

DETEÇÃO DE ALTERAÇÕES PARA ATUALIZAÇÃO DE CARTOGRAFIA

Tiago Soares Ferreira de Castro, Academia Militar, Centro de Informação Geoespacial do Exército, Faculdade de Ciências da Universidade de Lisboa, castro.ts@exercito.pt

DOI: https://doi.org/10.60746/8_14_36808

ABSTRACT

As part of the project work for the Master's Degree in Geospatial Engineering, an investigation was conducted to present a Change Detection methodology in order to support the update of the Portuguese Military Charter series M888 at a scale of 1:25 000. Historical cartographic records of the regions of Coimbra, Santarém and Cartaxo were used, which by comparison with the semantic segmentation of current images (orthophotos), enabled outdated ratios to be calculated and change maps to be created. The adopted methodology included data pre-processing, semantic segmentation of the orthophotos from the second epoch, and its utilization to detect changes. In the segmentation of Coimbra, Santarém, and Cartaxo data, it achieved, respectively, Intersection Over Union values of 0.45, 0.37, and 0.43, and Overall Accuracy of 0.80, 0.75 and 0.81. The change detection methodology reported outdated rates of 24.8%, 31.7%, and 30.1%, respectively, which compared to the cartography records, were overestimated by 10.3%. Area under the receiver operating characteristic curve values of 0.76, 0.79 and 0.82 and false negative rates of 5.6%, 3.5% and 3.0%, respectively, were obtained.

Keywords: Change detection, Deep learning, Ensemble learning, Cartographic update, Orthophotos.

RESUMO

No âmbito do trabalho de projeto do Mestrado em Engenharia Geoespacial, foi desenvolvida uma investigação com o objetivo de apresentar uma metodologia de deteção de alterações (*Change Detection*, CD) para apoio à atualização da Carta Militar de Portugal da série M888 à escala 1:25 000. Utilizaram-se dados históricos de cartografia das regiões de Coimbra, Santarém e Cartaxo, que por comparação com a segmentação semântica de imagens atuais (ortofotos) permitiram calcular taxas de desatualização e criar mapas de alterações. A metodologia adotada contemplou o pré-processamento dos dados, segmentação semântica das ortofotos da segunda época e sua utilização para a deteção de alterações. Na segmentação dos dados de Coimbra, Santarém e Cartaxo, obtiveram-se, respetivamente, valores de *Intersection Over Union* de 0.45, 0.37 e 0.43, e exatidão global de 0.80, 0.75 e 0.81. A deteção de alterações permitiu calcular valores de desatualização de 24.8%, 31.7% e 30.1% respetivamente, que comparadas com dados de cartografia, indicam sobrestimação média de 10.3%. Foram obtidos valores de área sob a curva ROC (*Receiver Operating Characteristic Curve*) de 0.76, 0.79 e 0.82, e taxas de falsos negativos de 5.6%, 3.5% e 3.0%, respetivamente.

Palavras-chave: Deteção de alterações, Aprendizagem profunda, Aprendizagem em conjunto, Atualização cartográfica, Ortofotos.

1. INTRODUÇÃO E ENQUADRAMENTO AO TEMA

Atualmente a aplicação da Inteligência Artificial (IA) no âmbito das geociências é um tema de elevado interesse e vasta aplicação. O Centro de Informação Geoespacial do Exército (CIGeoE) procura acompanhar os seus desenvolvimentos através da realização de vários trabalhos de investigação e participação ativa em diferentes fóruns, tais como reuniões técnicas, *workshops* e seminários. Enquanto órgão militar

responsável pela produção de informação geoespacial, tem a função de assegurar a informação geográfica necessária às suas atividades, em particular através do planeamento e execução dos trabalhos para produção da Carta Militar de Portugal à escala 1:25 000 (Carta Militar) e respetivas bases de dados geográficas (BDG) (CIGeoE, 2023; «Decreto Regulamentar n.º 11/2015», 2015).

A publicação da primeira folha da Carta Militar data de 1934, existindo atualmente um largo acervo histórico de dados de cartografia, nomeadamente diversas edições de cada folha englobando o território nacional. Para efeitos da sua atualização, entre diversos fatores influenciadores (por exemplo a disponibilidade de voo fotogramétrico), habitualmente a escolha dos blocos de trabalho segue a ordem cronológica (data de edição das folhas), não se considerando os ritmos de desatualização próprios de cada região e/ou entidades geoespaciais nelas presentes.

Neste sentido torna-se oportuna a avaliação prévia da desatualização de uma região, algo que poderá permitir o estabelecimento de prioridades na sua seleção.

1.1. CICLO DE PRODUÇÃO CARTOGRÁFICA

Na elaboração de novas edições da Carta Militar é seguido o atual Processo de Produção Cartográfica, contemplando três fases. O seu planeamento é da responsabilidade da Repartição de Produção Cartográfica, propondo à Direção do CIGeoE a aprovação da zona do território nacional a cartografar, com designação e descrição de um bloco de trabalho (CIGeoE, 2023).

A primeira fase é relativa à aquisição de informação por restituição estereoscópica (3D) e construção da BDG, seguindo-se após os trabalhos de completagem de campo, a edição cartográfica (CIGeoE, 2023). Neste processo, os elementos da cartografia constantes nas Normas de Aquisição de Dados do CIGeoE (NAD) são

maioritariamente adquiridos de raiz, não estando priorizada a reutilização de informação geográfica vetorial da edição anterior.

A existência de dados históricos tem promovido o teste e utilização de algoritmos de IA neste processo. Com o desenvolvimento de diferentes algoritmos para segmentação semântica (SS) (na tarefa de segmentação semântica de imagens pretende-se atribuir uma classe a cada um dos seus pixéis) de imagens aéreas de detecção remota (*Remote Sensing*, DR), nomeadamente no âmbito da aprendizagem automática (*Machine Learning*, ML) e aprendizagem profunda (*Deep Learning*, DL), assiste-se a uma melhoria crescente na qualidade dos resultados. Por outro lado, os recentes desenvolvimentos de técnicas de CD, permitem a investigação de metodologias para a sua combinação e melhoria do processo de produção cartográfica.

A implementação de técnicas de CD cria a oportunidade de se averiguar antecipadamente quais as áreas e classes de ocupação do solo mais desatualizadas, permitindo uma escolha mais criteriosa do próximo bloco a atualizar. A sua utilização também poderá permitir a automatização de alguns processos, uma vez que, na fase de aquisição de informação poderão ser desenvolvidos procedimentos para utilização dos dados pré-existentes.

