



**Validação da utilização do CCDC em séries temporais Sentinel-2
para a deteção de desflorestação em Portugal**

Confronto com dados históricos de gestão florestal

Filipe José Afonso Sabino de Sousa Louro

Dissertação

apresentada como requisito parcial para obtenção do grau de Mestre em Ciência e Sistemas de Informação Geográfica

NOVA Information Management School

Instituto Superior de Estatística e Gestão de Informação

Universidade Nova de Lisboa

NOVA Information Management School
Instituto Superior de Estatística e Gestão de Informação
Universidade Nova de Lisboa

**VALIDAÇÃO DA UTILIZAÇÃO DO CCDC EM SÉRIES TEMPORAIS SENTINEL-2 PARA A DETEÇÃO
DE DESFLORESTAÇÃO EM PORTUGAL**
Confronto com dados históricos de gestão florestal

por
Filipe José Afonso Sabino de Sousa Louro

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre em Ciência
e Sistemas de Informação Geográfica

Orientada por:

Mário Caetano, PhD, NOVA Information Management School
Hugo Costa, PhD, NOVA Information Management School

Novembro, 2024

DECLARAÇÃO DE INTEGRIDADE

Declaro que o trabalho contido neste documento é da minha autoria e não de outra pessoa. Toda a assistência recebida de outras pessoas está devidamente identificadas e é efetuada referência a todas as fontes utilizadas (publicadas ou não).

O trabalho não foi anteriormente submetido ou avaliado na NOVA Information Management School ou em qualquer outra instituição. Declaro ainda que tenho conhecimento das Regras de Conduta e do Código de Honra da NOVA Information Management School.

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL GENERATIVA

Tarefas	NÃO	SIM	Ferramentas de Inteligência Artificial Generativa
Compreender melhor as questões relacionadas com a investigação	X		
Resumir texto de bibliografia / recursos	X		
Resumo do(s) método(s) utilizado(s)	X		
Tradução de texto	X		
Verificação gramatical	X		
Parafrasear ou reescrever texto de outras pessoas/recursos	X		
Codificação em R, Python, etc.		X	ChatGPT (OpenAI)
Obter ajuda sobre um software		X	ChatGPT (OpenAI)
Criação e edição de imagens, mapas, vídeos, etc.	X		
Análise de dados	X		

AGRADECIMENTOS

Agradeço aos professores Mário Caetano e Hugo Costa pela orientação e disponibilidade.

Agradeço à The Navigator Company pelo apoio prestado, destacando a ajuda da Susana Morais e do José Luis Carvalho.

Agradeço à minha família pelo suporte e incentivo.

VALIDAÇÃO DA UTILIZAÇÃO DO CCDC EM SÉRIES TEMPORAIS SENTINEL-2 PARA A DETEÇÃO DE DESFLORESTAÇÃO EM PORTUGAL

Confronto com dados históricos de gestão florestal

RESUMO

O planeamento de gestão florestal e sua respetiva monitorização são questões complexas que exigem um acompanhamento regular. No entanto, o minifúndio existente atualmente em Portugal e o crescente abandono rural fazem com que esta tarefa árdua seja muitas vezes inalcançável. A utilização de dados de deteção remota para a monitorização de recursos naturais tem evoluído desde o surgimento de fotografias aéreas no século XX, que possibilitaram a supressão de necessidades pontuais e estáticas de cartografia de uso e ocupação do solo, até à mais recente e liberal disponibilização de séries temporais de imagens de satélite, que tem permitido detetar alterações de uso e ocupação do solo de forma cada vez mais dinâmica e responsiva. O algoritmo Continuous Change Detection and Classification (CCDC) foi descrito pela primeira vez em 2014, destacando-se por permitir analisar tendências intra e inter-anuais de séries temporais de imagens de satélite. Tem sido utilizado na monitorização contínua de alterações de ocupação do solo, utilizando quase exclusivamente séries temporais de Landsat, e raramente na Europa. A utilização de séries temporais de Sentinel-2, com resoluções espaciais e temporais superiores, e já com uma extensão temporal relevante, pode ser a chave que possibilita a utilização do CCDC para a monitorização de povoamentos florestais em Portugal e na Europa. Este estudo pretende validar parametrizações e otimizações do fluxo processual para a utilização do CCDC e Sentinel-2 para deteção de instâncias de desflorestação em Portugal recentemente publicadas, confrontando a metodologia com dados de referência de exploração e outras ações de silvicultura cedidos pela The Navigator Company, empresa responsável pela gestão de uma das maiores áreas florestais do país. Os resultados obtidos apresentam boa correspondência com os dados de referência e são bastante promissores em relação à utilização desta metodologia para monitorização de povoamentos florestais portugueses, permitindo realizar uma gestão florestal mais adequada, sustentável e responsável.

PALAVRAS-CHAVE

Deteção de Alterações Contínua; Desflorestação; Monitorização de Ocupação do Solo; Sentinel-2; Gestão Florestal Sustentável

Objetivos do Desenvolvimento Sustentável (ODS):



VALIDATION OF CCDC USE WITH SENTINEL-2 TIME SERIES FOR DEFORESTATION DETECTION IN PORTUGAL

Comparison with historical forest management data

ABSTRACT

Forest management planning and its monitoring are complex issues that require regular oversight. However, the actual prevalence of smallholdings in Portugal and the increasing rural abandonment make this challenging task often unachievable. The use of remote sensing data for natural resources monitoring has evolved since the advent of aerial photography in the 20th century, which initially allowed for specific, static land use and cover mapping, to the more recent, freely available satellite image time series, enabling the detection of land use and land cover changes in a more dynamic and responsive manner. The Continuous Change Detection and Classification (CCDC) algorithm was first described in 2014 and is notable for allowing the analysis of intra- and inter-annual trends in satellite imagery time series. It has been used for continuous land cover change monitoring, primarily relying on Landsat time series, and rarely applied in Europe. The use of Sentinel-2 time series, with superior spatial and temporal resolutions and now with a significant historical extent, could be the key to enabling CCDC for monitoring forest stands in Portugal and Europe. This study aims to validate recently published parameter settings and process flow optimizations for the use of CCDC and Sentinel-2 for detecting deforestation events in Portugal, comparing the methodology with reference data on logging and other forestry activities provided by The Navigator Company, responsible for managing one of the largest forest areas in the country. The results show good correspondence with the reference data and are very promising regarding the use of this methodology for monitoring Portuguese forest stands, enabling a more suitable, sustainable, and responsible forest management approach.

KEYWORDS

Continuous Change Detection; Deforestation; Land Cover Monitoring; Sentinel-2; Sustainable Forest Management

Sustainable Development Goals (SGD):



ÍNDICE

DECLARAÇÃO DE INTEGRIDADE.....	iii
UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL GENERATIVA	iv
AGRADECIMENTOS	v
RESUMO.....	vi
ÍNDICE DE TABELAS.....	xi
ÍNDICE DE FIGURAS.....	xii
1. INTRODUÇÃO	1
1.1 ENQUADRAMENTO	1
1.2. DETEÇÃO DE ALTERAÇÕES DE USO E OCUPAÇÃO DO SOLO	3
1.3. CONTINUOUS CHANGE DETECTION AND CLASSIFICATION	6
1.4. OBJETIVO	9
2. MATERIAIS E MÉTODOS	11
2.1. ESTADO DA ARTE.....	11
2.2. PARAMETRIZAÇÃO E FLUXO DO PROCESSO	12
2.3. DADOS DE REFERÊNCIA	14
2.4. VALIDAÇÃO	17
3. RESULTADOS E DISCUSSÃO	19
4. CONCLUSÃO	31
REFERÊNCIAS BIBLIOGRÁFICAS.....	33
APÊNDICE A	43
APÊNDICE B.....	46
APÊNDICE C.....	48

ÍNDICE DE TABELAS

Tabela 1 - Comparação de cortes florestais detetados pelo CCDC com dados de referência, por talhão.	19
Tabela 2 - Comparação de quebras detetadas pelo CCDC com dados de referência, por área.	19
Tabela 3 - Tabela comparativa de quebras detetadas pelo CCDC com registos históricos reais de operações de silvicultura.	21
Tabela 4 - Comparação de quebras detetadas pelo CCDC com dados de referência por áreas de talhão médio (cima) e áreas de talhão mediano (baixo).	24
Tabela 5 – P-values obtidos pelo teste estatístico Tuckey HSD, não tendo detetado diferenças significativas entre grupos ($p > 0,05$).	25
Tabela 6 - Resultados de acordo com a região administrativa.	26
Tabela 7 - Resultados discriminados por região administrativa.	26
Tabela 8 - Distribuição dos resultados Falsos Positivos por região administrativa.	27
Tabela 9 - Casos de estudo com utilização do CCDC publicados entre 2014 e 2023	43

ÍNDICE DE FIGURAS

Figura 1 - Mapa representativo da área moda de cada freguesia de Portugal continental de acordo com o 6º Inventário Florestal Nacional (ICNF, 2019b).....	2
Figura 2 - Exemplo de aplicação do CCDC e identificação de quebra (break) retirado do artigo original de Zhu & Woodcock (2014).....	7
Figura 3 - Histograma representativo da publicação de estudos de alteração de ocupação do solo em florestas com CCDC.....	8
Figura 4 - Tipos de dados de referência utilizados para validação de estudos de alteração de ocupação do solo em florestas com CCDC.	9
Figura 5 - Diagrama do fluxo de obtenção e tratamento de estado de arte produzido de acordo com o método padrão PRISMA descrito por Haddaway et al. (2020).....	11
Figura 6 - Diagrama do fluxo de processamento para obtenção de mapa de quebras..	14
Figura 7 - Distribuição geográfica dos talhões de floresta de produção de eucalipto analisados para este estudo sobre mapa OpenStreetMap.	15
Figura 8 - Histograma de área dos talhões estudados, por classes de área com intervalo de 10 ha.	16
Figura 9 - Comparação entre um talhão Navigator cuja floresta foi explorada e as áreas detetadas pelo CCDC como quebra sobre uma imagem falsa cor Sentinel-2.	20
Figura 10 - Área florestal afetada por incêndio entre 05/08/2023 e 09/08/2023 detetada com CCDC sobre imagens falsa cor de Sentinel-2.	20
Figura 11 - Comparação entre um talhão Navigator alvo de Limpeza Mecânica com as áreas detetadas pelo CCDC como quebra sobre uma imagem falsa cor Sentinel-2.	21
Figura 12 - Ilustração de alteração de ocupação detetada com CCDC devido a aumento de vegetação espontânea sobre imagens de falsa cor de Sentinel-2.....	23
Figura 13 – Gráfico representativo dos diferentes valores de NDVI ao longo do tempo, as respetivas curvas de valores esperados (regressão LASSO) e quebra (break) identificado pelo CCDC em 30/12/2023.	23
Figura 14 – Gráfico representativo dos diferentes valores de NDVI ao longo do tempo, as respetivas curvas de valores esperados (regressão LASSO) e quebra (break) identificado pelo CCDC em 23/02/2023.	24

Figura 15 – Gráfico boxplot com as distribuições das áreas dos talhões por resultado.	25
Figura 17 - Número de dias entre perturbação de referência e deteção de VP pelo CCDC.	28
Figura 18 - Percentagem de deteções de VP pelo CCDC ao longo do tempo.....	28
Figura 19 - Comparação entre progressão de exploração florestal e respetivas deteções pelo CCDC.	30

1. INTRODUÇÃO

1.1 ENQUADRAMENTO

As florestas representam cerca de 30% da área de superfície do mundo, sendo essenciais para algumas das necessidades básicas da humanidade como alimentação, vestuário, medicina, abrigo e enquanto sumidouro de carbono (Bhunia & Shit, 2021). Por terem um papel integral na regulação do clima e na manutenção de balanços ecológicos e de ciclos de carbono, reconhece-se que a gestão sustentável da floresta é uma das soluções mais efetivas para a mitigação das alterações climáticas e para o desenvolvimento sustentável (Cai et al., 2023).

Em Portugal continental, os espaços florestais representam 69,4% da superfície e encontram-se maioritariamente em posse privada (apenas cerca de 3% da área florestal em Portugal é pública). São caracterizados por uma grande representatividade de minifúndio, sendo que 24% dos espaços florestais têm áreas inferiores a 2 ha e 30% entre 2 e 10 ha. Na figura 1 pode-se ver como o tamanho dos povoamentos florestais se encontra representado em Portugal continental de acordo com o 6º Inventário Florestal Nacional relativo a 2015 (ICNF, 2019).

O planeamento de gestão florestal é um problema complexo que depende de diferentes critérios de natureza económica, ambiental e social (Diaz-Balteiro & Romero, 2008). Depende em grande parte de uma monitorização e acompanhamento regulares que até recentemente, em Portugal, eram conseguidos quase exclusivamente pelo trabalho de campo de técnicos locais, no caso das grandes empresas, ou dos próprios proprietários. A prevalência de povoamentos florestais com reduzidas dimensões, especialmente na metade Norte de Portugal continental, implica a existência de desafios adicionais no que toca à monitorização e gestão. No entanto, especialmente em paradigmas de paisagens fragmentadas, uma monitorização de alterações atempada e exata pode ser relevante para perceber padrões e dinâmicas espaço-temporais (Cai et al., 2023).

