



**Sistema de Monitorização
da Ocupação do Solo**

Painel de inovação: Novos produtos SMOS com tecnologia espacial e inteligência artificial

Moderação:



Mário Caetano

Chefe da Equipa Multidisciplinar Inteligência Geoespacial da DGT





COS



Cartografia temática

- COS
- COS conjuntural: anual e pré-verão
- Mapa Anual de Culturas Agrícolas Temporárias **Experimental**
- Carta de Interfaces de Áreas Edificadas
- Mapas Intra-anuais do Estado da Vegetação
- Carta de Perdas de Vegetação **Experimental**

Cartografia topográfica

- Mosaicos mensais Sentinel 2
- Ortofotomapas
- LiDAR
- Cartografia topográfica 10k
- Fotografia aérea antiga



Painel de inovação

Novos produtos SMOS com tecnologia espacial e inteligência artificial



Centro Nacional
de Computação Avançada

João Pina



INSTITUTO
SUPERIOR DE
AGRONOMIA
Universidade de Lisboa

Manuel Campagnolo



LABORATÓRIO DE INSTRUMENTAÇÃO
E FÍSICA EXPERIMENTAL DE PARTÍCULAS
partículas e tecnologia

João Pina

Inês Ochoa



UNIVERSIDADE
DE ÉVORA

Sérgio Godinho



Ciências
ULisboa

Ana Navarro



Direção-Geral do Território

Hugo Costa

Pedro Benevides



INESCTEC

Carlos Ferreira

*Instituto de Engenharia de Sistemas e
Computadores, Tecnologia e Ciência*



Painel de inovação



Novos produtos SMOS com tecnologia espacial e inteligência artificial

Hugo Costa





COS



Cartografia temática


- COS
- COS conjuntural: anual e pré-verão
- Mapa Anual de Culturas Agrícolas Temporárias **Experimental**
- Carta de Interfaces de Áreas Edificadas
- Mapas Intra-anuais do Estado da Vegetação
- Carta de Perdas de Vegetação **Experimental**

Cartografia topográfica

- Mosaicos mensais Sentinel 2
- Ortofotomapas
- LiDAR
- Cartografia topográfica 10k
- Fotografia aérea antiga




Produtos mensais







Mosaicos Sentinel-2



Verdura da Vegetação (VV)




Percentil Homólogo da
Verdura da Vegetação (PHVV)



Diferença Mensal da
Verdura da Vegetação (PHVV)



Produto bimestral




Carta de Perdas de Vegetação em Floresta e Mato


Experimental



Produtos anuais




Carta de Ocupação do Solo
Conjuntural (COSc)



Mapa Anual de Culturas
Agrícolas Temporárias (MACAT)

Experimental



Carta de Interface de Áreas
Edificadas (CIAE) Conjuntural






Produtos anuais

Agosto 2021




Agosto 2022

Agosto 2024


Sentinel-2




COSc




Atualiza a COSc em algumas classes




Classes atualizadas
(perdas de vegetação)



Carta de Interface de Áreas Edificadas (CIAE) pré-verão




Carta de perigosidade de Incêndio
Rural do ICNF




COSc



Produtos multianuais



Carta de Uso e Ocupação do Solo (COS)



Cartografia de imagem de muito grande resolução espacial (ortoimagens)



Fichas de produto

**Sistema de Monitorização da Ocupação do Solo**

Cartografia de uso e ocupação do solo

O Sistema de Monitorização da Ocupação do Solo (SMOS) integra duas cartografias de uso e ocupação do solo que se complementam.

Produtos SMOS → ☐ Cartografia de base ☒ Cartografia de uso e ocupação do solo ☐ Produtos cartográficos específicos

COS

A Carta de Uso e Ocupação do Solo é a cartografia de referência a nível nacional. A COS é produzida por interpretação visual de ortofotomapas.

COSc

A Carta de Ocupação do Solo Conjuntural é uma nova cartografia. A COSc é produzida por técnicas de Inteligência Artificial e imagens de satélite.

→ As cartografias são complementares por representarem conceitos diferentes (uso e ocupação) com diferente detalhe espacial, detalhe temático e frequência de atualização.

→ As cartografias podem ser usadas em conjunto ou em separado conforme as necessidades dos utilizadores.