1.2. OBJETIVO GERAL

Nesta sequência, a investigação pretende averiguar a utilização de CD pelo método de comparação pós-classificação, para efeitos de atualização cartográfica da Carta Militar, utilizando-se dados históricos de cartografia tais como as BDG e ortofotos existentes. Pretende-se obter previamente a taxa de desatualização de uma determinada área, permitindo a priorização das folhas a atualizar, assim como georreferenciar as alterações por classe.

Procurando resolver este problema de investigação, foi estabelecido o seguinte objetivo de investigação: apresentação de uma metodologia de Detecção de Alterações para efeitos de atualização cartográfica da Carta Militar de Portugal série M888 à escala 1:25000, permitindo uma avaliação prévia da taxa de desatualização ao nível de uma determinada folha, assim como a georreferenciação dos elementos e classes a atualizar.

1.3. INTELIGÊNCIA ARTIFICIAL NO ÂMBITO DAS GEOCIÊNCIAS

Nesta investigação foram utilizados diversos algoritmos de IA, nomeadamente diversos tipos de redes neuronais totalmente convolucionais (*Fully Convolutional Network*, FCN) no âmbito do DL. IA é um termo utilizado há várias décadas, tendo assumido diferentes significados. Jonh McCarthy et al. no verão de 1955 propuseram o termo de IA para descrever programas de computador que aparentemente demonstram inteligência, ou seja, programas capazes de realizar tarefas que habitualmente são realizadas por humanos e que necessitam da sua inteligência (Conway, 2018; Rajaraman, 2014). Engloba a disciplina de ML que por sua vez engloba o DL, que embora façam parte da mesma disciplina geral de IA, diferem na sua forma de aplicação e funcionamento (Ilustração 1).

Em DR os modelos de DL são vistos como os de maior capacidade, fruto da sua característica em produzir automaticamente mapas de características relevantes (*Feature Maps*, FM) dos dados ao longo da sua estrutura. Estes são um conjunto de representações intermédias, derivadas das características dos dados iniciais, utilizados durante a fase de treino dos modelos, que aumentam a sua capacidade de discriminar e interpretar novos dados (Thwal, 2019). Estas camadas intermédias denominadas por camadas ocultas (*hidden layers*), permitem a aprendizagem de características de

significado semântico progressivamente superior, criando o conceito de Redes Neurais Profundas, ou seja, a noção de DL.

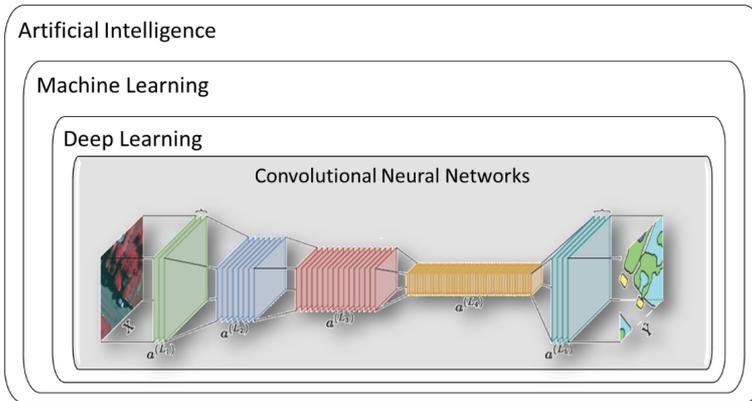


Ilustração 1: Relação entre IA, ML e DL

Fonte: Adaptado de Goodfellow et al. (2016)

Existem diversas aproximações de modelos de DL em DR, destacando-se a arquitetura das Redes Neurais Convolucionais (*Convolutional Neural Networks*, CNNs) e das FCN (Khelifi & Mignotte, 2020). As camadas iniciais das FCNs que formam o caminho de contração, habitualmente são denominadas por extratores dos FMs (*backbone*), podendo ser uma qualquer arquitetura de rede para classificação de imagens (ie. VGG, *ResNet* ou *EfficientNet*) (Ball et al., 2017).

Os avanços tecnológicos verificados nas plataformas de DR, permitem que atualmente os dados sejam recolhidos com melhores resoluções. Anteriormente as reduzidas resoluções espaciais, temporais e espectrais, limitavam o desenvolvimento de metodologias como o caso da CD (Shafique et al., 2022). Presentemente, tem-se assistido a maior incidência no desenvolvimento de metodologias de CD, dada a sua adequabilidade numa vasta área de aplicações tais como, atualização de informação cartográfica, deteção de áreas ardidas, monitorização de desastres naturais,

monitorização ambiental, análise de alterações urbanas, monitorização e gestão da cobertura e utilização do solo, entre outras (Alhedyan, 2021; Thwal, 2019).

Em geral CD pode ser definida como o processo de identificação de alterações relevantes num objeto, pela observação dos dados em diferentes momentos (de Jong & Bosman, 2018; Farida, 2021). As técnicas de comparação pós-classificação incluem-se nos métodos supracitados e técnicas baseadas na análise ao nível do pixel (Farida, 2021). Baseiam-se na SS independente de duas imagens, sendo comparadas segundo um critério definido em função dos elementos dos quais se pretendem destacar evoluções ou mudanças de estado.

2. DADOS E MÉTODOS

Neste capítulo é apresentada a metodologia proposta para CD, com vista à atualização de cartografia a partir de imagens de alta resolução espacial (*Very High Resolution*, VHR) e dados cartográficos existentes.

2.1. ÁREA DE ESTUDO

A Área de Estudo (AE) selecionada encontra-se subdividida em três regiões, nomeadamente Coimbra, Santarém e Cartaxo. São enquadradas no cartograma da Carta Militar pelas suas folhas 230, 353 e 364, conforme se observa na Ilustração 2. Considerando o objetivo da investigação, as NAD e as características das entidades geográficas existentes na AE, foram definidas oito classes de ocupação do solo: Construções, Vias Principais, Vias Secundárias, Hidrografia, Vegetação, Cultivo, Solo Nu e Sem Classe (corresponde ao fundo não identificado da cartografia). Como se observa nos gráficos circulares da Ilustração 2, em cada AE as classes distribuem-se em diferentes percentagens, traduzindo-se numa grande variabilidade na sua representação. Também se verifica que algumas são sempre minoritárias, enquanto

outras mais predominantes. Cada classe engloba um conjunto de vários tipos de objetos geográficos distintos, mas relacionados, algo que confere heterogeneidade aos dados de treino. Pode-se verificar o exemplo da classe de Cultivo que engloba áreas de Pomar, Vinhas e Arrozal. Tais factos aumentam a complexidades dos dados, dificultam o treino de algoritmos de segmentação semântica e a obtenção de bons resultados em todas as classes.