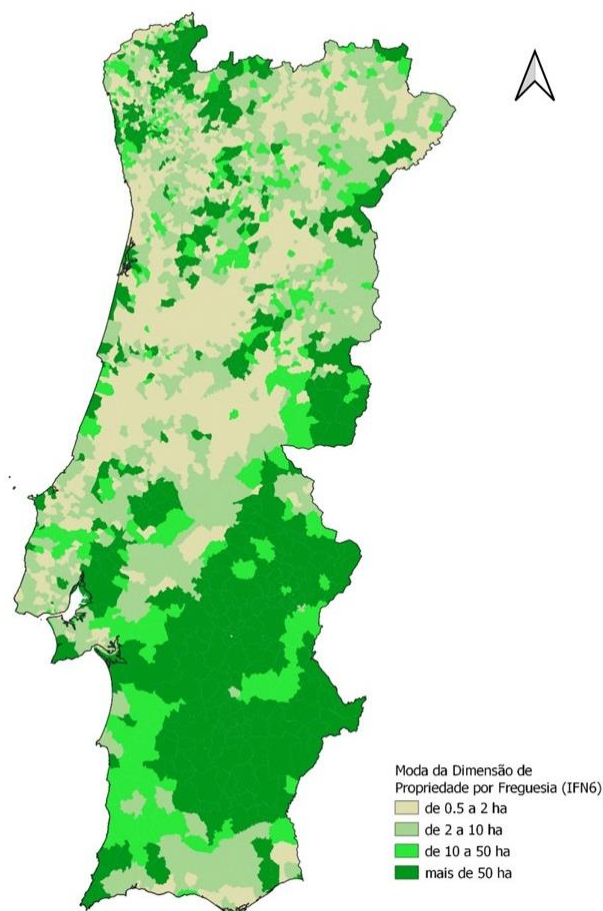


Figura 1 - Mapa representativo da área moda de cada freguesia de Portugal continental de acordo com o 6º Inventário Florestal Nacional (ICNF, 2019).

Este paradigma é uma das principais causas para a falta de gestão de povoamentos florestais em Portugal, dificultando a aplicação de modelos de silvicultura adequados e a respetiva monitorização. O abandono rural e consequente perda de mão-de-obra em trabalhos florestais, aliados à crescente preocupação com as consequências das alterações climáticas, tornam urgente a implementação de novas tecnologias de informação que permitam acompanhar regularmente o estado e o vigor de povoamentos florestais e, em particular, identificar perturbações como incêndios, cortes rasos, pragas e doenças, encharcamentos e danos meteorológicos (Sulla-Menashe et al., 2016).

1.2. DETEÇÃO DE ALTERAÇÕES DE USO E OCUPAÇÃO DO SOLO

A monitorização dos recursos naturais, tais como geológicos, bioquímicos e hidrológicos, fauna e flora, é fundamental para acompanhar e compreender as características mais fundamentais da Terra. Para tal, considera-se imprescindível conseguir identificar o uso e ocupação do solo, e como estes se relacionam (Liu et al., 2023; Loveland & Belward, 1997). Por um lado, a ocupação do solo identifica as características biofísicas de um local numa determinada altura no tempo e pode ser observado localmente ou por deteção remota. Por outro, o uso do solo refere-se à interação ou utilidade que determinado local tem com a humanidade numa determinada altura temporal. Diferentes áreas científicas podem primar por estudar uso ou ocupação, mas é importante ter sempre presente como estes dependem um do outro (Burley, 1961; Meyer & Turner, 1992).

Alterações no uso e ocupação do solo podem ser estudadas a diferentes escalas e pretendem refletir com exatidão fenómenos ou mudanças no estado de objetos, quer sejam fenómenos naturais ou com origem antropogénica. É essencial perceber a influência antropogénica nas alterações do uso e da ocupação dos solos, e como esta contribui para que fenómenos de alterações tenham uma frequência crescente e aconteçam a níveis cada vez mais locais (Lambin & Meyfroidt, 2011; J. Townshend et al., 1991). Turner et al. (2007) definiram a Ciência das Alterações do Solo como sendo a “ciência interdisciplinar [que] procura compreender as dinâmicas do uso e ocupação do solo como sistemas emparelhados humano-ambiente para abordar teoria, conceitos, modelos e aplicações relevantes para problemas ambientais e sociais, incluindo a interseção dos dois”, sendo temas com preocupações crescentes como as alterações climáticas e a sustentabilidade os seus principais desafios atuais (Zhu et al., 2022).

A produção de cartas de ocupação a partir de imagens aéreas remonta às primeiras décadas do século XX. No entanto considera-se que a era moderna da cartografia de uso e ocupação do solo tenha começado na década de 1970 com o lançamento do Earth Resources Technology Satellite, programa atualmente conhecido como Landsat, que tem vindo a disponibilizar imagens multiespectrais ao longo de todos estes anos até aos dias de hoje (Giri, 2012; Steiner, 1965). Foi por essa altura que surgiram os primeiros sistemas de classificações avançadas pelo U. S. Geological Survey para utilização com dados de

deteção remota, que são ainda utilizados ou servem de base a trabalhos mais recentes (Anderson, 1976).

O surgimento e popularização dos Sistemas de Informação Geográfica na década de 1980, consequentes da chegada generalizada de computadores ao público, e o crescente interesse na monitorização por deteção remota levaram ao eventual lançamento do satélite francês Satellite Pour l'Observation de la Terre (SPOT) em 1986, portador de instrumentação de alta resolução nas bandas visíveis que veio complementar a oferta do Landsat (Cornwell, 1982; Wulder et al., 2008).

Com os anos 90, a disponibilização de imagens de satélite cada vez mais generalizada inspirou maior colaboração entre entidades produtoras de cartografia, destacando-se a criação da entidade europeia Coordination of Information on the Environment (CORINE), novidades em técnicas de classificação como o aparecimento do Land-Cover Classification System do projeto Africover e o surgimento de Advanced Very High Resolution Radiometer (AVHRR) (Bossard et al., 2000; Csiszar & Gutman, 1999; DiGregorio & Jansen, 2000; Vogelmann et al., 1998).

Já no século XXI tem-se visto uma maior liberalização no acesso a cartografia de uso e ocupação do solo produzida com dados recolhidos por satélite. Mais recentemente é obrigatório destacar o projeto Sentinel da European Space Agency (ESA) cuja missão Sentinel-2, dedicada à recolha de imagens óticas de alta resolução, se iniciou em 2015 com o lançamento do Sentinel-2A. A constelação foi complementada em 2017 com o lançamento do Sentinel-2B, reduzindo o intervalo de revisita e tornando-se uma das mais relevantes fontes de dados para a produção de cartografia de ocupação do solo (ESA, 2015; Phiri et al., 2020).

Programas de satélites como o Landsat e Sentinel, devido à disponibilidade e facilidade de acesso e às suas resoluções espaciais e temporais (30 m e 8 dias no caso do Landsat e 10 m e 5 dias no caso do Sentinel), e Google Earth Engine (GEE), que permite processamento gratuito de conjuntos de dados de satélites e computação em *cloud* prontamente disponível, têm permitindo a expansão da comunidade de utilizadores a processar e analisar séries temporais de observações de satélite (Pasquarella et al., 2022).

As séries temporais Landsat, por conterem imagens dos últimos 50 anos e serem completamente gratuitas desde 2008, têm sido um dos padrões no que toca a análises de alterações de ocupação do solo, com principal ênfase em áreas florestais (Holden & Woodcock, 2016). No entanto, por ter resoluções espaciais e temporais mais favoráveis, as séries temporais de Sentinel-2 começam agora a ter uma amplitude temporal mais relevante, permitindo a sua utilização para análise e interpretação de tendências ao longo do tempo. A aplicação de imagens de Sentinel-2 tem sido largamente utilizada para monitorização de florestas, desde a mais simples produção de cartas de uso e ocupação do solo até à realização de inventário florestal, deteção de espécies invasoras, monitorização de incêndios florestais (e gestão de pós-fogo). Tem mesmo sido utilizado preferencialmente em relação a outros conjuntos de dados com melhores resoluções devido à sua natureza gratuita (Phiri et al., 2020).

Embora nem todas as perturbações em florestas possam ser detetadas através da utilização de imagens de satélite, tanto ações de desflorestação (conversão de floresta em agricultura, estruturas artificiais ou outros usos) como de florestação (o inverso) podem geralmente ser mapeadas de forma confiável utilizando dados de satélites publicamente disponíveis (Huang, 2018). A utilização de dados de deteção remota para estudar alterações do solo, em particular imagens de satélite, oferece vantagens inegáveis como coberturas amplas com longas séries temporais e fácil processamento, sendo uma das fontes de dados mais relevantes para deteção de alterações do solo nas últimas décadas (Liu et al., 2023). Aliás, em 2018, Huang reconhece que “a deteção remota com recurso a satélites tornou-se na principal fonte de dados para monitorização de florestas”.

Wulder et al. (2018) descrevem como recentes progressos tecnológicos aliados à necessidade de redução de custos, latência de produtos e subjetividade humana, têm levado ao longo das últimas três décadas a uma mudança de paradigma na produção e disponibilização de dados de ocupação do solo. Dados e produtos: são cada vez mais amplos e disponíveis ao público; são gerados sistematicamente e atualizados mais frequentemente; dependem de algoritmos avançados e objetivos; são facilmente acessíveis e a custos baixos ou inexistentes; são informados por séries temporais, permitindo estudar não só o estado, mas também as tendências.

1.3. CONTINUOUS CHANGE DETECTION AND CLASSIFICATION

A cada vez mais ubíqua existência de séries temporais de alta resolução com cobertura global tem levado a diferentes abordagens no estudo das alterações de uso e ocupação do solo. Enquanto Townshend, em 1992, referia o investimento em recursos humanos necessário para cada utilizador pré-processar individualmente os dados obtidos de satélites para que estes pudessem ser utilizados, atualmente a realidade é diferente. Novas metodologias tomam partido de coleções de séries temporais já pré-processadas e devidamente ortoretificadas e atmosféricamente corrigidas para detetar alterações. Em vez de depender da diferença entre classificações pontuais para identificar alterações, diversos algoritmos preveem tendências ao longo do tempo para detetar alterações com maior exatidão e permitem disponibilizar produtos digitais quase a tempo real (J. R. G. Townshend, 1992; Wulder et al., 2018).

Métodos como o LandTrendr utilizam coleções de séries temporais de imagens obtidas de satélites para calcular tendências inter-anuais e consequentes quebras nessas tendências para detetar alterações. Outros métodos, como Breaks For Additive Seasonal and Trend (BFAST) ou Continuous Change Detection and Classification (CCDC), utilizam também tendências sazonais (intra-anuais) para o mesmo fim (Kennedy et al., 2010; Verbesselt et al., 2010; Zhu & Woodcock, 2014).

O CCDC é um método que procura, para cada pixel, assinalar alterações de ocupação do solo em séries temporais de imagens. Este pretende caracterizar as alterações intra- anuais (normalmente devidas a flutuações de temperatura ou precipitação causadas pelo decorrer das estações) e as alterações graduais inter- anuais (tendências graduais associadas ao crescimento de vegetação ou a variabilidade climática) através do ajuste de uma regressão harmónica (embora utilizasse OLS – Ordinary Least Squares originalmente, na versão mais recente e estabelecida utiliza LASSO - Least Absolute Shrinkage and Selection Operator) e, posteriormente, sinalizar alterações bruscas (normalmente atribuíveis a catástrofes naturais ou fenómenos antropogénicos) identificando valores significativamente diferentes dos esperados de acordo com o modelo estabelecido (Zhou et al., 2022; Zhu & Woodcock, 2014). Na figura 2 pode-se analisar um exemplo do comportamento do CCDC, estabelecendo linhas de regressão

para valores esperados e sinalizando uma quebra (*break*) quando identifica valores significativamente diferentes do esperado.




Figura 2 - Exemplo de aplicação do CCDC e identificação de quebra (*break*) retirado do artigo original de Zhu & Woodcock (2014)

Na sua versão mais recente, a aplicação deste algoritmo pressupõe a determinação de quatro parâmetros:

- (1) *lambda*: Representa o parâmetro de penalização para o ajuste da regressão LASSO. *lambda* representa o viés que é permitido ao ajuste da regressão. Valores excessivamente altos podem resultar em regressões que apenas têm em conta a tendência inter-anual (lineares), enquanto valores mais baixos podem levar a *overfitting*;
- (2) *chi-square*: O valor limite para que o teste de chi-quadrado determine se um novo valor obtido é estatisticamente diferente do valor esperado de acordo com a regressão estabelecida. Pode variar entre 0 e 1 sendo que quanto mais próximo de 1 for definido mais sensível é o teste. Neste contexto, valores mais altos devem reduzir os erros de omissão, podendo resultar em erros de comissão;
- (3) *minObservations*: Representa o número mínimo de observações consecutivas identificadas pelo teste de chi-quadrado como estatisticamente diferentes para que o algoritmo detecte uma quebra (*break*);
- (4) *minYears*: Tempo mínimo, em anos, exigido para que uma regressão seja ajustada e nova quebra seja identificada.

Após a sua publicação original em 2014 e até ao fim de 2023, o método tem sido utilizado com frequência crescente (figura 3) em estudos de alteração de ocupação do solo com principal incidência na Amazônia, na China e nos Estados Unidos da América

(apenas 24% dos artigos identificados se interessam por áreas fora destes territórios). Devido às suas séries temporais mais longas (disponíveis desde a década de 1970) a grande maioria dos casos de estudo baseiam-se em dados de Landsat, tendo 74% destas publicações utilizado séries temporais exclusivamente de Landsat e 16% utilizado séries de Landsat complementadas com outras (Tabela 6 – APÊNDICE A).




Figura 3 - Histograma representativo da publicação de estudos de alteração de ocupação do solo em florestas com CCDC.

Tanto quanto pode ser verificada, a utilização do CCDC em séries temporais Sentinel-2 encontra-se ainda num estado embrionário, mas pode ser uma ferramenta importante para a monitorização de parcelas florestais em Portugal. Tal como o Landsat, o acesso às suas séries temporais é gratuito e está disponível através de Google Earth Engine, no entanto conta com uma resolução espacial superior, mais adequado às pequenas dimensões dos prédios em Portugal.