Uso versus ocupação:

Uso do solo

Uso do solo refere-se à utilização ou finalidade com que uma área é explorada do ponto de vista da atividade humana, por exemplo, atividades económicas, sociais e ambientais.

Ocupação do solo

Ocupação do solo refere-se aos elementos biofísicos que cobrem a superfície, por exemplo, vegetação, água ou edificações.

Os dois conceitos (uso e ocupação) estão fortemente ligados e são muitas vezes entendidos como sinónimos. No entanto, há casos em que divergem. Por exemplo, uma área de uso florestal, e portanto, identificada na COS como **Floresta**, pode ser classificada na COSc como **Superfície sem vegetação**, **Vegetação herbácea espontânea** ou **Matos**, se nesse ano estiver temporariamente desarboreada devido a um corte ou fogo.

 **dg Território**
Direção-Geral do Território

smos.dgterritorio.gov.pt

Cartografia de uso e ocupação do solo

Temático e espacial

A COSc é uma cartografia de conjuntura, pelo que, em planeamento e gestão a médio prazo, a cartografia relevante continua a ser a COS. A COSc poderá ser útil em exercícios de planeamento e programação conjuntural.

Cartografia vetorial e raster

A COSc é uma cartografia vetorial de polígonos com uma unidade mínima cartográfica de 1 hectare. O desenho dos polígonos respeita regras de generalização cartográfica, omitindo detalhes de menor dimensão para minimizar ruído e garantir a legibilidade. A COSc é uma cartografia raster com pixels de 10 metros determinados pelas imagens de satélite.

A área identificada como Superfície agroflorestal (SAF) na COS (Bergel) é classificada em diferentes classes na COSc: Agricultura (amarido) e Sobrelheira e Azinheira (roxo). A COSc permite, portanto, com a sua estrutura regular de pixels de 10 m, distinguir os diferentes tipos de cobertura em áreas compostas por vários elementos, como as SAF, mas também trechos edificadas descontínuas e outras paisagens heterogêneas.

smos.dgterritorio.gov.pt

Cartografia de uso e ocupação do solo

Temático e espacial

A COSc é uma cartografia de conjuntura, pelo que, em planeamento e gestão a médio prazo, a cartografia relevante continua a ser a COS. A COSc poderá ser útil em exercícios de planeamento e programação conjuntural.

Cartografia vetorial e raster

A COSc é uma cartografia vetorial de polígonos com uma unidade mínima cartográfica de 1 hectare. O desenho dos polígonos respeita regras de generalização cartográfica, omitindo detalhes de menor dimensão para minimizar ruído e garantir a legibilidade. A COSc é uma cartografia raster com pixels de 10 metros determinados pelas imagens de satélite.

A área identificada como Superfície agroflorestal (SAF) na COS (Bergel) é classificada em diferentes classes na COSc: Agricultura (amarido) e Sobrelheira e Azinheira (roxo). A COSc permite, portanto, com a sua estrutura regular de pixels de 10 m, distinguir os diferentes tipos de cobertura em áreas compostas por vários elementos, como as SAF, mas também trechos edificadas descontínuas e outras paisagens heterogêneas.

smos.dgterritorio.gov.pt

smos.dgterritorio.gov.pt



Painel de inovação

Novos produtos SMOS com tecnologia espacial e inteligência artificial

João Pina

CNCA

Centro Nacional
de Computação Avançada



LABORATÓRIO DE INSTRUMENTAÇÃO
E FÍSICA EXPERIMENTAL DE PARTÍCULAS
partículas e tecnologia



Sobre o LIP e o CNCA

Laboratório de Instrumentação e Física Experimental de Partículas

- Instituição de referência para a física experimental de partículas em Portugal.
- Parceiro do CERN e de outras infraestruturas científicas internacionais.

Centro Nacional de Computação Avançada

- Computação de alto desempenho.
- Computação distribuída.
- Dados de investigação.

LIP e CNCA (ex-INCD) têm colaborado ao longo dos anos no desenvolvimento de plataformas e centro de dados para várias disciplinas.