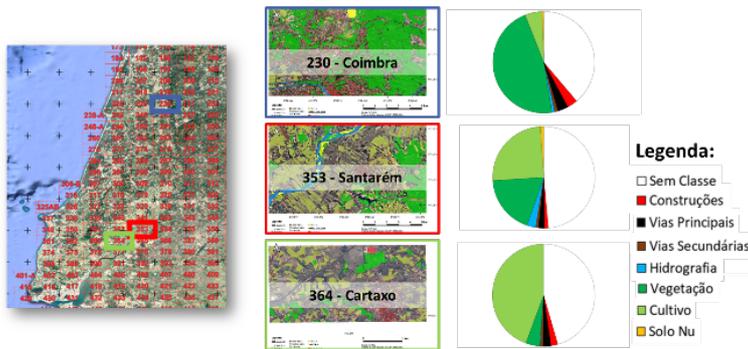


Ilustração 2: Enquadramento e caracterização da área de estudo

Fonte: Elaboração própria

2.2. DADOS

Na investigação foram utilizados os dados vetoriais das BDG e respetivas ortofotos, tendo sido selecionados dados de duas edições já existentes. As BDG foram utilizadas para criação das máscaras de classes de ocupação do solo. Já as ortofotos foram utilizadas conjuntamente com estas máscaras para treino, validação e teste dos modelos de DL. Os dados da primeira época (T1) foram utilizados no treino e validação, enquanto que os da segunda época (T2) para a fase de testes e avaliação dos resultados. As ortofotos caracterizam-se por serem produtos elaborados para apoio da cadeia de produção, sendo utilizadas no CIGeoE durante os trabalhos de aquisição da informação

geográfica. As suas principais características encontram-se detalhadas na Ilustração 3. Da sua análise é possível verificar que em cada AE, o voo fotogramétrico entre as duas edições foi realizado em estações do ano distintas e com câmaras diferentes. Tal terá impacto na resposta espectral dos objetos, dificultando a tarefa de aplicação de modelos treinados em novos conjuntos de dados.

| | | Folha da Carta Militar | | | | | |
|---|-----------------------------|---------------------------------|---------------------------------|----------------------------------|----------------------------------|---------------------------------|---------------------------------|
| | | 230 – Coimbra (5ª Edição) | 230 – Coimbra (6ª Edição) | 353 – Santarém (4ª Edição) | 353 – Santarém (5ª Edição) | 364 – Cartaxo (4ª Edição) | 364 – Cartaxo (5ª Edição) |
| Descrição dos dados de Cartografia | Ano de produção | 2011 | 2017 | 2004 | 2012 | 2003 | 2012 |
| | Datum planimétrico | WGS84 Militar | | | | | |
| | Datum altimétrico | Marégrafo de Cascais | | | | | |
| | Elipsóide | WGS84 | | | | | |
| | Projeção | Gauss Krüger | | | | | |
| | Fonte de aquisição de dados | Fotografia Aérea | | | | | |
| | | UltraCam Xp | UltraCam Xp-wa | Wild RC 20 | UltraCam Xp | Wild RC 20 | UltraCam Xp |
| Descrição da fonte de aquisição dos dados | Data do voo | Outubro de 2010 | Maior de 2015 | Junho de 2001 | Outubro de 2010 | Junho de 2001 | Outubro de 2010 |
| | Resolução Espacial | 0.5 m | | | | | |
| | Bandas | RGB | | | | | |
| | | | | | | | |

Ilustração 3: Descrição dos dados utilizados

Fonte: Elaboração própria

Conforme será descrito na metodologia, foram utilizadas duas edições da mesma Folha da Carta Militar. Dado que a aquisição das fotos ocorreu em épocas do ano distintas e utilizando câmaras diferentes, os próprios dados contêm em si várias diferenças que se manifestam como ruído na fase do treino. Na Ilustração 4 é possível verificar esse efeito no histograma (o histograma é a distribuição de frequência dos níveis de cinzento de uma imagem. Para cada banda RGB, cada valor no eixo das abcissas representa o nível de cinzento específico e no eixo das ordenadas representa o número de ocorrências desse nível) correspondente à ortofoto de exemplo.



Ilustração 4: Caracterização dos dados da área de estudo do Cartaxo

Fonte: Elaboração própria

2.3. METODOLOGIA

Considerando o objetivo de investigação, a metodologia adotada contempla três fases principais, iniciando-se pelo pré-processamento dos dados, seguindo-se a fase de SS de imagens, terminando com a fase de CD. Na Ilustração 5 é possível observar um esquema global desta metodologia, no qual as fases principais se encontram numeradas de 1 a 3, e dentro de cada uma delas as suas principais tarefas identificadas por letras de [a] a [h].

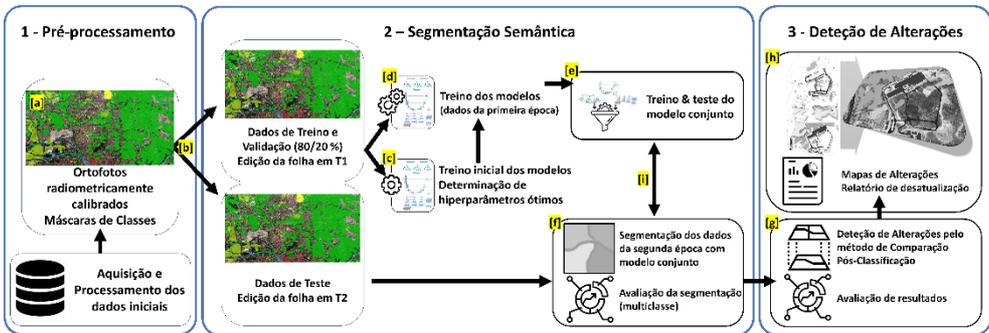


Ilustração 5: Fluxograma da metodologia adotada

Fonte: Elaboração própria

Na fase de pré-processamento dos dados (cf. 1 da Ilustração 5) foi efetuada a transformação das BDG nas máscaras de classes (de T1 e T2), seu correjisto com as

ortofotos e preparação dos dados para treino dos modelos de DL (cf. 2 [b] da Ilustração 5). Dada a heterogeneidade verificada entre as ortofotos, foi aplicada uma calibração radiométrica relativa através da técnica de correspondência de histogramas (*histogram matching*) (assinalado em [a] na Ilustração 5). Na preparação dos dados para treino dos modelos de DL, as ortofotos e respetivas máscaras de classes foram divididas em mosaicos (*patches*) de dimensão de 256x256 pixels. Posteriormente foram separados em dois grupos na proporção de 80% e 20% para a fase de treino e validação, respetivamente.