A validação de produtos de perturbações pode ser desafiante e depende, normalmente, de avaliações visuais ou baseadas em amostragem (métodos que dependem de dados de satélite ou outros tipos de dados de referência), ou então de dados de referência independentes oportunistas (usualmente amostragens de parcelas de inventário florestal ou registos de gestão florestal) (Huang, 2018). Validar e aferir exatidão de mapas de ocupação do solo de grande área e alterações bruscas respetivas é um desafio

ubíquo à comunidade de detecção remota, sendo muitas vezes custosa e frequentemente subvalorizada (Vogelmann et al., 2016).

Dos 37 casos de estudo identificados, oito deles (21,6%) realizaram a validação de resultados e aferição de exatidão meramente via imagens de satélite de referência (sete dos casos utilizaram apenas imagens de Landsat). O segundo método mais comum assentou na utilização de dados de referência oportunistas como mapas de ocupação ou parcelas de inventário previamente produzidos por entidades públicas ou outros institutos. Sete dos estudos identificados (18,9%) utilizaram este método. Quatro estudos dependeram de levantamentos aéreos (fotografia ou LiDAR) e outros quatro de amostragens de campo realizadas especificamente para este propósito (10,8% cada). Os restantes trabalhos aferiram as suas exatidões utilizando mais do que um dos métodos atrás descritos ou não utilizaram dados de referência (figura 4).

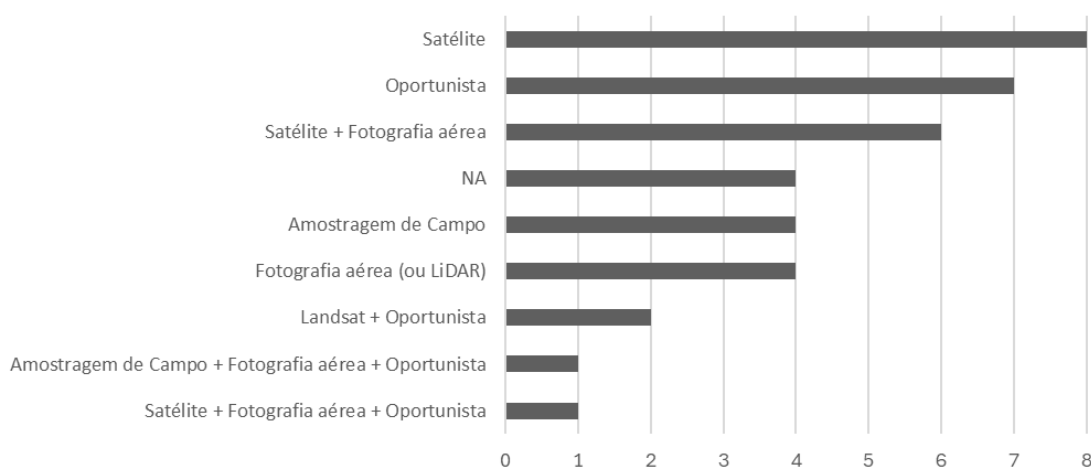


Figura 4 - Tipos de dados de referência utilizados para validação de estudos de alteração de ocupação do solo em florestas com CCDC.

1.4. OBJETIVO

Em 2024, Moraes et al. utilizaram 300 parcelas circulares com um raio de 200 m para parametrizar o método CCDC e identificar alterações de ocupação do solo, tendo utilizado fotointerpretação de ortofotos (25 cm) e imagens de Sentinel-2 (10 m) para validar os produtos resultantes. Esta dissertação propõe-se a avaliar a utilidade potencial das imagens Sentinel-2 e do CCDC com a parametrização otimizada para

Portugal por Moraes et al. para cartografar ações de desflorestação em povoamentos florestais portugueses.

Este protocolo, inteiramente dependente de conjuntos de dados gratuitos e amplamente disponíveis e software open-source, poderá vir a ser uma grande mais-valia para gestores de povoamentos florestais em Portugal como complemento relevante para a monitorização de áreas de minifúndio (uma grande parte do território nacional), contribuindo para uma gestão mais eficiente e sustentável e maior produtividade.

2. MATERIAIS E MÉTODOS

2.1. ESTADO DA ARTE

De forma a identificar de forma objetiva e reproduzível os trabalhos publicados relevantes para a revisão sistemática deste trabalho foi realizada uma pesquisa na base de dados de literatura científica ScienceDirect (Elsevier, 2024) por trabalhos entre 2014 e 2023 com os termos “CCDC” e “Forest” (*floresta*) nas áreas científicas de “Environmental Science” (*Ciência Ambiental*), “Earth and Planetary Sciences” (*Ciências Planetárias e da Terra*) e “Agricultural and Biological Sciences” (*Ciências Biológicas e da Agricultura*). Os resultados obtidos e o tratamento realizado encontram-se descritos no diagrama do fluxo produzido de acordo com o método padrão PRISMA descrito por Haddaway et al. em 2020 (figura 5). Outras fontes relevantes foram utilizadas de forma a complementar ou enquadrar a informação obtida.

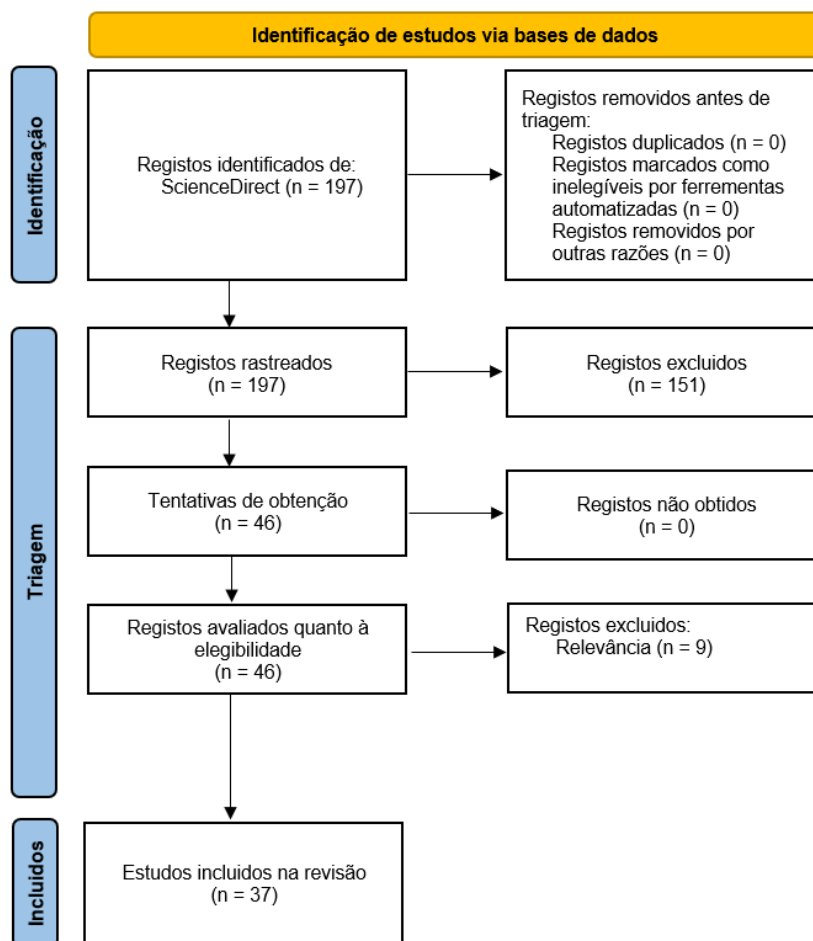


Figura 5 - Diagrama do fluxo de obtenção e tratamento de estado de arte produzido de acordo com o método padrão PRISMA descrito por Haddaway et al. (2020)

2.2. PARAMETRIZAÇÃO E FLUXO DO PROCESSO

De forma a utilizar o algoritmo CCDC para produzir uma carta com as deteções de alterações de ocupação decorridas entre 2021 e 2023 em Portugal continental a partir uma série temporal de imagens de satélite Sentinel-2, foi estabelecido um *script* utilizado o API de JavaScript do GEE (APÊNDICE B). Este utiliza o conjunto de dados “Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A” indexado como “S2_SR_HARMONIZED” no catálogo do GEE para obter uma série temporal de imagens de refletância de superfície de nível 2A (produto ortorretificado e atmosféricamente corrigido – todos os valores de refletância são referentes ao Bottom-of-Atmosphere) com resolução espacial de 10 m e valores normalizados a partir de 28/03/2017 (ESA, 2015; GEE, 2024a).

De seguida, para excluir nuvens e sombras em cada uma das imagens da série temporal, utilizou-se o conjunto de dados “Sentinel-2: Cloud Probability”, indexado no catálogo do GEE como “COPERNICUS_S2_CLOUD_PROBABILITY”. Este identifica para cada pixel das imagens da série temporal de Sentinel-2 utilizada a probabilidade de nuvens e sombras, baseada no algoritmo s2cloudless disponibilizado pelo programa Copernicus da ESA. Em conjunto com o TMask, um mecanismo interno do CCDC que utiliza as bandas B3 (Verde) e B12 (Infravermelho de onda curta 2), foi aplicada uma máscara para identificar e remover nuvens e respetivas sombras (GEE, 2024b; Skakun et al., 2022).

Para cada uma das imagens foi calculado o Normalized Difference Vegetation Index (NDVI) (Rouse et al., 1974). Este índice baseia-se na refletância nas bandas de Vermelho (B4) e Infravermelho Próximo (B8) para identificar a existência de vegetação de acordo com a fórmula:

$$NDVI = \frac{(B8 - B4)}{(B8 + B4)}$$

A instância do algoritmo CCDC presente no GEE, foi aplicada utilizando os parâmetros identificados por Moraes et al. (2024) como ótimos para a deteção de alterações de ocupação do solo com séries temporais Sentinel-2 em Portugal (lambda 200, chi-square

0,999, minYears 1 e minObservations 4) tendo sido determinada, para cada pixel, a data da última quebra.

Posteriormente, foi estabelecido um algoritmo em Python (baseado na biblioteca PyQGIS) para processar os resultados obtidos do CCDC de forma a serem utilizáveis (APÊNDICE C). Este aplica um filtro de maioria da biblioteca GRASS GIS 7 “r.neighbors” recorrendo à moda dos vizinhos de cada pixel para reduzir o aspeto pulverizado do produto. De seguida foram extraídos os polígonos para cada área afetada por uma quebra detetada na mesma data com recurso à ferramenta “Polygonize (raster to vector)” da biblioteca GDAL. Este identifica todos os pixels contíguos cuja data de quebra seja a mesma e devolve polígonos em formato vetorial. Foi ainda necessário calcular a data da quebra de cada polígono a partir do *timestamp* UNIX (milissegundos desde 01/01/1970), que é o output gerado pelo CCDC, utilizando a função “Datetime_from_epoch” nativo do PyQGIS. Finalmente, para este estudo, foram ignorados todos os polígonos correspondentes a datas fora do período analisado (2021 a 2023) e foi definida uma Unidade Mínima Cartográfica (UMC) de 0,1 ha (figura 6).

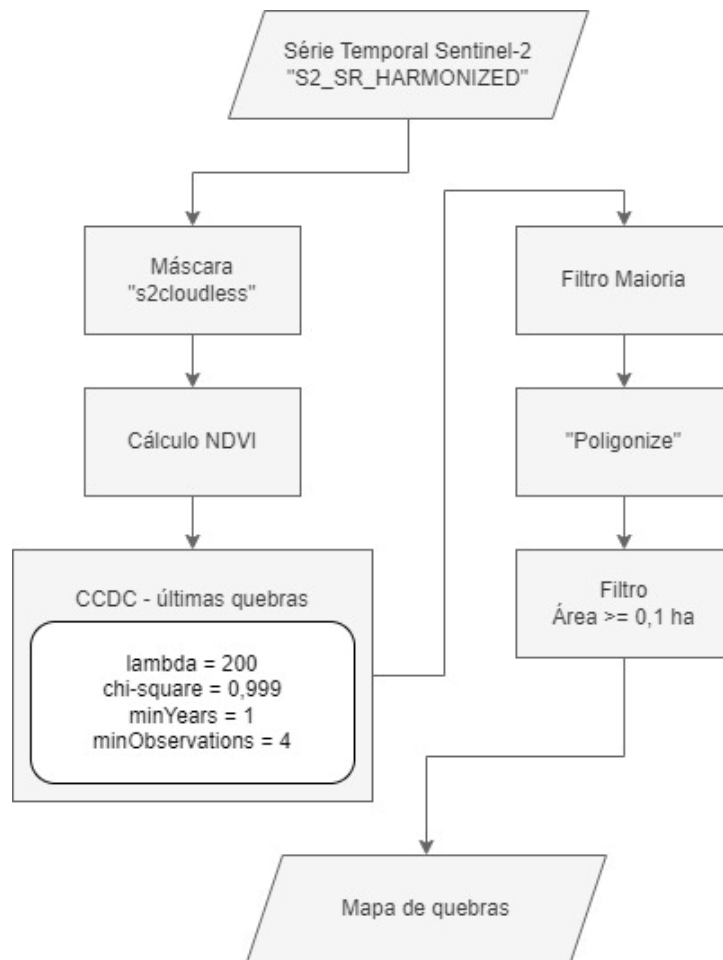


Figura 6 - Diagrama do fluxo de processamento para obtenção de mapa de quebras.