<https://www.lip.pt/>




<https://www.incd.pt>

<https://www.acnca.pt>

Desenvolvimento do Centro de Dados


- Plataforma para permitir a transferência e acesso aos dados:
 - o Dados LiDAR (**em produção**):
 - Formato LAS comprimido (LAZ), Modelos Digitais de Terreno (MDT), Modelos Digitais de Superfície (MDS)
 - Dados LiDAR em formato otimizado para visualização (**em desenvolvimento**)



<https://cdd.dgterritorio.gov.pt>

Desenvolvimento do Centro de Dados

- Recurso a catálogos espacio-temporais
 - Vantagens dos catálogos STAC
 - **Acesso uniforme a diferentes tipos de dados**
 - Efetuar pesquisas nos catálogos para zonas geográficas ao longo de períodos de tempo



- Dados Sentinel 2 (**em desenvolvimento**)
 - Imagens Sentinel 2 sem nuvens
 - COSc: Carta de Ocupação de Solo conjuntural
 - Macat: Mapa anual de culturas agrícolas temporárias
 - MIAEV: Mapas infra anuais do estado de Vegetação
 - Carta de Perdas de Vegetação (CPV)

Desafios e requisitos: Dimensão dos dados e Elevado número de datasets



Painel de inovação

Novos produtos SMOS com tecnologia espacial e inteligência artificial


Ana Navarro



**Ciências
ULisboa**

Evolução do Mapa Anual de Culturas Agrícolas Temporárias (MACAT) para o Mapa Anual de Culturas Agrícolas (MACA)

PRINCIPAIS CARACTERÍSTICAS	MACAT	MACA
Tipo de culturas	Temporárias	Temporárias e Permanentes
Máscara com as áreas a classificar identificadas na última versão da COS	Classe 2 (Agricultura)	Classe 2 (Agricultura) Áreas alteradas nas classes 3 (Pastagens), 5 (Florestas) e 6 (Matos)
Classes da nomenclatura	36	24
Unidade Espacial de Processamento	Unidade de Paisagem (UP)	Quadrícula WGS84/UTM (Tile)
Algoritmo de classificação	Random Forest	Support Vector Machine






Nomenclatura do Mapa Anual de Culturas Agrícolas (MACA)

NOMENCLATURA MACA

20 culturas temporárias do MACAT


4 culturas permanentes

sendo estas as culturas mais representativas em Portugal continental



CLASSES DA NOMENCLATURA MACA	CLASSES DA NOMENCLATURA MACA
Milho	Abóboras e aboborinhas
Aveia	Batata
Arroz	Tremocilha
Trigo	Girassol
Tomate	Grão de bico
Azevém	Feijão
Ervilha	Matos
Triticale	Vegetação herbácea espontânea
Cevada	Vinha
Outras hortícolas	Olival
Centeio	Pomares de folha caduca
Sorgo	Pomares de folha persistente

Identificação de novas áreas agrícolas nas áreas classificadas como pastagens, florestas e matos na última versão da COS



COS 2018



Imagens Sentinel-2 do dia 15.03.2023






COS 2018 atualizada

Tile SNC

COS 2018 atualizada


Legenda

- Agricultura
- Pastagens
- Florestas
- Novas áreas agrícolas



Tile TPF


Random Forests (RF) versus Support Vector Machines (SVM)



$n_estimators = ?$
 $max_depth = ?$
 $max_features = ?$

TREINO
(80%)

TESTE
(20%)




$C = ?$
 $gamma = ?$


TREINO
(80%)

TESTE
(20%)


Resultados preliminares



Métricas de exatidão obtidas por *Tile* com o algoritmo *Support Vector Machine* (SVM)




Métricas de exatidão obtidas por *Tile* com o algoritmo *Random Forest* (RF)





% Tiles em que uma dada cultura existente no treino é classificada com um F1-score superior a



CLASSE (Nº Tiles)	F1-score	% Tiles em que a classe entra no treino
Arroz (4)	0.9	100
Vinha (14)	0.7	100
Tomate (3)	0.7	100
Girassol (2)	0.7	100
Olival (13)	0.7	92
Cevada (7)	0.7	71
Milho (11)	0.7	64
Trigo (10)	0.7	50
Grão de bico (2)	0.7	50
Ervilha (6)	0.5	83
Centeio (5)	0.5	80
Matos (14)	0.5	79
Pomares folha persistente (11)	0.5	73
Pomares folha caduca (11)	0.5	70
Aveia (13)	0.5	69
Triticale (6)	0.5	67
Tremocilha (3)	0.5	67
Sorgo (8)	0.5	63
Veg. herbácea espontânea (13)	0.5	62
Abóboras e aboborinhas (8)	0.5	50
Azevém (13)	0.5	46
Outras hortícolas (12)	0.5	33
Batata (8)	0.5	25
Feijão (3)	-	-