Na fase seguinte foram treinados e utilizados os algoritmos de DL para a tarefa de SS das ortofotos (cf. 2, [c] a [e] da Ilustração 5). Este processo decorreu inicialmente na região de Coimbra, sendo posteriormente replicado nas restantes (assinalado em [i] na Ilustração 5). Durante a segmentação das ortofotos de T2 as AE utilizadas correspondem a $\frac{1}{16}$ da área das respetivas folhas, ou seja, uma área total de 1000ha (4000m por 2500m). Para tal foram utilizadas duas arquiteturas de FCN com diferentes *backbones*, nomeadamente a U-Net e a FPN com *backbones* das famílias *ResNet* e *EfficientNet*. Também foi testado um modelo U-Net sem transferência de aprendizagem. Para cada configuração foi definido um número máximo de 500 épocas de treino, com uma condição de paragem de 50 épocas sem melhorias nos resultados. Por fim utilizou-se a técnica de CD pelo método de comparação pós-classificação (cf. 3 da Ilustração 5), comparando o resultado da segmentação de T2 (pelos modelos treinados) com a máscara de classes de T1 (dados históricos de cartografia). A máscara de classes de T2 oriunda de dados de cartografia, foi utilizada na avaliação de resultados (cf. assinalado em [g] e [h] da Ilustração 5). A aplicação desta metodologia permite a obtenção da taxa de desatualização global da AE, georreferenciação das alterações por classe e detalhe da variabilidade entre classes.

O processo de CD por comparação pós-classificação foi efetuado pela análise de diferenças ao nível do pixel, entre a máscara de T1 e o resultado da segmentação de T2, permitindo obter um mapa assinalando as diferenças entre épocas e variação entre as classes (cf. assinalado em [g] da Ilustração 5). No final desta fase é possível avaliar a taxa de desatualização da área analisada e georreferenciar as alterações.

A Ilustração 6 permite verificar um exemplo sumário de produção de uma máscara de alterações para a classe de Construções. Pela sua análise verifica-se que apenas assinalou as áreas onde a metodologia detetou novas construções e as áreas onde existiam em T1 mas não em T2. Este processo é realizado no sentido de eliminar aquelas construções que se mantêm entre épocas. Também segue um princípio de minimização de situações de falsos negativos, mesmo que para tal seja aumentado o número de falsos positivos. Entende-se que é preferível aumentar o volume de trabalho por existirem mais elementos a confirmar alterações, do que ter uma taxa superior de falha na sua deteção.

Para facilitar a utilização das máscaras de alterações, torna-se necessário o seu processamento no sentido de realçar as áreas identificadas (cf. assinalado em [h] da Ilustração 5). O objetivo da edição do mapa de alterações é a obtenção de um mapa de alterações por classe e de fácil consulta, para facilitar a identificação dos objetos geográficos no processo de atualização cartográfica. Pretende-se maximizar a possibilidade de utilização dos dados pré-existentis sempre que possível, bastando apenas a verificação (e edição quando necessário) dos elementos assinalados por estes mapas de alterações (Ilustração 7).

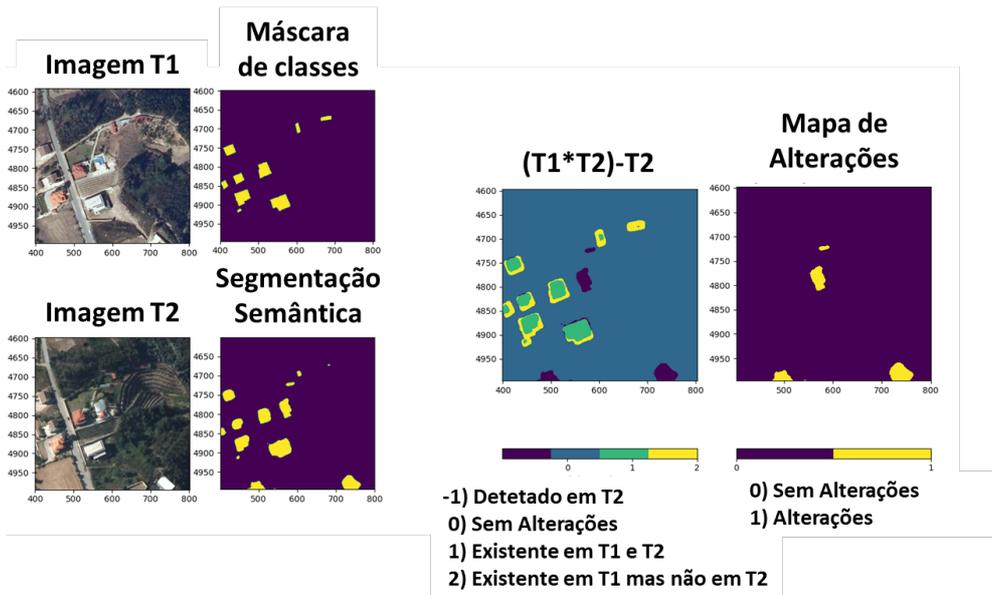


Ilustração 6: Exemplo de melhoria de resultados na classe Construções

Fonte: Elaboração própria



Ilustração 7: Exemplo de mapa de alterações editado

Fonte: Elaboração própria

2.4. MÉTRICAS DE AVALIAÇÃO

Nas tarefas de CD a avaliação da qualidade dos resultados realiza-se em duas fases, exigindo métricas distintas: num primeiro momento a avaliação e comparação dos resultados da SS da imagem de T2, seguindo-se a avaliação da subsequente deteção de alterações (de Jong & Bosman, 2018). Para avaliar a segmentação das ortofotos, tal como diversos autores sugerem (Sang & Minh, 2018), as métricas selecionadas foram a exatidão global (*overall accuracy*, OA), F1-Score (F1) e o mIOU (*mean Intersection Over Union*), que por facilidade de exposição será denominado simplesmente por IOU. Na avaliação de CD também será utilizada a ROC-Curve (*Receiver Operating Characteristic Curve*) (Piralilou et al., 2019).