2.3. DADOS DE REFERÊNCIA

A The Navigator Company (Navigator) é uma companhia portuguesa dedicada à gestão florestal, à indústria de pasta de celulose e papel e energias renováveis e é responsável pela gestão, monitorização e exploração de mais de 100 000 ha de floresta distribuídos pelas zonas de maior prevalência de floresta de produção em Portugal continental (The Navigator Company, 2024). Para este estudo, foram selecionados aleatoriamente 300 talhões (unidade mínima de gestão florestal) de floresta de eucalipto geridos pela Navigator, estratificados pelas quatro regiões administrativas da empresa: Norte, Vale do Tejo, Interior e Sul. Estas quatro regiões foram estabelecidas por cada uma representar a necessidade de gestão dos povoamentos florestais de forma diferente, devido à produtividade potencial inerente ao clima, tipo de solo ou outras condicionantes. Desta forma foi possível garantir uma distribuição com uma

representação adequada das áreas de floresta de produção de eucalipto geridas pela companhia (figura 7).

Os talhões estudados têm uma área média de 41,56 ha, uma área mediana de 27,19 ha e uma distribuição assimétrica, como se pode verificar no histograma apresentado na figura 8. O talhão com menor área tem 0,36 ha enquanto o maior tem 303,97 ha. Esta amostragem é representativa do património da Navigator, tanto na sua distribuição de áreas como na sua dispersão geográfica em Portugal.

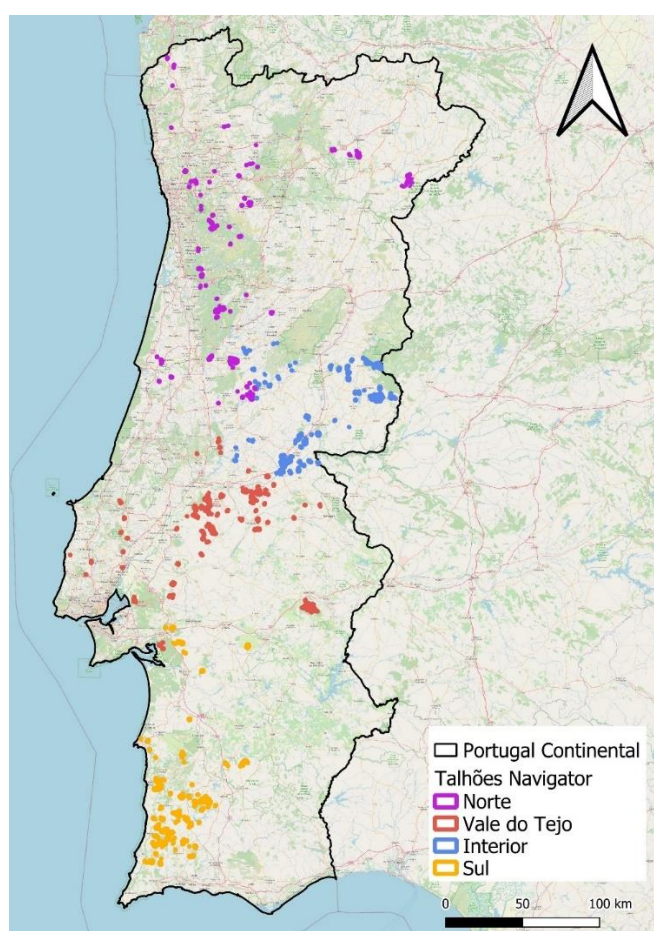


Figura 7 - Distribuição geográfica dos talhões de floresta de produção de eucalipto analisados para este estudo sobre mapa OpenStreetMap.




Figura 8 - Histograma de área dos talhões estudados, por classes de área com intervalo de 10 ha.

Para estes talhões, foram realizadas *queries* em bases de dados da Navigator de forma a selecionar e identificar as seguintes situações decorridas entre 2021 e 2023:

(1) Ações de exploração: estes registos são representativos de todas as intervenções em que um povoamento florestal foi alvo de corte raso para exploração e aproveitamento da madeira como matéria-prima. Para cada talhão, foi possível identificar (caso tenha sido alvo de exploração) os limites da exploração e datas de início e fim de trabalhos;

(2) Ações de silvicultura: estes registos são representativos de todas as ações decorrentes da usual gestão de povoamentos florestais passíveis de potencialmente provocar falsos positivos por resultarem *a priori* numa possível redução de vegetação no povoamento estudado, nomeadamente:

- Aplicação de herbicida – aplicação pontual de herbicida para controlo de espécies invasoras;
- Limpezas manuais – controlo de vegetação espontânea com recurso a equipamentos manuais (enxada ou sacho) ou moto-manuais (motorroçadora);

- Limpezas mecânicas – controlo de vegetação espontânea com recurso a acoplados a tratores como destroçadores ou capinadeiras;
- Seleção de varas – desbaste de rebentações sem vigor ou sem interesse económico;
- Preparações de terreno – obra de preparação do talhão para nova rearborização. Pode implicar limpeza de sobrantes de um povoamento anterior ou vegetação espontânea;

(3) Áreas ardidas – povoamentos afetados por incêndios florestais.

Ocasionalmente foram também utilizadas imagens de satélite Sentinel-2 para complementar e enquadrar a análise na secção 3.

2.4. VALIDAÇÃO

O mapa de quebras foi comparado, em primeira instância, com os registos de ações de exploração e de áreas ardidas da Navigator. Determinou-se que seriam consideradas como verdadeiros positivos (VP) os talhões com ações de exploração ou incêndios florestais no período de estudo com deteção pelo CCDC (isto é, situações de concordância entre o mapa produzido e os dados de referência). De forma a analisar de forma objetiva, consideraram-se como VP todos os talhões que reunissem as seguintes condições:

- (1) Polígono(s) de quebra sobrepõe(m) pelo menos 80% da área do polígono de referência – considerou-se 80% da área de forma a prever potenciais perdas de informação decorrentes do processo de generalização previsto no fluxo do processamento. Devido à aplicação do filtro de maioria e à UMC estabelecida, prevê-se que possam potencialmente existir reduções de área que não devem ser penalizadoras;
- (2) Data de quebra posterior a data de referência menos de 60 dias – a aplicação de máscara de nuvens “s2cloudless” pode levar a que exista uma ausência de amostragem em alguns locais, especialmente no inverno. Assim, é aceitável um desfasamento de algumas semanas na deteção de quebras pelo CCDC.

Consideraram-se com verdadeiros negativos (VN) todos os talhões sem registo de ações de exploração na janela temporal estudada onde não tivessem sido detetadas quebras pelo CCDC.

Para cada uma destas comparações foram quantificados os erros de comissão (falsos positivos – FP) e omissão (falsos negativos – FN), tendo sido calculada a exatidão do produto e o F1-score de acordo com as fórmulas apresentadas (Congalton & Green, 2019; Zhu et al., 2020).

$$Exatidão = \frac{VP + VN}{VP + VN + FP + FN}$$

$$Comissão = \frac{FP}{VP + FP}$$

$$Omissão = \frac{FN}{VP + FN}$$

$$F1 - score = \frac{(1 - Comissão) \times (1 - Omissão)}{2 - Comissão - Omissão} \times 2$$

Critérios semelhantes foram utilizados para estudar a influência das ações de silvicultura nas deteções de quebras pelo CCDC.

3. RESULTADOS E DISCUSSÃO

O produto obtido foi validado de acordo com os critérios descritos para a comparação com os dados de referência. Para os 300 talhões analisados foram quantificados 82 VP, 23 FP, 3 FN e 192 VN (tabela 1). Estes resultados representam uma exatidão de 0,91 e um F1-score de 0,86 (comissão de 0,22 e omissão de 0,04).

Tabela 1 - Comparação de cortes florestais detetados pelo CCDC com dados de referência, por talhão.

CCDC\Referência	Corte	Sem Corte
<i>Com Quebra</i>	82	23
<i>Sem Quebra</i>	3	192

Os resultados são semelhantes quando se considera a área dos talhões estudados, tendo-se determinado que os VP têm uma área total de 3 793,97 ha, os FP 1 329,71 ha, os FN 132,29 ha e os VN 7 212,51 ha, num total de 12 468,48 ha (tabela 2). Estes resultados representam uma exatidão de 0,88 e um F1-score de 0,84 (comissão de 0,26 e omissão de 0,03).

Tabela 2 - Comparação de quebras detetadas pelo CCDC com dados de referência, por área.

CCDC\Referência	Corte	Sem Corte
<i>Com Quebra</i>	3 793,97 ha	1 329,71 ha
<i>Sem Quebra</i>	132,29 ha	7 212,51 ha

Entre os 82 talhões identificados como VP encontram-se 81 talhões onde ocorreram ações de exploração e 1 talhão afetado por incêndio florestal. Na figura 9 pode ser analisado um dos casos em que os cortes detetados têm uma aderência adequada à informação de referência. Nesta demonstração pode-se verificar que a área do talhão explorado foi corretamente identificada no resultado produzido. Na figura 10 é ilustrado o caso em que os danos provocados pelo incêndio florestal de 5 a 9 de agosto em Odemira foram detetados corretamente pelo CCDC em 7 e 12 de agosto.




Figura 9 - Comparação entre um talhão Navigator cuja floresta foi explorada e as áreas detetadas pelo CCDC como quebra sobre uma imagem falsa cor Sentinel-2.




Figura 10 - Área florestal afetada por incêndio entre 05/08/2023 e 09/08/2023 detetada com CCDC sobre imagens falsa cor de Sentinel-2.

Na figura 11 pode ser verificado um dos casos de FP. Não tendo havido exploração florestal, foram identificadas quebras com o protocolo definido. Algumas destas situações podem ser explicadas pela realização de ações de silvicultura no talhão: neste caso foi feito o controle de vegetação espontânea com Limpeza Mecânica.




Figura 11 - Comparação entre um talhão Navigator alvo de Limpeza Mecânica com as áreas detetadas pelo CCDC como quebra sobre uma imagem falsa cor Sentinel-2.

Para além de consideradas todas as ações de exploração, foram também tidos em conta todos os registos de ações de silvicultura que pudessem resultar em reduções de biomassa e/ou representar alterações bruscas na refletância das imagens. Dentro do universo dos 300 talhões avaliados foram identificados 108 com histórico de operações no período estudado e, para cada uma das ações de silvicultura consideradas, quantificaram-se quais as operações que deram origem a uma quebra no CCDC ou não (tabela 3).

Tabela 3 - Tabela comparativa de quebras detetadas pelo CCDC com registos históricos reais de operações de silvicultura.

CCDC\Referência	Aplicação de herbicida	Limpeza manual	Limpeza mecânica	Preparação de terreno	Seleção de varas
<i>Com Quebra</i>	0	1	9	9	1
<i>Sem Quebra</i>	8	14	33	0	33

No que toca a ações de controlo de vegetação espontânea, verifica-se que aplicações de herbicida não foram detetadas pelo CCDC, havendo registo de aplicação em 8 talhões sem respetiva deteção. Nos 15 talhões com registos de limpeza manual houve uma deteção e nos 42 talhões onde foram efetuadas operações de limpezas mecânicas houve

nove deteções. Estes resultados vêm ao encontro do esperado uma vez que acompanham o grau de severidade de vegetação espontânea e, conseqüentemente, de interação humana. A aplicação de herbicida apenas pode ser utilizada em situações de vegetação pontual e ainda em fase inicial de crescimento, resultando numa redução mínima de biomassa. Em situações extremas, com maior presença de mato, a única solução é a limpeza mecânica com recurso a tratores, podendo mesmo resultar na incorporação de parte da biomassa no solo. A limpeza manual é utilizada em situações intermédias, onde a vegetação a controlar tem um volume ainda reduzido ou com crescimento localizado – a biomassa não é retirada do local, acabando por secar lentamente.

A outra operação estudada é a seleção de varas (monda ou desbaste) em que rebentos menos desenvolvidos são cortados de forma a seleccionar os mais produtivos. Esta ação foi apenas detetada uma vez em 34 talhões alvos desta operação (3%). Este é um resultado também esperado uma vez que estas varas, para além de representarem uma parte reduzida da biomassa presente no local, não são normalmente retiradas do local ao serem cortadas. A redução de biomassa é bastante reduzida e pode até levar a um maior vigor vegetativo dos rebentos restantes a curto prazo.

No respeitante a obras de preparação de terreno para novas re-arborizações, todas elas foram identificadas pela metodologia utilizada. Estas são, a par das explorações, as operações que mais alterações provocam. Normalmente implicam a presença de maquinaria mais pesada e podem representar mudanças bruscas nos talhões. Devido à sua natureza será difícil diferenciar as obras de preparação de terreno das ações de exploração, uma vez que são ambas intervenções que provocam uma redução incisiva de biomassa.

Estes casos em que operações de silvicultura foram identificados como alterações de ocupação pelo CCDC explicam 20 dos 23 erros de comissão encontrados e expostos anteriormente. Previa-se à partida a possibilidade de operações de manutenção serem detetadas pelo protocolo descrito, esperando-se assim estes erros.

Um dos casos analisados mais interessante está ilustrado na figura 12. Nesta situação, e em duas outras semelhantes, foi identificada uma quebra na ocupação causada pelo

crescimento de vegetação espontânea, talvez devido à inclusão de uma quantidade reduzida de observações em meses de inverno, derivada da existência de nuvens. As observações esporádicas levaram à existência de uma diferença significativa entre imagens resultando num FP. Na figura 13 pode também ser analisado o gráfico obtido para a aplicação da metodologia em um pixel exemplo com recurso ao plugin de QGIS CCD-Plugin (Llano & Moraes, 2024). Neste caso podem-se ver os valores observados para o NDVI desta localização, as respetivas linhas de tendência esperadas e a determinação da quebra (Break). Na figura 14 pode-se ver outro caso semelhante em que, também devido a valores mais elevados de NDVI no inverno, a quebra é detetada com a redução de NDVI após o regresso da meteorologia mais amena.