Painel de inovação

Novos produtos SMOS com tecnologia espacial e inteligência artificial

Manuel Campagnolo



INSTITUTO
SUPERIOR DE
AGRONOMIA
Universidade de Lisboa



Desenvolvimento de mapas de perdas recentes de floresta e mato em Portugal derivados de imagens de satélite (colaboração DGT/ISA)

Objetivos principais:

1. Criação de uma base de **dados de referência** de perdas de vegetação para Portugal Continental
2. **Implementação operacional** de uma metodologia automática com base em imagens de satélite
3. Produto nacional de **delimitação de manchas vetoriais** superiores a 0.5 ha de perda recente de floresta e mato, com uma **periodicidade de pelo menos dois meses**
4. Adicionalmente, identificação sistemática do **agente causador** das perdas recentes de floresta e mato



Desafios:

1. Abranger a totalidade do território de Portugal Continental
2. Usar um grande volume de dados (série temporal de imagens Sentinel-2 desde 2017)
3. Processar dados com periodicidade bimestral
4. Validar os produtos obtidos de forma precisa



Aplicação de técnica automática de deteção de alterações (CCD) a imagens Sentinel-2

Nesta figuras comparam-se dois pontos em talhões de eucaliptal:

1) não sofreu corte durante o período maio 2017-final 2024;






2) foi sujeito a corte em maio de 2023



Nota: o algoritmo para Landsat foi adaptado a Sentinel-2 (13 bandas, 10 m)

Comparação com o produto experimental de Cartas de Perdas de Vegetação (DGT)




Na mesma zona de eucaliptal, a identificação da perda de vegetação é mais fiável quando se usa a **série temporal completa de imagens Sentinel-2**, em vez de usar apenas compósitos mensais.

Mas o processamento da totalidade da série é muito mais **exigente do ponto de vista computacional**, sobretudo quando tem que ser realizada com periodicidade bimestral.

O que se pretende é um produto vetorial com área mínima de 0.25-0.5 ha.

- 1) Processamento ao nível do pixel
- 2) Análise ao nível da imagem (deep learning)

Ambas as técnicas são **exigentes em recursos computacionais**



Detecção consistente com os dados de referência que indicam corte em eucalipto



Recursos computacionais e a necessidade de processar dados em HPC

Para Portugal Continental e para a série complete Sentinel-2 até final de 2024

1) Análise ao nível do pixel:

Número de imagens S2 por tile (17 tiles)	~ 800 imagens (2017—2024)
Tamanho dos dados (por banda)	~ 0.75 TB
Número de pixels (potenciais áreas de perda de floresta e mato)	aprox 500 000 000
Tempo de computação (HPC com 480 threads – CIRRUS/CNCA)	10 dias
Tempo de computação (máquina local)	aprox 30 vezes mais

2) Análise ao nível da paisagem com deep learning:

- Treinar (ou *fine-tuning*) modelos de *deep learning* para segmentação das imagens (exige GPUs)
- Aplicar modelo ao conjunto do território com periodicidade bimestral

Conclusão: existem técnicas promissoras para obter mapas de perdas de vegetação com boa qualidade mas que exigem acesso a infraestruturas de armazenamento de dados e de computação avançada.



Painel de inovação

Novos produtos SMOS com tecnologia espacial e inteligência artificial

João Pina

CNCA


Centro Nacional
de Computação Avançada



LABORATÓRIO DE INSTRUMENTAÇÃO
E FÍSICA EXPERIMENTAL DE PARTÍCULAS
partículas e tecnologia

- Previsão mensal:

- Assente em meios do Centro Nacional de Computação Avançada (CNCA)
- Processamento automático por intermédio de workflow customizado



- Grande volume de dados e elevado poder computacional:

- Acesso ao mapas de Sentinel2 sem nuvens produzidos
- Análise ocorre em ambiente cluster (modo HPC) recorrendo simultaneamente a dezenas de nós de computação



Infraestrutura Física e virtual (CNCA)