O cálculo destas métricas é possível através da comparação entre cada pixel das imagens resultantes da segmentação e respetivas máscaras de classes. No âmbito de CD, cada pixel poderá ser classificado em quatro grupos com a seguinte interpretação (Radke et al., 2005; Shafique et al., 2022):

- Verdadeiro positivo (*True Positives*, VP) - pixel corretamente detetado;
- Falso positivo (*False Positives*, FP ou *false alarms*) - pixel sem alterações, mas identificado como tendo alterações;
- Verdadeiro negativo (*True Negatives*, VN) - pixel corretamente assinalado como não tendo alterações;
- Falso negativo (*False Negatives*, FN ou *misses*) - pixel com alterações incorretamente assinalado como não tendo alterações.

O IOU pode ser interpretado como uma medida de avaliação da quantidade de sobreposição de uma determinada segmentação de imagem e a máscara de classes de referência (verdade do terreno). Define-se pela razão entre a interseção destas duas máscaras e a sua união. pode assumir valores entre 0 e 1 (0 e 100 %), onde o valor de 0 corresponde à total ausência de interseção entre a verdade do terreno e o resultado

da segmentação e 1 corresponde à sobreposição perfeita entre a verdade do terreno e o resultado da segmentação (cf. Ilustração 8).

OA reflete a razão entre todos os pixels corretamente classificados e o total dos pixels presentes nessa imagem, ou seja, quão perto estão as classificações efetuadas da verdade do terreno. Esta métrica varia entre 0 e 1 (0 e 100 %), sendo que valores próximos a 1 indicam que o modelo está a atribuir classe correta à maioria dos pixels analisados.

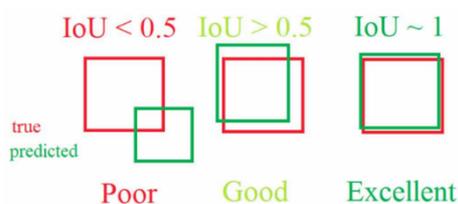


Ilustração 8: Interpretação da métrica IOU

Fonte: Adaptado de Majchrowska (2020).

O F1 reflete uma média ponderada com pesos equivalentes, entre a precisão (*precision*) e a revocação (*recall*). Para uma determinada classe, a precisão é o rácio entre pixels corretamente classificados e o conjunto dos positivamente classificados como pertencentes à classe. Já a revocação avalia o rácio entre os pixels corretamente classificados e o conjunto dos que pertencem realmente a essa classe, permitindo medir a capacidade do nosso modelo em identificar corretamente os VP. F1 considera não só a quantidade de pixels bem classificados, assim como quantos dos verdadeiramente pertencentes em cada classe e que foram corretamente classificados. Varia entre 0 e 1, onde 1 corresponde à correta classificação de todos os pixels e 0 a uma classificação totalmente errada. Valores elevados indicam que o modelo obtém um bom equilíbrio entre a precisão e a revocação, ou seja, tem uma boa taxa VP relativamente a FP e FN.

O IOU e a OA são métricas utilizadas para avaliação global dos modelos. Já o F1, a precisão e a revocação permitem avaliar o desempenho do modelo em função de cada classe.

Para a avaliação de um classificador binário habitualmente é utilizada a curva ROC. Esta é traçada utilizando as medidas de sensibilidade e especificidade (Shafique et al., 2022). A sensibilidade (ou taxa de VP) avalia a capacidade do modelo classificar corretamente resultados positivos. Já a especificidade (ou taxa de VN) mede a capacidade do modelo identificar as classificações negativas. Esta métrica permite quantificar a exatidão do modelo através da medição da área sob a curva ROC (*Area Under Curve*, AUC). Quanto mais próxima a curva se apresentar do canto superior esquerdo do gráfico, maior a exatidão obtida pelo nosso modelo. Este valor varia entre 0 e 1, onde 1 corresponde a um modelo perfeito. Tem como desvantagem a incapacidade de verificar o algoritmo em diferentes regiões da área analisada, fornecendo apenas o valor global do seu desempenho.

4. RESULTADOS

Os resultados obtidos serão apresentados em função da Segmentação Semântica e Detecção de Alterações, para as três AE de estudo, conforme fases 2 e 3 da metodologia apresentada na Ilustração 5.

4.1. SEGMENTAÇÃO SEMÂNTICA

Os resultados obtidos na AE de Coimbra são os apresentados na Ilustração 9.

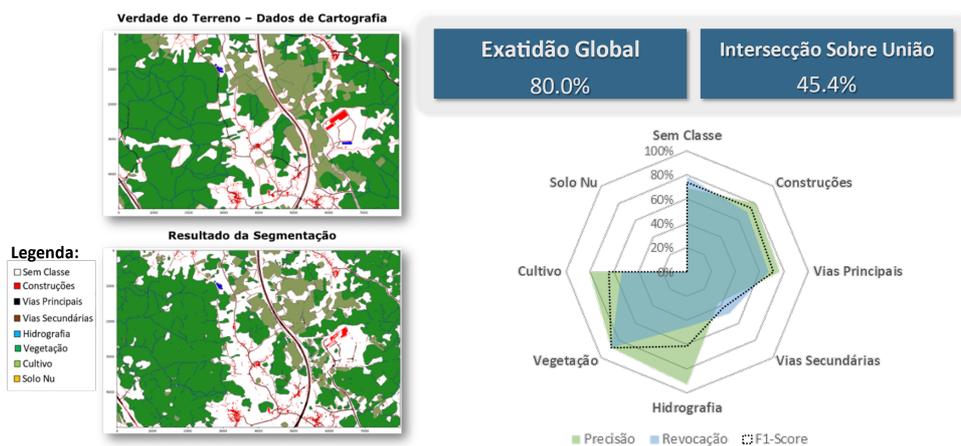


Ilustração 9: Resultados da segmentação semântica na AE de Coimbra

Fonte: Elaboração própria

Verificam-se valores de OA de 80.0% e IOU de 45.4%. Estes valores refletem não só uma boa taxa de pixéis corretamente classificados, assim como uma aceitável correspondência e sobreposição entre os vários objetos geográficos identificados.

