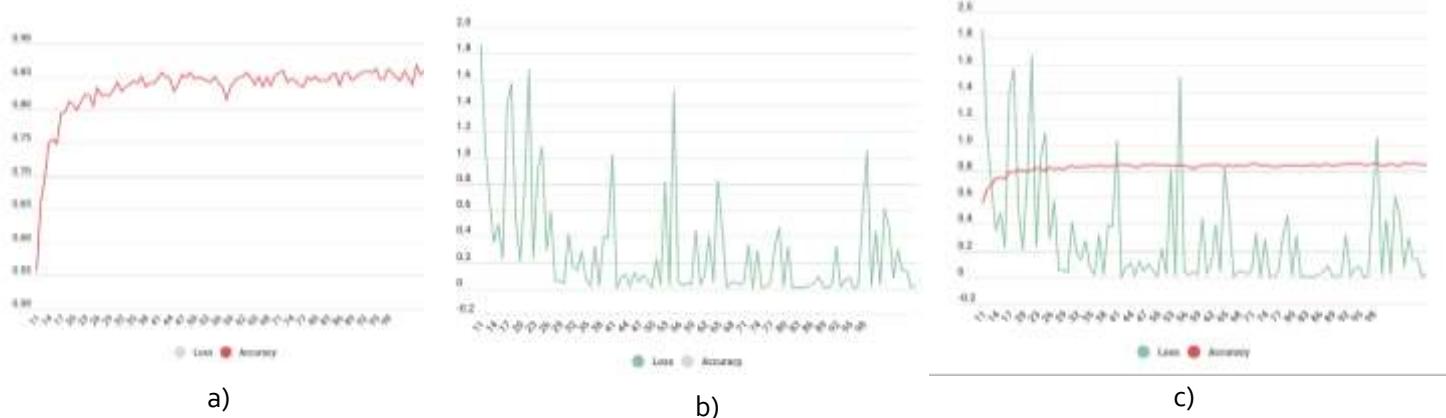


Figura 4: Resultados da fase de validação do *ShuffleNet V2_xo_5*; a) Resultados de precisão; b) Resultados de perda; c) Comparação de ambos os resultados num só gráfico.



Figure 5: Exemplo do protótipo da aplicação em Gradio, no caso da espécie *Umbilicus rupestris* sem flor.

Na figura 5 é apresentado um excerto do protótipo da aplicação desenvolvida em Gradio. Neste teste é possível observar a inserção de uma imagem com a planta *Umbilicus rupestris*, mais conhecida por chapéus-de-parede, esta imagem foi carregada e o nome da espécie foi devolvido bem como o seu estado fenológico. Como é possível observar na coluna de previsão da espécie, mais à direita, o nome da espécie carregada foi “*Umbilicus rupestris sem flor*”.

Na figura 6 é apresentado um excerto do protótipo da aplicação desenvolvida em Gradio. Neste teste é possível observar a inserção de uma imagem com a planta Armeria transmontana, mais conhecida por Cravo-divino, esta imagem foi carregada e o nome da espécie foi devolvido bem como o seu estado fenológico. Como é possível observar na coluna de previsão da espécie, mais à direita, o nome da espécie carregada foi “Armeria transmontana com flor”



Figure 6: Exemplo do protótipo da aplicação em Gradio, no caso da espécie *Armeria transmontana* com flor.

5. Conclusões

O Projeto Montanha Viva visa desenvolver um sistema inteligente de apoio à decisão, focado na exploração económica de plantas de montanha, especialmente em áreas remotas.

Ao longo deste relatório, foi detalhado o desenvolvimento do módulo de Inteligência Artificial e suporte à decisão, com ênfase na utilização de CNNs para a classificação e deteção de plantas. Foram definidos objetivos claros, desde a aquisição e preparação das imagens até o treino e validação dos algoritmos. Os resultados obtidos foram promissores, com a arquitetura EfficientNet_B5 alcançando uma precisão máxima de 90% na iteração 25. Esses resultados demonstram a eficácia do modelo desenvolvido na classificação e identificação das plantas de montanha, mesmo em condições desafiadoras.

Em suma, o trabalho realizado neste relatório representa um avanço significativo no desenvolvimento de sistemas inteligentes para a gestão sustentável de recursos naturais, com potenciais aplicações não apenas na exploração económica de plantas de montanha, mas também em outras áreas da agricultura e conservação ambiental.