Figura 12 - Ilustração de alteração de ocupação detetada com CCDC devido a aumento de vegetação espontânea sobre imagens de falsa cor de Sentinel-2.

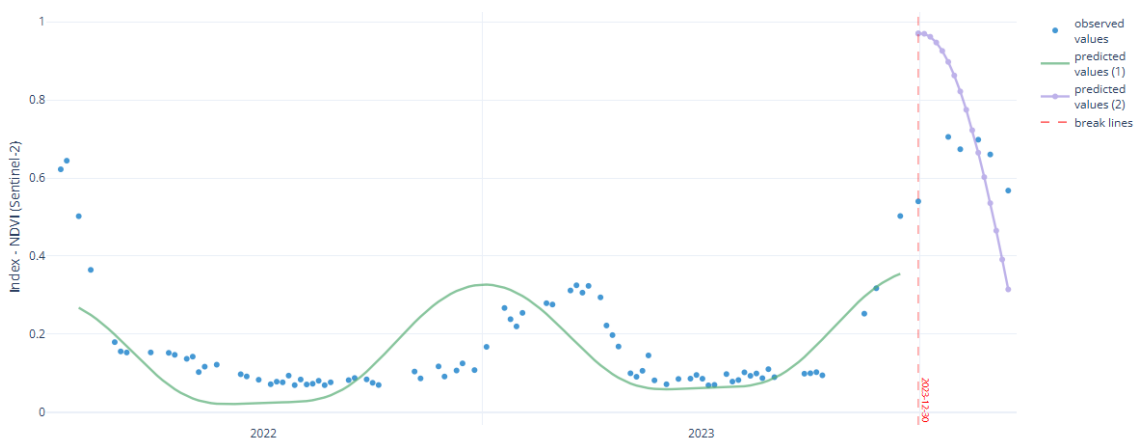


Figura 13 – Gráfico representativo dos diferentes valores de NDVI ao longo do tempo, as respetivas curvas de valores esperados (regressão LASSO) e quebra (break) identificado pelo CCDC em 30/12/2023.




Figura 14 – Gráfico representativo dos diferentes valores de NDVI ao longo do tempo, as respectivas curvas de valores esperados (regressão LASSO) e quebra (break) identificado pelo CCDC em 23/02/2023.

De forma a estudar se a área dos talhões pode ter influência na produção de erros, e por se prever uma maior incidência de erros (principalmente de FN) em talhões com áreas mais reduzidas, calculou-se, para cada cenário, o valor de área média e mediana dos talhões (tabela 3). Na figura 15 pode-se verificar que os diferentes resultados identificados variam de forma semelhante e a realização de uma análise de variância (ANOVA) de uma via com aplicação de um teste estatístico post-hoc Tuckey HSD não detetou diferenças significativas entre cenários, como é possível verificar na tabela 4 ($p > 0,05$). Adicionalmente, verificou-se que o resultado FN com área mais reduzida tem 22,63 ha, tendo sido, no entanto, identificados como VP 36 talhões inferiores (7 deles com áreas inferiores a 5 ha). Com estes resultados pode-se inferir com grande segurança que a amplitude das áreas dos talhões estudados não teve influência para este estudo, e que não houve a produção de resultados FN resultantes de áreas reduzidas.

Tabela 4 - Comparação de quebras detetadas pelo CCDC com dados de referência por áreas de talhão médio (cima) e áreas de talhão mediano (baixo).

CCDC\Referência	Corte	Sem Corte
Com Quebra	46,26 ha	57,81 ha
Sem Quebra	44,10 ha	37,57 ha

CCDC\Referência	Corte	Sem Corte
Com Quebra	25,90 ha	30,73 ha
Sem Quebra	34,55 ha	27,03 ha




Figura 15 – Gráfico boxplot com as distribuições das áreas dos talhões por resultado.

Tabela 5 – P-values obtidos pelo teste estatístico Tuckey HSD, não tendo detetado diferenças significativas entre grupos ($p > 0,05$).

	VP	FP	FN	VN
VP		0,701588	0,999806	0,464069
FP	0,701588		0,960601	0,178342
FN	0,999806	0,960601		0,994660
VN	0,464069	0,178342	0,994660	

De forma a compreender os resultados de acordo com a sua distribuição espacial, foram estudados os resultados de acordo com a região administrativa a que pertencem (tabela 6). A exatidão apurada foi aproximada para as quatro regiões, tendo o Interior o pior resultado (0,88) e a região Sul o melhor (0,93). Aqui é relevante realçar que apenas

ocorreram erros de omissão nas regiões Norte e Vale do Tejo e que os erros de comissão foram consideravelmente superiores na região Interior – levando a um F1-score substancialmente inferior às restantes regiões. Como é possível verificar na tabela 7, a região do Interior foi onde se encontraram simultaneamente o maior número de FP e o menor de VP.

Tabela 6 - Resultados de acordo com a região administrativa.

	Norte	V. Tejo	Interior	Sul
<i>Exatidão</i>	0,92	0,92	0,88	0,93
<i>Comissão</i>	0,20	0,14	0,41	0,19
<i>Omissão</i>	0,11	0,03	0,00	0,00
<i>F1-score</i>	0,84	0,91	0,74	0,90

Tabela 7 - Resultados discriminados por região administrativa.

	VP	FP	FN	VN
<i>Norte</i>	16	4	2	53
<i>V. Tejo</i>	31	5	1	38
<i>Interior</i>	13	9	0	53
<i>Sul</i>	22	5	0	48

Na tabela 8 podem-se analisar os resultados de FP discriminados e verificar que no Interior foram identificadas quatro das nove operações de preparação de terreno (todas as preparações de terreno apuradas nos dados de referência foram detetadas pelo CCDC) e três das nove operações de limpeza mecânica (27% das limpezas mecânicas apuradas nos dados de referência foram detetadas pelo CCDC). À partida, não há razões técnicas para que se realizem este tipo de operações de silvicultura em maior frequência no Interior. Neste caso, a deteção de um maior número de FP pode estar, por exemplo, associada a um investimento mais acentuado da empresa na aquisição de novas propriedades nesta região. Estas aquisições poderiam levar a limpezas de vegetação (derivadas do enquadramento das propriedades no modelo de gestão florestal da empresa) ou ter exigido uma rearborização (e a preparação de terreno associada).

Tabela 8 - Distribuição dos resultados Falsos Positivos por região administrativa.

Região	Limpeza Manual	Limpeza Mecânica	Preparação de terreno	Seleção de varas	Vegetação
<i>Norte</i>	0	1	1	1	1
<i>V. Tejo</i>	0	3	2	0	0
<i>Interior</i>	1	3	4	0	1
<i>Sul</i>	0	2	2	0	1

Estudaram-se também os critérios definidos para a identificação dos VP. Todas as ações de exploração apuradas nos dados de referência identificadas como FN devem esse resultado à inexistência, ou deteção residual, de quebras pelo CCDC na área do talhão. Isto quer dizer que a janela temporal de 60 dias foi adequada.

Mais pormenorizadamente, para cada uma das 82 VP, verificaram-se as datas de início e fim das perturbações de referência (exploração ou incêndio), assim como as datas do primeiro e do último polígono detetados pelo CCDC. Na figura 16 encontra-se ilustrado o desfasamento (Δ) entre as datas. Também na figura 17 podemos ver que tanto no caso do início como no fim os desfasamentos entre a referência e a deteção se comportam de forma semelhante. Aproximadamente 50% das deteções acontecem até seis dias após a data de referência e 80% em 19 dias. Lembrando o tempo de revisita de 5 dias do Sentinel-2, podemos estimar que a maioria das perturbações são detetadas na primeira ou segunda passagem do satélite após a alteração, o que seria o esperado em situações ótimas. A deteção das primeiras alterações (início) parece ser mais incisiva, tendo a quebra com maior desfasamento sido detetada com um intervalo de 46 dias. Por outro lado, houve deteções que distaram até 58 dias da data de fim da intervenção. Estes desfasamentos podem ser explicados pela aplicação da máscara de nuvens (a existência de nuvens sobre o local em revisitas consecutivas pode levar a uma demora na deteção) ou pela presença de sobrantes vegetais no talhão imediatamente após o corte. Uma vez que apenas a madeira é recolhida, os ramos e folhas que permanecem no local podem ser responsáveis por uma diminuição menos brusca no NDVI, atrasando a sinalização da quebra pelo CCDC.

É ainda interessante reconhecer que alguns trabalhos foram detetados pelo CCDC antes do registo nos dados de referência. Entre os 82 VP, 10 talhões tiveram deteções de

quebras pelo CCDC antes da data de início de exploração. Estas deteções acontecem até quatro dias antes da data de referência, ou seja, na visita do Sentinel-2 imediatamente antes da data de referência. Estes podem ser indicativos de trabalhos de preparação para o arranque da obra (por exemplo a abertura de clareiras para descarregamento de máquinas pesadas ou para futuro empilhamento de madeira cortada) ou erros de registo. Em relação ao fim da intervenção, há também cinco deteções de quebras pelo CCDC antes da data de referência. Estas podem exemplificar situações em que os últimos trabalhos não foram detetados ou foram perdidos no processo de generalização do mapa por serem áreas mais pequenas ou erros de registo.

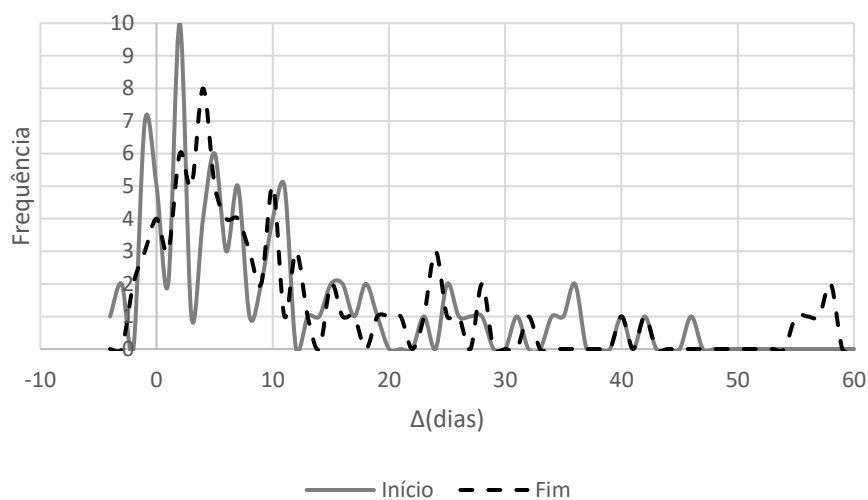


Figura 16 - Número de dias entre perturbação de referência e deteção de VP pelo CCDC.

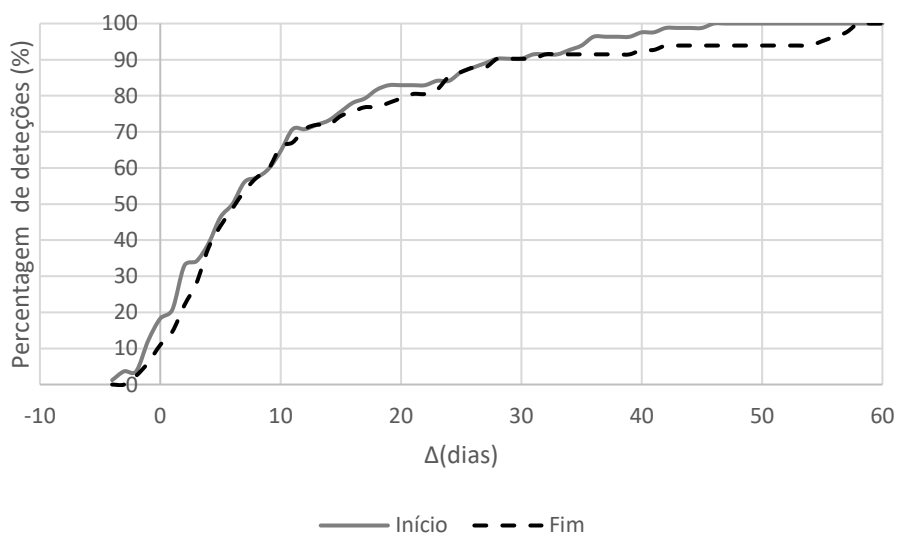


Figura 17 - Percentagem de deteções de VP pelo CCDC ao longo do tempo.

Uma das aplicações mais promissoras deste produto é a possibilidade de validação posterior de trabalhos desenvolvidos. Como é possível verificar na figura 18, o gradual desenvolvimento de trabalhos pode ser analisado com um desfasamento muito baixo da realidade. Neste caso, embora os registos semanais da Navigator indiquem apenas que os trabalhos de exploração se desenvolveram entre 26/12/2022 e 20/02/2023, o produto obtido permite estudar as obras realizadas e até obter métricas de qualidade e celeridade de trabalho. Em circunstâncias ótimas e em períodos sem presença de nuvens, é expectável que a utilização do CCDC possa ser utilizada para validação de trabalhos de exploração florestal sem necessidade de deslocação de um técnico responsável ao local.

Os resultados são extremamente promissores e representam F1-score ligeiramente superior ao apresentado por Moraes et al. (2024). Enquanto Moraes et al. obtiveram um F1-score de 0,82 esta abordagem estudando talhões de povoamentos florestais originou um F1-score de 0,86. O erro de comissão foi semelhante em ambos os casos (0,22 enquanto Moraes et al. obtiveram 0,21), porém o erro de omissão foi bastante mais reduzido (0,04 enquanto Moraes et al. obtiveram 0,15). Estas discrepâncias podem facilmente ser explicadas pela diferente metodologia de validação e avaliação de exatidão. O presente trabalho baseia-se em manchas florestais com limites conhecidos e tenta fazer corresponder as quebras detetadas a registos históricos de gestão florestal enquanto Moraes et al. consideraram cada pixel individualmente. Este procedimento, aliado ao filtro de maioria aplicado e à UMC definida (necessários para a geração de um produto mais facilmente interpretável pelo utilizador), explicam certamente estes resultados, sendo o produto final mais adequado à utilização por técnicos florestais para gestão de povoamentos florestais.