Genericamente foram obtidos bons resultados nas classes predominantes nesta AE, nomeadamente as classes de Vegetação, Construções, Sem Classe e Vias principais, que totalizam 92% da AE. Estas classes apresentaram valores de F1 sempre superiores a 71.6%.

Por outro lado, os piores resultados verificaram-se nas classes de Vias Secundárias, Hidrografia e Solo Nu. As Vias Secundárias na sua grande maioria localizam-se em zonas densamente arborizadas, estando muitas vezes cobertas por vegetação. Deste modo vários segmentos destas são classificadas como Vegetação, degradando os resultados. Na Hidrografia verifica-se baixa revocação, ou seja, de todos os verdadeiros positivos grande parte deles não foi classificado corretamente. Conforme se verifica na Ilustração 2, a classe de Vias Secundárias e a de Solo Nu são minoritárias,

tendo como consequência piores resultados e maior sensibilidade a falhas na classificação. Ainda assim, salienta-se que estes resultados nestas três classes específicas dizem respeito a apenas 3% dos dados desta AE.

Quanto à Segmentação Semântica efetuada na AE do Cartaxo os resultados globais obtidos foram de 74.8% em OA e apenas 36.9% em IOU. O valor de IOU foi mais reduzido pois os objetos geográficos nesta AE são mais numerosos e de contornos mais irregulares. A AE de Santarém e do Cartaxo são caracterizadas pela existência de várias parcelas agrícolas de geometria variável e complexa, sendo fator que dificulta a obtenção de um bom valor de IOU.

Relativamente aos resultados de cada classe em Santarém, importa referir que os piores resultados se encontram nas classes de: Vias Secundárias, Hidrografia e Solo Nu. Relativamente às Vias Secundárias, destaca-se que nesta AE existe maior percentagem de áreas de cultivo, cujo traçado das suas plantações revela muitas vezes semelhanças com esta classe. Tal resultou em baixa precisão e revocação nesta classe. Na classe de Hidrografia verificou-se baixa revocação, ou seja, de todos os VP grande parte deles não foi classificado corretamente. Tal decorre das próprias NAD onde os elementos de hidrografia são adquiridos pelo nível pleno de armazenamento, que na grande maioria dos casos não corresponde ao nível das águas do momento, sendo que este é o visualizado pelos algoritmos. A classe Solo Nu corresponde a apenas 1% da AE. Neste caso específico localiza-se no leito do rio, onde foram encontrados alguns erros na construção da máscara de classes.

As classes de Cultivo, Sem Classe e Construções foram as que apresentaram melhores resultados de F1 com valores de 76.8%, 79.5% e 68.5% respetivamente. Estas classes correspondem a aproximadamente 75% da ocupação do solo nesta AE.

Na AE do Cartaxo nas métricas de avaliação globais dos resultados registaram-se valores de IOU de 42.7% e OA de 80.8%.

As classes de Cultivo, Sem Classe e Vias Principais, que representam mais de 92% desta AE, foram as que apresentaram melhores resultados, registando-se valores de 73.8%, 86.6% e 72.6% em F1, respetivamente.

Mais uma vez os piores resultados verificaram-se nas classes de Vias Secundárias e Hidrografia, que neste caso dizem respeito a apenas 1% da AE. Na classe Hidrografia apenas existiam dois corpos de água e de reduzida dimensão, e uma vez não terem sido identificados, o resultado foi muito negativo.

4.2. DETEÇÃO DE ALTERAÇÕES

Em cada AE os valores reais das alterações e sua georreferenciação, foram calculados por comparação entre as máscaras de classes das duas épocas. Já os valores calculados pela metodologia foram obtidos por comparação da máscara de classe de T1 e a máscara resultante da SS de T2.

Na AE de Coimbra assinalou-se uma taxa de desatualização real de 18.0%, correspondendo a uma área total de alterações de 180.2ha. Utilizando a mesma metodologia com os resultados da segmentação, o valor obtido foi de 24.8%, correspondendo a uma área total de 247.5ha. Estes valores demonstram uma sobrestimação da taxa de desatualização em 6.8% e 67.3ha.

Quanto ao mapa de alterações elaborado, na Ilustração 10 apresentam-se os resultados obtidos comparativamente à verdade do terreno. A verde assinalam-se as áreas de VP (zonas com alterações corretamente identificadas), a vermelho os FN (zonas com alterações não identificadas) e a amarelo zonas de FP (zonas sem alterações, mas identificadas como tendo alterações). Toda a área a negro corresponde a situações de VN, ou seja, zonas sem alterações devidamente identificadas como tal.

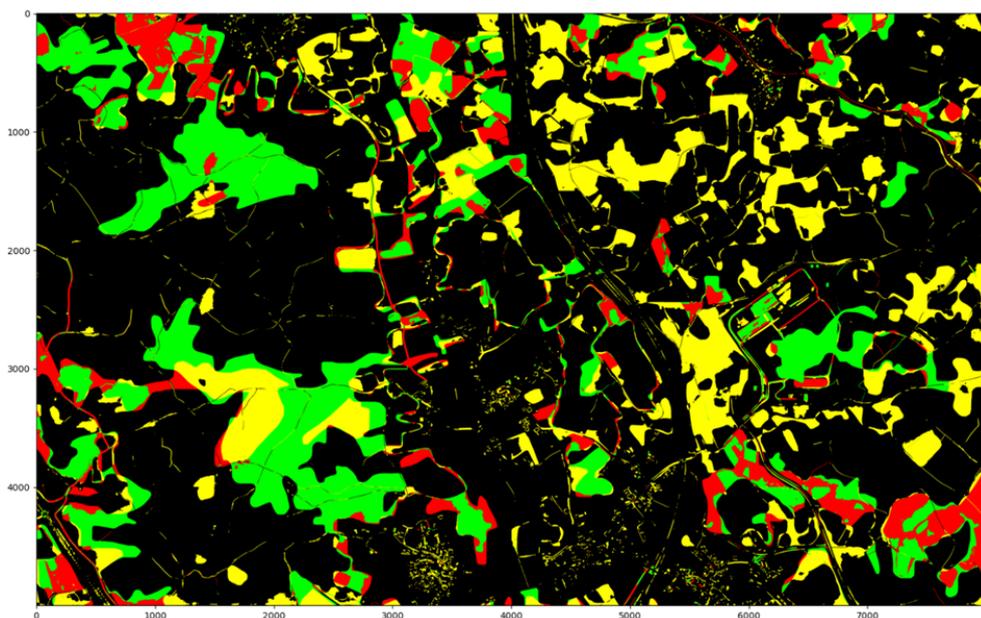


Ilustração 10: Mapa de alterações – Coimbra

Fonte: Elaboração própria

Posteriormente foi calculado e obtido um IOU de 54.2%, refletindo a coincidência e exatidão de contornos entre a máscara de alterações real e o mapa de alterações obtido. Também foi calculada a curva ROC e a matriz de confusão pela comparação destes dados (cf. Ilustração 11). Da sua análise verifica-se que o valor de AUC é 0.76, indicando de que o modelo e metodologia adotada permitem uma boa identificação das alterações.