Assente em meios do Centro Nacional de Computação Avançada

- Lisboa (LNEC)
- Vila Real (UTAD)
- Armazenamento de dados
 - o Objetos compatível S3 para os dados
- Computação em nuvem
 - o Virtualização IaaS
 - o Contentorização
- Computação alta performance:
 - o Cluster HPC
 - o Cluster GPU
 - o Máquinas de muita alta memória





Painel de inovação

Novos produtos SMOS com tecnologia espacial e inteligência artificial


Inês Ochoa



LABORATÓRIO DE INSTRUMENTAÇÃO
E FÍSICA EXPERIMENTAL DE PARTÍCULAS
partículas e tecnologia


Sentinel-2

900 milhões píxeis de 10 m



Pléiades Neo

8100 milhões píxeis de 30 cm



Mapeamento com técnicas de *Deep Learning*: porquê?



- ✓ Para capturar e interpretar o contexto espacial de cada píxel, de forma generalizável, para várias categorias de ocupação.
- ✓ Para analisar grandes volumes de dados.
- ✓ Para automatizar o processo de produção de mapas a larga escala.




É necessário *criar um modelo especializado para o* território Português.

Mapeamento com técnicas de *Deep Learning*: porquê?



⇒ Reutilização de mapas de ocupação do território existentes (COSc — 10 m de resolução) para gerar mapas de alta resolução (30 cm).



DOI:10.1109/CVPR52733.2024.02618

Da OrtoSat2023 a um novo mapa de ocupação de solo a 30 cm

Imagem



COSc2023



- Artificializado
- Culturas anuais de outono/inverno
- Culturas anuais de primavera/verão
- Outras áreas agrícolas
- Águas
- Zonas húmidas

Novo mapa a 30 cm (preliminar)



- Edifícios
- Estrada de alcatrão
- Outro artificializado

Da OrtoSat2023 a um novo mapa de ocupação de solo a 30 cm


Imagem



COSc2023



Novo mapa a 30 cm (preliminar)





Painel de inovação

Novos produtos SMOS com tecnologia espacial e inteligência artificial

Carlos Ferreira



Desenvolvimento de metodologias automáticas para a deteção de edifícios utilizando Inteligência Artificial e imagens de muito grande resolução espacial

Tarefa A. Identificação de edifícios num só ortofotomapa




Ortofotomapa de entrada



Mapa de saída

Desenvolvimento de metodologias automáticas para a deteção de edifícios utilizando Inteligência Artificial e imagens de muito grande resolução espacial

Metodologia de identificação de edifícios num só ortofotomapa **baseada em objetos**



1. Modelo Segment Anything Model (SAM) identifica todos os objetos automaticamente (sem classificar)

2. Refinar mapa utilizando dados cartográficos (mapa de uso de solo e Microsoft Global Building Footprints)


3. Modelo de classificação binário para identificar objetos que são edifícios

Desenvolvimento de metodologias automáticas para a deteção de edifícios utilizando Inteligência Artificial e imagens de muito grande resolução espacial


Metodologia de identificação de edifícios num só ortofotomapa **baseada em píxeis**

Abordagem utilizada pela Microsoft para a criação do Dataset Microsoft Building Footprints. A identificação de edifícios é realizada em duas etapas:

1. Segmentação Semântica – Reconhecimento de pixels de edifícios numa imagem aérea utilizando redes neurais profundas (DNNs)




2. Polygonização – Conversão das deteções de pixels de edifícios em polígonos



Desenvolvimento de metodologias automáticas para a deteção de edifícios utilizando Inteligência Artificial e imagens de muito grande resolução espacial

Tarefa B. Deteção de mudança entre um ortofotomapa referência (data anterior) e um ortofotomapa alvo (data posterior)



Ortofotomapa referência



Ortofotomapa alvo



Mapa de saída



Desenvolvimento de metodologias automáticas para a deteção de edifícios utilizando Inteligência Artificial e imagens de muito grande resolução espacial

Contribuições

- Aumento da eficiência nos processos internos da DGT
- Reforço da colaboração entre entidades e impulso à inovação tecnológica
- Avanços na identificação de edifícios e deteção de mudanças em imagens de alta resolução