Figura 18 - Comparação entre progressão de exploração florestal e respectivas detecções pelo CCDC.

4. CONCLUSÃO

De um modo geral, o método utilizado resultou num produto bastante adequado e próximo dos dados de referência. Demonstrou-se que a utilização de algoritmo CCDC em conjunto com séries temporais de Sentinel-2 pode ser uma ferramenta muito fidedigna para o acompanhamento de povoamentos florestais de produção de eucaliptal, permitindo identificar e sinalizar alterações bruscas de ocupação do solo, em particular explorações, com grande exatidão. Na análise dos trabalhos publicados com a utilização do CCDC verificou-se uma dependência na utilização de séries temporais de Landsat e uma ausência de trabalhos na Europa. O presente trabalho mostra que a utilização da série temporal do Sentinel-2, embora mais curta que a série temporal do Landsat, pode ser relevante na utilização do CCDC e colmatar necessidades de monitorização onde o Landsat, por ter resolução espacial inferior, não é suficiente.

Entre os 300 talhões estudados, 274 foram corretamente identificados pelo CCDC (81 explorações, 1 incêndio e 192 sem alterações). Apenas 3 talhões com registos de exploração não foram identificados pelo protocolo descrito e 23 foram falsamente sinalizados como tendo sido alvo de desflorestação. Entre as mais diversas razões para o surgimento destes falsos positivos destacam-se os nove talhões que foram intervencionados com preparação de terreno para nova rearborização.

É importante destacar que, embora os dados de referência amostrados sejam representativos do património florestal gerido pela Navigator, não são necessariamente representativos do panorama florestal nacional. Apesar de terem sido estudados talhões com áreas bastante reduzidas apenas 10 deles têm áreas abaixo dos 2 ha. A realidade da floresta em Portugal, particularmente na metade Norte como representada na figura 1, é regularmente caracterizada por minifúndio em que os prédios rurais têm frequentemente áreas abaixo dos 2 ha, chegando mesmo a ter áreas menores que 0,1 ha e larguras inferiores a 10m. Esta realidade é extremamente desafiante e não se prevê conseguir resultados com qualidade elevada nestas situações, mesmo com a alta resolução espacial do Sentinel-2.

Para além de permitir uma monitorização remota dos próprios povoamentos florestais, a possibilidade de a Navigator poder monitorizar remotamente ações de exploração de

povoamentos florestais de terceiros pode também ser muito útil num enquadramento de *Business Intelligence*. Conhecendo as manchas florestais que tradicionalmente abastecem os parques de madeira da companhia, e com a utilização do CCDC, pode ser alcançável antecipar entregas de madeira por parte de produtores ou madeireiros locais. Esta inteligência pode ser uma mais-valia para a gestão de *stocks* e necessidades, permitindo à empresa estar menos dependente da oscilação dos preços do mercado, e ganhar assim uma vantagem importante no negócio.

É também muito importante perceber a possibilidade da utilização desta metodologia para responder à crescente necessidade de garantir o cumprimento dos compromissos de sustentabilidade das empresas. Uma das oportunidades que se prevê para este tipo de ferramentas é dar resposta à prevista implementação do Regulamento Anti-Deflorestação da União Europeia (European Union Deforestation Regulation) que se espera começar a ser imposto no início de 2025. Este prevê um modelo de *blockchain* que pretende acompanhar produtos florestais desde a exploração até à sua utilização final e responsabiliza cada interveniente na cadeia de custódia a realizar a diligência devida e garantir a correta proveniência de cada produto de origem florestal (Köthke et al., 2023). Com a utilização do CCDC, empresas como a Navigator podem mais facilmente monitorizar explorações de povoamentos florestais de produtores terceiros no momento da aquisição desta matéria-prima. Assim, podem garantir a proveniência de cada lote, validando se a origem anunciada corresponde de facto a um povoamento florestal explorado nas datas descritas.

Esta validação permite demonstrar a adequação da metodologia, assim como a série temporal utilizada, para a deteção de cortes rasos em áreas florestais portuguesas e eventual produção de cartas de alteração de ocupação do solo com um elevado grau de confiança.

REFERÊNCIAS BIBLIOGRÁFICAS

- Anderson, J. R. (1976). *A land use and land cover classification system for use with remote sensor data* (Vol. 964). US Government Printing Office.
- Arévalo, P., Baccini, A., Woodcock, C. E., Olofsson, P., & Walker, W. S. (2023). Continuous mapping of aboveground biomass using Landsat time series. *Remote Sensing of Environment*, 288, 113483. <https://doi.org/https://doi.org/10.1016/j.rse.2023.113483>
- Arévalo, P., Olofsson, P., & Woodcock, C. E. (2020). Continuous monitoring of land change activities and post-disturbance dynamics from Landsat time series: A test methodology for REDD+ reporting. *Remote Sensing of Environment*, 238, 111051. <https://doi.org/https://doi.org/10.1016/j.rse.2019.01.013>
- Bhunia, G. S., & Shit, P. K. (2021). Chapter 1 - Recent development and future challenges of geospatial approaches for enhancing forest inventories. In P. Kumar Shit, H. R. Pourghasemi, P. P. Adhikary, G. S. Bhunia, & V. P. Sati (Eds.), *Forest Resources Resilience and Conflicts* (pp. 3–16). Elsevier. <https://doi.org/https://doi.org/10.1016/B978-0-12-822931-6.00001-0>
- Bossard, M., Feranec, J., & Otahel, J. (2000). *CORINE land cover technical guide: Addendum 2000* (Vol. 40). European Environment Agency Copenhagen.
- Brown, J. F., Tollerud, H. J., Barber, C. P., Zhou, Q., Dwyer, J. L., Vogelmann, J. E., Loveland, T. R., Woodcock, C. E., Stehman, S. V, Zhu, Z., Pengra, B. W., Smith, K., Horton, J. A., Xian, G., Auch, R. F., Sohl, T. L., Saylor, K. L., Gallant, A. L., Zelenak, D., ... Rover, J. (2020). Lessons learned implementing an operational continuous United States national land change monitoring capability: The Land Change Monitoring, Assessment, and Projection (LCMAP) approach. *Remote Sensing of Environment*, 238, 111356. <https://doi.org/https://doi.org/10.1016/j.rse.2019.111356>
- Bullock, E. L., Healey, S. P., Yang, Z., Houborg, R., Gorelick, N., Tang, X., & Andrianirina, C. (2022). Timeliness in forest change monitoring: A new assessment framework demonstrated using Sentinel-1 and a continuous change detection algorithm.

Remote Sensing of Environment, 276, 113043.
<https://doi.org/https://doi.org/10.1016/j.rse.2022.113043>

Bullock, E. L., Woodcock, C. E., & Holden, C. E. (2020). Improved change monitoring using an ensemble of time series algorithms. *Remote Sensing of Environment*, 238, 111165. <https://doi.org/https://doi.org/10.1016/j.rse.2019.04.018>

Burley, T. M. (1961). Land use or land utilization? *The Professional Geographer*, 13(6), 18–20.

Cai, Y., Shi, Q., Xu, X., & Liu, X. (2023). A novel approach towards continuous monitoring of forest change dynamics in fragmented landscapes using time series Landsat imagery. *International Journal of Applied Earth Observation and Geoinformation*, 118, 103226. <https://doi.org/https://doi.org/10.1016/j.jag.2023.103226>

Chen, S., Olofsson, P., Saphangthong, T., & Woodcock, C. E. (2023). Monitoring shifting cultivation in Laos with Landsat time series. *Remote Sensing of Environment*, 288, 113507. <https://doi.org/https://doi.org/10.1016/j.rse.2023.113507>

Chen, S., Woodcock, C. E., Bullock, E. L., Arévalo, P., Torchinava, P., Peng, S., & Olofsson, P. (2021). Monitoring temperate forest degradation on Google Earth Engine using Landsat time series analysis. *Remote Sensing of Environment*, 265, 112648. <https://doi.org/https://doi.org/10.1016/j.rse.2021.112648>

Chen, T.-H. K., Pandey, B., & Seto, K. C. (2023). Detecting subpixel human settlements in mountains using deep learning: A case of the Hindu Kush Himalaya 1990–2020. *Remote Sensing of Environment*, 294, 113625. <https://doi.org/https://doi.org/10.1016/j.rse.2023.113625>

Congalton, R. G., & Green, K. (2019). *Assessing the accuracy of remotely sensed data: principles and practices*. CRC press.

Cornwell, S. B. (1982). History and status of state natural resource systems. *Computers, Environment and Urban Systems*, 7(4), 253–260.

Csiszar, I., & Gutman, G. (1999). Mapping global land surface albedo from NOAA AVHRR. *Journal of Geophysical Research: Atmospheres*, 104(D6), 6215–6228.

- Deng, C., & Zhu, Z. (2020). Continuous subpixel monitoring of urban impervious surface using Landsat time series. *Remote Sensing of Environment*, 238, 110929. <https://doi.org/https://doi.org/10.1016/j.rse.2018.10.011>
- Diaz-Balteiro, L., & Romero, C. (2008). Making forestry decisions with multiple criteria: A review and an assessment. *Forest Ecology and Management*, 255(8), 3222–3241. <https://doi.org/https://doi.org/10.1016/j.foreco.2008.01.038>
- DiGregorio, A., & Jansen, L. J. M. (2000). *Land cover classification system, concepts and user manual*. GCP/RAF/287/ITA Africover. Rome: Food and Agriculture Organization of the ...
- Elsevier. (2024). *ScienceDirect: Elsevier's premier platform of peer-reviewed scholarly literature*. <https://www.elsevier.com/products/sciencedirect>
- ESA. (2015). Sentinel-2 User Handbook. In *ESA Standard Document* (2nd ed.). ESA Standard Document.
- Fu, B., Lan, F., Yao, H., Qin, J., He, H., Liu, L., Huang, L., Fan, D., & Gao, E. (2022). Spatio-temporal monitoring of marsh vegetation phenology and its response to hydro-meteorological factors using CCDC algorithm with optical and SAR images: In case of Honghe National Nature Reserve, China. *Science of The Total Environment*, 843, 156990. <https://doi.org/https://doi.org/10.1016/j.scitotenv.2022.156990>
- GEE. (2024a). *Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A*. Earth Engine Data Catalog. https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR_HARMONIZED#description
- GEE. (2024b). *Sentinel-2: Cloud Probability*. Earth Engine Data Catalog. https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_CLOUD_PROBABILITY
- Giri, C. P. (2012). *Remote sensing of land use and land cover: principles and applications*. CRC press.
- Haddaway, N. R., Page, M. J., Pritchard, C. C., & McGuinness, L. A. (2022). PRISMA2020: An R package and Shiny app for producing PRISMA 2020-compliant flow diagrams,

- with interactivity for optimised digital transparency and Open Synthesis. *Campbell Systematic Reviews*, 18(2), e1230.
<https://doi.org/https://doi.org/10.1002/cl2.1230>
- Holden, C. E., & Woodcock, C. E. (2016). An analysis of Landsat 7 and Landsat 8 underflight data and the implications for time series investigations. *Remote Sensing of Environment*, 185, 16–36.
<https://doi.org/https://doi.org/10.1016/j.rse.2016.02.052>
- Hu, Y., Dong, Y., & Batunacun. (2018). An automatic approach for land-change detection and land updates based on integrated NDVI timing analysis and the CVAPS method with GEE support. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 347–359. <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2018.10.008>
- Huang, C. (2018). 6.03 - Forest Disturbance Mapping. In S. Liang (Ed.), *Comprehensive Remote Sensing* (pp. 13–23). Elsevier.
<https://doi.org/https://doi.org/10.1016/B978-0-12-409548-9.10623-2>
- ICNF. (2019). *6º Inventário Florestal Nacional - Relatório Final*.
- Kennedy, R. E., Yang, Z., & Cohen, W. B. (2010). Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr - Temporal segmentation algorithms. *Remote Sensing of Environment*, 114(12), 2897–2910.
<https://doi.org/10.1016/j.rse.2010.07.008>
- Lambin, E. F., & Meyfroidt, P. (2011). Global land use change, economic globalization, and the looming land scarcity. *Proceedings of the National Academy of Sciences*, 108(9), 3465–3472.
- Liao, Z., Liu, X., van Dijk, A., Yue, C., & He, B. (2022). Continuous woody vegetation biomass estimation based on temporal modeling of Landsat data. *International Journal of Applied Earth Observation and Geoinformation*, 110, 102811.
<https://doi.org/https://doi.org/10.1016/j.jag.2022.102811>
- Liu, B., Song, W., Meng, Z., & Liu, X. (2023). Review of Land Use Change Detection—A Method Combining Machine Learning and Bibliometric Analysis. In *Land* (Vol. 12,

Issue 5). Multidisciplinary Digital Publishing Institute (MDPI).
<https://doi.org/10.3390/land12051050>

- Llano, X. C., & Moraes, D. (2024). *CCD-Plugin*. <https://github.com/SMByC/CCD-Plugin>
- Loveland, T. R., & Belward, A. S. (1997). The international geosphere biosphere programme data and information system global land cover data set (DISCover). *Acta Astronautica*, *41*(4–10), 681–689.
- Meyer, W. B., & Turner, B. L. (1992). Human population growth and global land-use/cover change. *Annual Review of Ecology and Systematics*, 39–61.
- Moraes, D., Barbosa, B., Costa, H., Moreira, F. D., Benevides, P., Caetano, M., & Campagnolo, M. (2024). Continuous forest loss monitoring in a dynamic landscape of Central Portugal with Sentinel-2 data. *International Journal of Applied Earth Observation and Geoinformation*, *130*, 103913.
<https://doi.org/https://doi.org/10.1016/j.jag.2024.103913>
- Murillo-Sandoval, P. J., Clerici, N., & Correa-Ayram, C. (2022). Rapid loss in landscape connectivity after the peace agreement in the Andes-Amazon region. *Global Ecology and Conservation*, *38*, e02205.
<https://doi.org/https://doi.org/10.1016/j.gecco.2022.e02205>
- Myroniuk, V., Bell, D. M., Gregory, M. J., Vasylyshyn, R., & Bilous, A. (2022). Uncovering forest dynamics using historical forest inventory data and Landsat time series. *Forest Ecology and Management*, *513*, 120184.
<https://doi.org/https://doi.org/10.1016/j.foreco.2022.120184>
- Myroniuk, V., Zibtsev, S., Bogomolov, V., Goldammer, J. G., Soshenskyi, O., Levchenko, V., & Matsala, M. (2023). Combining Landsat time series and GEDI data for improved characterization of fuel types and canopy metrics in wildfire simulation. *Journal of Environmental Management*, *345*, 118736.
<https://doi.org/https://doi.org/10.1016/j.jenvman.2023.118736>
- Pasquarella, V. J., Arévalo, P., Bratley, K. H., Bullock, E. L., Gorelick, N., Yang, Z., & Kennedy, R. E. (2022). Demystifying LandTrendr and CCDC temporal segmentation.