Como se pode observar na matriz de confusão, em 70% da área analisada foi possível verificar que se acertou na previsão de não existir qualquer alteração, que em 12% da área se verificou correspondência entre alterações detetadas e as reais, que em 13% da área analisada houve sobrestimação das alterações e que em apenas 5.6% da área analisada existiriam alterações não detetadas.

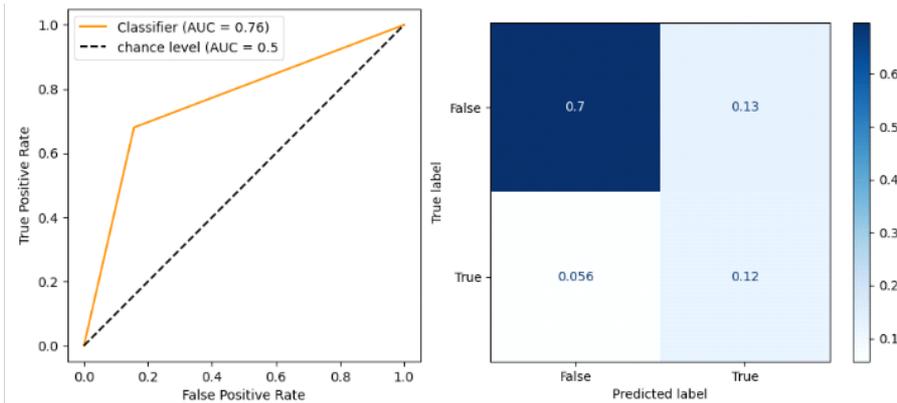


Ilustração 11: Curva ROC (esquerda) e matriz de confusão (direita) – Coimbra

Fonte: Elaboração própria

No gráfico da Ilustração 12 apresenta-se uma comparação dos valores de todas estas métricas relativamente às áreas analisadas. Verifica-se que a metodologia adotada permite obter valores de taxas de desatualização calculados *a priori*, com uma sobrestimação geral média de 10.3%. Por outro lado, a taxa de FN, ou seja, alterações não detetadas, foi inferior a 6% em todos os testes efetuados.

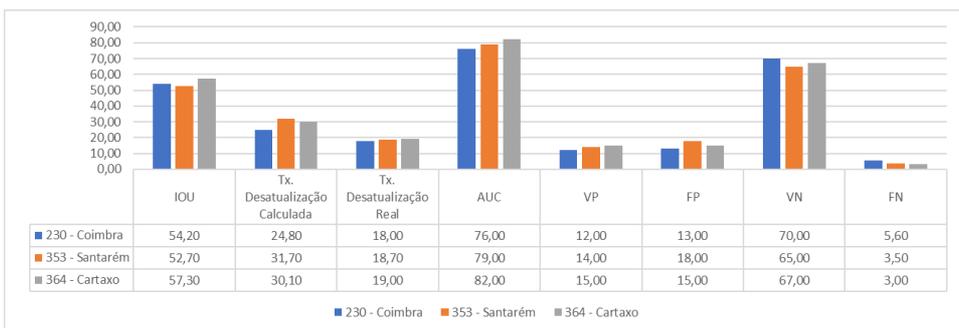


Ilustração 12: Comparação de resultados na fase de Detecção de Alterações

Fonte: Elaboração própria

Na Ilustração 13 é apresentado um exemplo do resultado gráfico, com explicação de produção da máscara de alterações e sua avaliação. É com base nestas máscaras de alterações que os operadores farão a confirmação das alterações e classes envolvidas.

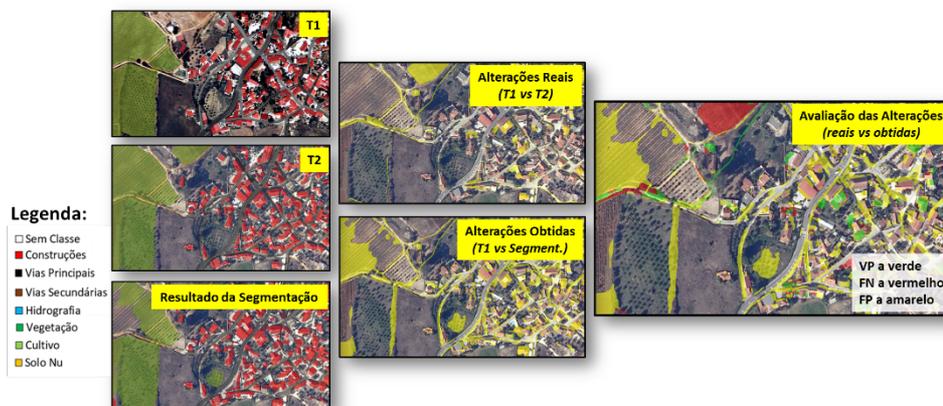


Ilustração 13: Construção e avaliação do mapa de alterações – Santarém

Fonte: Elaboração própria

5. CONCLUSÕES

O desenvolvimento deste projeto teve como objetivo principal a apresentação de uma metodologia de deteção de alterações, para efeitos de atualização cartográfica da Carta Militar de Portugal série M888 à escala 1:25 000, avaliando a taxa de desatualização da área em estudo e georreferenciando os elementos e classes a atualizar.

Na análise efetuada ao longo da introdução verificou-se a utilização generalizada de CNNs em diversas tarefas no âmbito da DR. Existe uma utilização habitual de modelos de DL na segmentação de imagens VHR.