Painel de inovação


Novos produtos SMOS com tecnologia espacial e inteligência artificial

Pedro Benevides







Imagem satélite – Falsa cor



Modelo Digital de Superfície (MDS)




Modelo Digital de Terreno (MDT)




Diferença entre MDS e MDT

- Processamento pontos LiDAR:
 - Modelo de altura das copas
 - Detecção individual de árvores




Estimação topo das árvores –
Altura da árvore




Segmentação das árvores –
Área da copa

- Processamento pontos LiDAR:
 - Modelo de altura das copas
 - Detecção individual de árvores




Estimação topo das árvores –
Altura da árvore




Segmentação das árvores –
Área da copa




- Processamento pontos LiDAR:
 - Modelo de altura das copas
 - Detecção individual de árvores




Estimação topo das árvores –
Altura da árvore




Segmentação das árvores –
Área da copa




- Processamento pontos LiDAR:
 - Modelo de altura das copas
 - Detecção individual de árvores




Estimação topo das árvores –
Altura da árvore




Segmentação das árvores –
Área da copa




- Processamento pontos LiDAR:
 - Modelo de altura das copas
 - Detecção individual de árvores




Estimação topo das árvores –
Altura da árvore




Segmentação das árvores –
Área da copa




Modelo de altura de copas – exemplo Pomares




Modelo de altura de copas – exemplo Pomares



Modelo de altura de copas – exemplo Pomares



Modelo de altura de copas – exemplo Pomares






Criação de alertas – Floresta em excesso





Polígono COS da classe "Outros Carvalhos"







Criação de alertas – Floresta em excesso



Deteção de vegetação (≥ 1.5 m)





Criação de alertas – Floresta em excesso



Deteção de vegetação (≥ 1.5 m)





Criação de alertas – Floresta em excesso



Categorização da altura das árvores





Criação de alertas – Floresta em excesso




Deteção de vegetação (≥ 1.5 m)



Criação de alertas – Floresta em excesso




Altura das copas ≥ 3.5 m





Utilização do LiDAR para detecção automática de culturas permanente em áreas agrícolas COS

- Objetivo: geração de alertas para áreas que não estão no parcelário do IFAP
- Dados dos topos das árvores
- Algoritmo de clustering de pontos:
 - Número mínimo de pontos
 - Distância máxima entre pontos
- Criação de polígonos a partir dos clusters de pontos, usando o algoritmo Convex Hull



Identificação de permanentes – Áreas agrícolas COS





Identificação de permanentes – Áreas agrícolas COS



Identificação de permanentes – Áreas agrícolas COS





Identificação de permanentes – Áreas agrícolas COS







Classe Olival – Caracterização de diferentes subclasses



Olival em copa de baixa densidade



Olival em copa de alta densidade



Olival em sebe






Painel de inovação



Novos produtos SMOS com tecnologia espacial e inteligência artificial

Sérgio Godinho





UNIVERSIDADE
DE ÉVORA






Combinação da tecnologia LiDAR, Radar (SAR) e multiespectral







Produção da COSc baseada na combinação multi-sensor



Nomenclatura da Carta de Ocupação do Solo Conjuntural (COSc)

Nível 3	
100	Artificializado
211	Culturas anuais de outono/inverno*
212	Culturas anuais de primavera/verão*
213	Outras áreas agrícolas*
311	Sobreiro e Azinheira
312	Eucalipto
313	Outras folhosas
321	Pinheiro bravo
322	Pinheiro manso
323	Outras resinosas
410	Matos
420	Vegetação herbácea espontânea
500	Superfícies sem vegetação
610	Zonas húmidas
620	Água





Sistema
colaborativo

Painel de inovação



Centro Nacional
de Computação Avançada

João Pina



INSTITUTO
SUPERIOR DE
AGRONOMIA
Universidade de Lisboa

Manuel Campagnolo



LABORATÓRIO DE INSTRUMENTAÇÃO
E FÍSICA EXPERIMENTAL DE PARTÍCULAS
partículas e tecnologia

João Pina

Inês Ochoa



UNIVERSIDADE
DE ÉVORA

Sérgio Godinho



Ciências
ULisboa

Ana Navarro



Direção-Geral do Território

Hugo Costa

Pedro Benevides



Carlos Ferreira

*Instituto de Engenharia de Sistemas e
Computadores, Tecnologia e Ciência*