International Journal of Applied Earth Observation and Geoinformation, 110, 102806.

Peneva-Reed, E. I., Krauss, K. W., Bullock, E. L., Zhu, Z., Woltz, V. L., Drexler, J. Z., Conrad, J. R., & Stehman, S. V. (2021). Carbon stock losses and recovery observed for a mangrove ecosystem following a major hurricane in Southwest Florida. *Estuarine, Coastal and Shelf Science*, 248, 106750. <https://doi.org/https://doi.org/10.1016/j.ecss.2020.106750>

Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V. R., Murayama, Y., & Ranagalage, M. (2020). Sentinel-2 data for land cover/use mapping: A review. In *Remote Sensing* (Vol. 12, Issue 14). MDPI AG. <https://doi.org/10.3390/rs12142291>

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec. Publ*, 351(1), 309.

Skakun, S., Wevers, J., Brockmann, C., Doxani, G., Aleksandrov, M., Batič, M., Frantz, D., Gascon, F., Gómez-Chova, L., & Hagolle, O. (2022). Cloud Mask Intercomparison eXercise (CMIX): An evaluation of cloud masking algorithms for Landsat 8 and Sentinel-2. *Remote Sensing of Environment*, 274, 112990.

Steiner, D. (1965). Use of air photographs for interpreting and mapping rural land use in the United States. *Photogrammetria*, 20(2), 65–80.

Sulla-Menashe, D., Friedl, M. A., & Woodcock, C. E. (2016). Sources of bias and variability in long-term Landsat time series over Canadian boreal forests. *Remote Sensing of Environment*, 177, 206–219. <https://doi.org/https://doi.org/10.1016/j.rse.2016.02.041>

Tang, X., Bullock, E. L., Olofsson, P., Estel, S., & Woodcock, C. E. (2019). Near real-time monitoring of tropical forest disturbance: New algorithms and assessment framework. *Remote Sensing of Environment*, 224, 202–218. <https://doi.org/https://doi.org/10.1016/j.rse.2019.02.003>

Tang, X., Bullock, E. L., Olofsson, P., & Woodcock, C. E. (2020). Can VIIRS continue the legacy of MODIS for near real-time monitoring of tropical forest disturbance?

- Remote Sensing of Environment*, 249, 112024.
<https://doi.org/https://doi.org/10.1016/j.rse.2020.112024>
- Tang, X., Hutyrá, L. R., Arévalo, P., Baccini, A., Woodcock, C. E., & Olofsson, P. (2020). Spatiotemporal tracking of carbon emissions and uptake using time series analysis of Landsat data: A spatially explicit carbon bookkeeping model. *Science of The Total Environment*, 720, 137409.
<https://doi.org/https://doi.org/10.1016/j.scitotenv.2020.137409>
- Tang, X., Woodcock, C. E., Olofsson, P., & Hutyrá, L. R. (2021). Spatiotemporal assessment of land use/land cover change and associated carbon emissions and uptake in the Mekong River Basin. *Remote Sensing of Environment*, 256, 112336.
<https://doi.org/https://doi.org/10.1016/j.rse.2021.112336>
- The Navigator Company. (2024). *Navigator Relatório Anual 2023*.
- Townshend, J., Justice, C., Li, W., Gurney, C., & McManus, J. (1991). Global land cover classification by remote sensing: present capabilities and future possibilities. *Remote Sensing of Environment*, 35(2–3), 243–255.
- Townshend, J. R. G. (1992). Land cover. *International Journal of Remote Sensing*, 13(6–7), 1319–1328. <https://doi.org/10.1080/01431169208904193>
- Turner, B. L., Lambin, E. F., & Reenberg, A. (2007). The emergence of land change science for global environmental change and sustainability. *Proceedings of the National Academy of Sciences*, 104(52), 20666–20671.
<https://doi.org/10.1073/pnas.0704119104>
- Verbesselt, J., Hyndman, R., Newnham, G., & Culvenor, D. (2010). Detecting trend and seasonal changes in satellite image time series. *Remote Sensing of Environment*, 114(1), 106–115. <https://doi.org/10.1016/j.rse.2009.08.014>
- Vogelmann, J. E., Gallant, A. L., Shi, H., & Zhu, Z. (2016). Perspectives on monitoring gradual change across the continuity of Landsat sensors using time-series data. *Remote Sensing of Environment*, 185, 258–270.
<https://doi.org/https://doi.org/10.1016/j.rse.2016.02.060>

- Vogelmann, J. E., Sohl, T., & Howard, S. M. (1998). Regional characterization of land cover using multiple sources of data. *Photogrammetric Engineering and Remote Sensing*, 64(1), 45–57.
- Wang, H., Zhou, Y., Wu, J., Wang, C., Zhang, R., Xiong, X., & Xu, C. (2023). Human activities dominate a staged degradation pattern of coastal tidal wetlands in Jiangsu province, China. *Ecological Indicators*, 154, 110579. <https://doi.org/10.1016/j.ecolind.2023.110579>
- Wulder, M. A., Coops, N. C., Roy, D. P., White, J. C., & Hermosilla, T. (2018). Land cover 2.0. *International Journal of Remote Sensing*, 39(12), 4254–4284. <https://doi.org/10.1080/01431161.2018.1452075>
- Wulder, M. A., White, J. C., Goward, S. N., Masek, J. G., Irons, J. R., Herold, M., Cohen, W. B., Loveland, T. R., & Woodcock, C. E. (2008). Landsat continuity: Issues and opportunities for land cover monitoring. *Remote Sensing of Environment*, 112(3), 955–969.
- Xie, S., Liu, L., Zhang, X., & Yang, J. (2022). Mapping the annual dynamics of land cover in Beijing from 2001 to 2020 using Landsat dense time series stack. *ISPRS Journal of Photogrammetry and Remote Sensing*, 185, 201–218. <https://doi.org/10.1016/j.isprsjprs.2022.01.014>
- Xu, H., Qi, S., Li, X., Gao, C., Wei, Y., & Liu, C. (2021). Monitoring three-decade dynamics of citrus planting in Southeastern China using dense Landsat records. *International Journal of Applied Earth Observation and Geoinformation*, 103, 102518. <https://doi.org/10.1016/j.jag.2021.102518>
- Yan, J., Wang, L., Song, W., Chen, Y., Chen, X., & Deng, Z. (2019). A time-series classification approach based on change detection for rapid land cover mapping. *ISPRS Journal of Photogrammetry and Remote Sensing*, 158, 249–262. <https://doi.org/10.1016/j.isprsjprs.2019.10.003>
- Ye, S., Rogan, J., Zhu, Z., & Eastman, J. R. (2021). A near-real-time approach for monitoring forest disturbance using Landsat time series: stochastic continuous

- change detection. *Remote Sensing of Environment*, 252, 112167.
<https://doi.org/https://doi.org/10.1016/j.rse.2020.112167>
- Ye, S., Rogan, J., Zhu, Z., Hawbaker, T. J., Hart, S. J., Andrus, R. A., Meddens, A. J. H., Hicke, J. A., Eastman, J. R., & Kulakowski, D. (2021). Detecting subtle change from dense Landsat time series: Case studies of mountain pine beetle and spruce beetle disturbance. *Remote Sensing of Environment*, 263, 112560.
<https://doi.org/https://doi.org/10.1016/j.rse.2021.112560>
- Zhang, Y., & Li, M. (2021). A new method for monitoring start of season (SOS) of forest based on multisource remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 104, 102556.
<https://doi.org/https://doi.org/10.1016/j.jag.2021.102556>
- Zhang, Y., Woodcock, C. E., Chen, S., Wang, J. A., Sulla-Menashe, D., Zuo, Z., Olofsson, P., Wang, Y., & Friedl, M. A. (2022). Mapping causal agents of disturbance in boreal and arctic ecosystems of North America using time series of Landsat data. *Remote Sensing of Environment*, 272, 112935.
<https://doi.org/https://doi.org/10.1016/j.rse.2022.112935>
- Zhou, Q., Zhu, Z., Xian, G., & Li, C. (2022). A novel regression method for harmonic analysis of time series. *ISPRS Journal of Photogrammetry and Remote Sensing*, 185, 48–61. <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2022.01.006>
- Zhu, Z., Fu, Y., Woodcock, C. E., Olofsson, P., Vogelmann, J. E., Holden, C., Wang, M., Dai, S., & Yu, Y. (2016). Including land cover change in analysis of greenness trends using all available Landsat 5, 7, and 8 images: A case study from Guangzhou, China (2000–2014). *Remote Sensing of Environment*, 185, 243–257.
<https://doi.org/https://doi.org/10.1016/j.rse.2016.03.036>
- Zhu, Z., Gallant, A. L., Woodcock, C. E., Pengra, B., Olofsson, P., Loveland, T. R., Jin, S., Dahal, D., Yang, L., & Auch, R. F. (2016). Optimizing selection of training and auxiliary data for operational land cover classification for the LCMAP initiative. *ISPRS Journal of Photogrammetry and Remote Sensing*, 122, 206–221.
<https://doi.org/https://doi.org/10.1016/j.isprsjprs.2016.11.004>

- Zhu, Z., Qiu, S., & Ye, S. (2022). Remote sensing of land change: A multifaceted perspective. *Remote Sensing of Environment*, 282, 113266. <https://doi.org/https://doi.org/10.1016/j.rse.2022.113266>
- Zhu, Z., & Woodcock, C. E. (2014). Continuous change detection and classification of land cover using all available Landsat data. *Remote Sensing of Environment*, 144, 152–171. <https://doi.org/https://doi.org/10.1016/j.rse.2014.01.011>
- Zhu, Z., Zhang, J., Yang, Z., Aljaddani, A. H., Cohen, W. B., Qiu, S., & Zhou, C. (2020). Continuous monitoring of land disturbance based on Landsat time series. *Remote Sensing of Environment*, 238, 111116. <https://doi.org/https://doi.org/10.1016/j.rse.2019.03.009>

APÊNDICE A

Tabela 9 - Casos de estudo com utilização do CCDC publicados entre 2014 e 2023

Autores (Data)	Produto	Área de Estudo	Período	Datasets utilizados	Dados de referência
<i>Zhu & Woodcock (2014)</i>	Alteração de ocupação do solo	Costa de New England, USA	1982 - 2011	Landsat	Fotografia aérea
<i>Sulla-Menashe et al. (2016)</i>	Resposta de florestas a alterações climáticas	Área florestal, Canada	1984 - 2011	Landsat	Landsat e base de dados de incêndios canadiana (LFDB)
<i>Holden & Woodcock (2016)</i>	Utilização do CCDC com diferentes bandas e índices	Colorado, USA	2008 - 2015	Landsat	Landsat
<i>Vogelmann et al. (2016)</i>	Alteração de ocupação do solo	Diversos locais, USA	1985 - 2014	Landsat	N.A.
<i>Zhu, Gallant, et al. (2016)</i>	Alteração de ocupação do solo	Diversos locais, USA	1982 - 2014	Landsat	Amostragem de campo (U.S. Geological Survey's Land Cover Trends)
<i>Zhu, Fu, et al. (2016)</i>	Alteração de ocupação do solo	Guangzhou, China	1999 - 2014	Landsat	Amostragem de campo (Land Use Inventory Map of Guangzhou)
<i>Hu et al. (2018)</i>	Deteção automática de alteração de ocupação do solo	China ocidental (12 províncias)	2009 - 2014	Landsat	Mapa de ocupação do solo (ESA GlobCover 2009)
<i>Tang et al. (2019)</i>	Deteções de alterações quase-tempo-real (NRT-CCDC)	Amazónia, Brasil / Colômbia	2013 - 2015	Landsat / MODIS	Landsat
<i>Yan et al. (2019)</i>	Alteração de ocupação do solo	China	2000 - 2018	MODIS	Amostragem de campo
<i>Arévalo et al. (2020)</i>	Recuperação pós-distúrbio	Amazónia, Colômbia	1997 - 2016	Landsat	Landsat
<i>Brown et al. (2020)</i>	Classificação e alteração de ocupação do solo	Diversos locais, USA	1985 - 2017	Landsat	Amostragem de campo (U.S. Forest Service Land Change Monitoring System)

<i>Bullock et al. (2020)</i>	Alteração de ocupação do solo	Diversos locais, USA	1984 - 2015	Landsat	Landsat, Google Earth e The National Agriculture Imagery Program (NAIP)
<i>Deng & Zhu (2020)</i>	Alteração de ocupação do solo	New York, USA	2000 - 2014	Landsat	Fotografia aérea
<i>Tang, Bullock, et al. (2020)</i>	Deteções de alterações quase-tempo-real (NRT-CCDC)	Amazónia, Brasil	2013 - 2015	MODIS / VIIRS	Algoritmo de monitorização (Tang et al., 2019)
<i>Tang, Hutyra, et al. (2020)</i>	Quantificação de sequestro de carbono	Amazónia, Colômbia	2000 - 2012	Landsat	Modelo de previsão de Biomassa aérea
<i>Zhu et al. (2020)</i>	Mapeamento de perturbações	Diversos locais, USA	1985 - 2011	Landsat	Landsat
<i>S. Chen et al. (2021)</i>	Desflorestação	Geórgia	1987 - 2019	Landsat	Amostragem de campo
<i>Peneva-Reed et al. (2021)</i>	Recuperação pós-distúrbio	Florida	1985 - 2018	Landsat	United States Department of Agriculture (USDA) e National Agriculture Imagery Program (NAIP)
<i>Tang et al. (2021)</i>	Alteração de ocupação do solo / Carbono	Bacia hidrográfica do rio Mekong, Asia	2000 - 2016	MODIS	Landsat e Google Earth
<i>Xu et al. (2021)</i>	Alteração de ocupação do solo	China	1986 - 2018	Landsat	Mapa de ocupação (Resource and Environment Science and Data Center)
<i>Ye, Rogan, Zhu, & Eastman (2021)</i>	Deteções de alterações quase-tempo-real (NRT-CCDC)	USA, 3782 parcelas	1996 - 2019	Landsat	Landsat
<i>Ye, Rogan, Zhu, Hawbaker, et al. (2021)</i>	Deteções de fitossanidade quase-tempo-real (NRT-CCDC)	Colorado, USA	2001 - 2019	Landsat	Landsat e National Land Cover Database (NLCD)
<i>Zhang & Li (2021)</i>	Acompanhamento de fenologia	Yunnan, China	2013 - 2019	Landsat / Sentinel-2	Amostragem de campo
<i>Bullock et al. (2022)</i>	Alertas quase-tempo-real desflorestação	Madagáscar	2014 - 2020	Sentinel-1	Planet, Sentinel-2, Landsat e Sentinel-1

<i>Liao et al. (2022)</i>	Estimativa contínua de biomassa	Austrália ocidental	1990 - 2019	Landsat	Mapas de biomassa aérea pré-existent
<i>Fu et al. (2022)</i>	Respostas de vegetação a fenómenos meteorológicos	Honghe National Nature Reserve, China	1985 - 2021	Landsat / Sentinel-1	Amostragem de campo, imagens drone (multi-espectral), mapas topográficos e de vegetação Institute of Geography and Agroecology, Chinese Academy of Sciences
<i>Murillo-Sandoval et al. (2022)</i>	Desflorestação	Andes / Amazónia, Colombia	2000 - 2020	Landsat	N.A.
<i>Myroniuk et al. (2022)</i>	Mapeamento de biomassa aérea	Ivano-Frankivsk e Sumy, Ucrânia	1990 - 2020	Landsat	Amostragem de campo
<i>Xie et al. (2022)</i>	Alteração de ocupação do solo	Pequim, China	2001 - 2020	Landsat	Landsat e Google Earth
<i>Zhang et al. (2022)</i>	Mapeamento de perturbações	América do Norte	1984 - 2014	Landsat	Landsat e Google Earth
<i>Zhou et al. (2022)</i>	Alteração de ocupação do solo	USA	1985 - 2014	Landsat	Landsat
<i>Arévalo et al. (2023)</i>	Mapeamento de biomassa aérea	Amazónia, Brasil	1999 - 2019	Landsat / GLAS	Dados LiDAR obtidos por drone
<i>Cai et al. (2023)</i>	Desflorestação	Amazónia, 1285 parcelas	1986 - 2020	Landsat	Landsat e Google Earth
<i>T.-H. K. Chen et al. (2023)</i>	Alteração de ocupação do solo	Hindu Kush, Himalaias	1990 - 2020	Landsat	Google Earth
<i>S. Chen et al. (2023)</i>	Alteração de ocupação do solo	Laos	1991 - 2021	Landsat	Landsat e Google Earth
<i>Myroniuk et al. (2023)</i>	Acompanhamento risco de incêndio (combustível)	Chernobyl Exclusion Zone (CEZ), Ucrânia	2010 - 2022	Landsat / GEDI	Landsat e Google Earth
<i>Wang et al. (2023)</i>	Alteração de ocupação do solo	Jiangsu, China	1990 - 2020	Landsat	Landsat

APÊNDICE B

```
var featureCollection = ee.FeatureCollection('projects/ee-xxxxx');
var geometry = featureCollection.geometry();
var study_area = geometry;
var date_start = '2010-01-01';
var date_end = '2024-03-01';

var S2 = ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
    .filterBounds(study_area)
    .filterDate(date_start, date_end);

var s2cloudless = ee.ImageCollection('COPERNICUS/S2_CLOUD_PROBABILITY')
    .filterBounds(study_area)
    .filterDate(date_start, date_end);

var joinFilter = ee.Filter.equals({
  leftField: 'system:index',
  rightField: 'system:index'
});

var joinedCollection = ee.Join.inner().apply(S2, s2cloudless, joinFilter);

function maskClouds(joinedImage) {
  var s2Image = ee.Image(joinedImage.get('primary'));
  var cloudProbabilityImage = ee.Image(joinedImage.get('secondary'));
  var cloudMask = cloudProbabilityImage.select('probability').lt(30);
  return s2Image.updateMask(cloudMask).copyProperties(s2Image, s2Image.propertyNames());
}

var S2_clipped = ee.ImageCollection(joinedCollection.map(maskClouds));

function clipCollection(image) {
  return image.clip(study_area);
}

S2_clipped = S2_clipped.map(clipCollection);

function addNDVI(image) {
  var ndvi = image.normalizedDifference(['B8', 'B4']).multiply(10000).int16();
  return image.addBands(ndvi.rename('ndvi'));
}

var S2filtered = S2_clipped.map(addNDVI);

var ccdc_params = {
  collection: S2filtered.select(['ndvi', 'B3', 'B12']),
  breakpointBands: ['ndvi', 'B3', 'B12'],
  tmaskBands: ['B3', 'B12'],
  minObservations: 4,
  chiSquareProbability: 0.999,
  minNumOfYearsScaler: 1,
  dateFormat: 2,
  lambda: 200,
  maxIterations: 25000
};

var ccdc_result = ee.Algorithms.TemporalSegmentation.Ccdc(ccdc_params);

var tbreak = ccdc_result.select(['tBreak']);
var lastBreak = tbreak.arrayReduce(ee.Reducer.max(),
[0]).arrayProject([0]).arrayFlatten(['Last_Break']);

Map.addLayer(lastBreak, {}, 'Last Break');

var exportParams = {
  image: lastBreak,
  description: 'Last_Break',
  scale: 10,
  region: ee.Geometry(study_area).bounds(),
```

```
folder: 'GEE_Outputs',  
maxPixels: 1e13  
};  
Export.image.toDrive(exportParams);
```

Código utilizado na API JavaScript do GEE para obter as quebras identificadas pelo CCDC

APÊNDICE C

```
from qgis.core import QgsProcessing
from qgis.core import QgsProcessingAlgorithm
from qgis.core import QgsProcessingMultiStepFeedback
from qgis.core import QgsProcessingParameterRasterLayer
from qgis.core import QgsProcessingParameterFeatureSink
import processing

class Ccdc_process(QgsProcessingAlgorithm):

    def initAlgorithm(self, config=None):
        self.addParameter(QgsProcessingParameterRasterLayer('input_ccdc_raster', 'Input
CCDC raster', defaultValue=None))
        self.addParameter(QgsProcessingParameterFeatureSink('Breaks_ccdc', 'Breaks_CCDC',
type=QgsProcessing.TypeVectorAnyGeometry, createByDefault=True, supportsAppend=True,
defaultValue=None))

    def processAlgorithm(self, parameters, context, model_feedback):
        feedback = QgsProcessingMultiStepFeedback(7, model_feedback)
        results = {}
        outputs = {}

        # r.neighbors
        alg_params = {
            '-a': False,
            '-c': False,
            'GRASS_RASTER_FORMAT_META': '',
            'GRASS_RASTER_FORMAT_OPT': '',
            'GRASS_REGION_CELLSIZE_PARAMETER': 0,
            'GRASS_REGION_PARAMETER': None,
            'gauss': None,
            'input': parameters['input_ccdc_raster'],
            'method': 2, # mode
            'quantile': '',
            'selection': parameters['input_ccdc_raster'],
            'size': 5,
            'weight': '',
            'output': QgsProcessing.TEMPORARY_OUTPUT
        }
        outputs['Rneighbors'] = processing.run('grass7:r.neighbors', alg_params,
context=context, feedback=feedback, is_child_algorithm=True)

        feedback.setCurrentStep(1)
        if feedback.isCanceled():
            return {}

        # Polygonize (raster to vector)
        alg_params = {
            'BAND': 1,
            'EIGHT_CONNECTEDNESS': False,
            'EXTRA': '',
            'FIELD': 'DN',
            'INPUT': outputs['Rneighbors']['output'],
            'OUTPUT': QgsProcessing.TEMPORARY_OUTPUT
        }
        outputs['PolygonizeRasterToVector'] = processing.run('gdal:polygonize',
alg_params, context=context, feedback=feedback, is_child_algorithm=True)

        feedback.setCurrentStep(2)
        if feedback.isCanceled():
            return {}

        # Zonal statistics
        alg_params = {
            'COLUMN_PREFIX': 'MS',
            'INPUT': outputs['PolygonizeRasterToVector']['OUTPUT'],
            'INPUT_RASTER': outputs['Rneighbors']['output'],
            'RASTER_BAND': 1,
            'STATISTICS': [9], # Majority
            'OUTPUT': QgsProcessing.TEMPORARY_OUTPUT
```

```

    }
    outputs['ZonalStatistics'] = processing.run('native:zonalstatisticsfb',
alg_params, context=context, feedback=feedback, is_child_algorithm=True)

    feedback.setCurrentStep(3)
    if feedback.isCanceled():
        return {}

    # datetime_from_epoch
    alg_params = {
        'FIELD_LENGTH': 0,
        'FIELD_NAME': 'Date',
        'FIELD_PRECISION': 0,
        'FIELD_TYPE': 3,
        'FORMULA': 'datetime_from_epoch("MSmajority")',
        'INPUT': outputs['ZonalStatistics']['OUTPUT'],
        'OUTPUT': QgsProcessing.TEMPORARY_OUTPUT
    }
    outputs['Datetime_from_epoch'] = processing.run('native:fieldcalculator',
alg_params, context=context, feedback=feedback, is_child_algorithm=True)

    feedback.setCurrentStep(4)
    if feedback.isCanceled():
        return {}

    # format_date
    alg_params = {
        'FIELD_LENGTH': 0,
        'FIELD_NAME': 'ym',
        'FIELD_PRECISION': 0,
        'FIELD_TYPE': 2,
        'FORMULA': 'format_date("Date", \'yyyy/MM\')',
        'INPUT': outputs['Datetime_from_epoch']['OUTPUT'],
        'OUTPUT': QgsProcessing.TEMPORARY_OUTPUT
    }
    outputs['Format_date'] = processing.run('native:fieldcalculator', alg_params,
context=context, feedback=feedback, is_child_algorithm=True)

    feedback.setCurrentStep(5)
    if feedback.isCanceled():
        return {}

    # dropna
    alg_params = {
        'EXPRESSION': '"ym" != \'1970/01\'',
        'INPUT': outputs['Format_date']['OUTPUT'],
        'OUTPUT': QgsProcessing.TEMPORARY_OUTPUT
    }
    outputs['Dropna'] = processing.run('native:extractbyexpression', alg_params,
context=context, feedback=feedback, is_child_algorithm=True)

    feedback.setCurrentStep(6)
    if feedback.isCanceled():
        return {}

    # Field calculator
    alg_params = {
        'FIELD_LENGTH': 5,
        'FIELD_NAME': 'Area_ha',
        'FIELD_PRECISION': 3,
        'FIELD_TYPE': 0,
        'FORMULA': '$area/10000',
        'INPUT': outputs['Dropna']['OUTPUT'],
        'OUTPUT': parameters['Breaks_ccdc']
    }
    outputs['FieldCalculator'] = processing.run('native:fieldcalculator', alg_params,
context=context, feedback=feedback, is_child_algorithm=True)
    results['Breaks_ccdc'] = outputs['FieldCalculator']['OUTPUT']
    return results

def name(self):
    return 'CCDC_Process'

```

```
def displayName(self):  
    return 'CCDC_Process'  
  
def group(self):  
    return ''  
  
def groupId(self):  
    return ''  
  
def createInstance(self):  
    return Ccdc_process()
```

Algoritmo Python utilizado para processar as quebras identificadas pelo CCDC e gerar a carta de alterações.



**Validação da utilização do CCDC em séries temporais
Sentinel-2 para a deteção de desflorestação em Portugal**
Confronto com dados históricos de gestão florestal

Filipe José Afonso Sabino de Sousa Louro

Dissertação apresentada como requisito parcial para obtenção do grau de
Mestre em Ciência e Sistemas de Informação Geográfica

UNIGIS PT