Na descrição dos dados verificou-se que as ortofotos utilizadas são produtos de trabalho, produzidas para apoio da cadeia de produção. Entre edições também se registou a utilização de equipamentos diferentes na aquisição dos dados, bem como a

realização do voo fotogramétrico em estações do ano diferentes. Estas duas características dificultam o isolamento das alterações exclusivas do estado dos objetos, podendo ser minimizadas com atualizações mais frequentes da Carta Militar e planeamento dos voos na mesma época do ano.

Os dados de treino caracterizam-se por serem desequilibrados (representatividade das classes) e heterogéneos (ortofotos com diferentes características), mas a sua disponibilização em grande volume, conjugado com o objetivo de CD com minimização de situações de FN, permitiram a obtenção de bons resultados.

Os resultados de F1 e revocação em todos os testes indicam que as classes de Vias Secundárias e Hidrografia foram as que apresentaram piores resultados na segmentação. Estes relacionam-se com as características dos dados históricos de cartografia: as vias secundárias localizam-se principalmente em zonas de elevada concentração de vegetação, estando em alguns casos ocultas; os cursos de águas e lagoas são de diferentes naturezas embora pertençam à mesma classe, conjugado com a sua reduzida representatividade dificultam a sua separabilidade das restantes classes. Por outro lado, a sua aquisição de acordo com as NAD resulta em diferentes delimitações destes objetos, enviesando os resultados obtidos. Os resultados mais consistentes e elevados surgem nas classes de Construções e Vias Principais.

No que respeita ao método de CD por comparação pós-classificação, também se verificou que as ortofotos enquanto imagens VHR com informação espectral limitada, disponibilizam informação suficiente para obtenção de bons resultados na segmentação semântica por modelos de DL. Pela metodologia adotada verifica-se uma sobrestimação nas áreas de alterações, tal como se verificou nas AE de Coimbra, Santarém e Cartaxo com taxas de FP de 13%, 18% e 15% respetivamente. Estes valores aumentam o trabalho dos especialistas na sua confirmação visual, mas por outro lado

garantem a diminuição de FN (5.6%, 3.5% e 3% respetivamente), contribuindo para a resolução da tarefa estabelecida na formulação do problema de estudo.

Foram obtidos mapas de alterações globais para cada AE. Calcularam-se taxas de desatualização de 24.8%, 31.7% e 30.1%, respetivamente para Coimbra, Santarém e Cartaxo. Com os dados de cartografia atuais foi possível verificar as diferenças para as taxas reais, sendo todas elas de sobrestimação na ordem dos 10%. Este procedimento poderá ser efetuado *a priori* do início da aquisição da informação geográfica, sendo necessária a realização do voo fotogramétrico para produção da ortofoto de T2 e a disponibilidade da BDG de T1 com respetiva ortofoto.

Considerando o exposto anteriormente, foi possível atingir com sucesso o objetivo principal da investigação, ou seja, a apresentação de uma metodologia de CD para efeitos de atualização cartográfica da Carta Militar de Portugal série M888 à escala 1:25 000, permitindo uma avaliação prévia da taxa de desatualização ao nível de uma determinada folha, assim como a georreferenciação dos elementos e classes a atualizar. O objetivo principal foi atingido pela utilização de modelos de DL na segmentação semântica das ortofotos de T2, pelo emprego de uma metodologia de CD pelo método de comparação pós-classificação, alterado pela utilização de dados de cartografia como referência para T1, e pela obtenção dos produtos derivados como os mapas de alteração globais, mapas de alterações editados por classes e taxas de desatualização.

A metodologia implementada torna-se pertinente para apoio à cadeia de produção cartográfica do CIGeoE uma vez que, permite a obtenção antecipada de uma taxa de desatualização e georreferenciação das áreas a avaliar. Tal permitirá priorizar a seleção dos blocos de trabalho pelo critério de desatualização. Também abre a possibilidade de desenvolvimento de novas formas para aquisição de informação geográfica pela reutilização e atualização de BDG existentes.

AUTOR

Tiago Soares Ferreira de Castro é Major de Artilharia, mestre em Engenharia Geoespacial pela Faculdade de Ciências da Universidade de Lisboa (FCUL). É licenciado em Engenharia Geoespacial pela FCUL e em Ciências Militares pela Academia Militar. Este artigo científico resulta de uma adaptação da comunicação científica realizada nas comemorações do 91º aniversário do CIGeoE, tendo sido baseada no projeto de mestrado subordinado ao tema “*Deteção de alterações para efeitos de atualização de cartografia a partir de imagens de alta resolução espacial e dados cartográficos existentes*”, disponível em <http://hdl.handle.net/10451/62551>.

REFERÊNCIAS BIBLIOGRÁFICAS

- Alhedyan, M. A. (2021). CHANGE DETECTION OF LAND USE AND LAND COVER, USING LANDSAT-8 AND SENTINEL-2A.
- Ball, J. E., Anderson, D. T., & Chan, C. S. (2017). Comprehensive survey of deep learning in remote sensing: theories, tools, and challenges for the community. *Journal of Applied Remote Sensing*, 11(04), 1. <https://doi.org/10.1117/1.jrs.11.042609>
- CIGeoE. (2023). Centro de Informação Geoespacial Do Exército. <https://www.igeoe.pt/index.php?id=28>
- Conway, J. (2018). Artificial Intelligence and Machine Learning: Current Applications in Real Estate.
- de Jong, K. L., & Bosman, A. S. (2018). Unsupervised Change Detection in Satellite Images Using Convolutional Neural Networks. <http://arxiv.org/abs/1812.05815>
- Decreto Regulamentar n.º 11/2015. (2015). In Diário da República, 1ª série no148 de 31 de julho de 2015.

- Farida, D. (2021). Change Detection in Satellite Imagery by Combining Algebraic Methods and Convolutional Neural Network.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*.
- Khelifi, L., & Mignotte, M. (2020). Deep Learning for Change Detection in Remote Sensing Images: Comprehensive Review and Meta-Analysis. *IEEE Access*, 8(Cd), 126385–126400. <https://doi.org/10.1109/ACCESS.2020.3008036>
- Majchrowska, S. (2020). Object Detection Algorithms: Starter Pack. <https://neurosys.com/blog/object-detection-algorithms-starter-pack>
- Piralilou, S. T., Shahabi, H., Jarihani, B., Ghorbanzadeh, O., Blaschke, T., Gholamnia, K., Meena, S. R., & Aryal, J. (2019). Landslide detection using multi-scale image segmentation and different machine learning models in the higher himalayas. *Remote Sensing*, 11(21). <https://doi.org/10.3390/rs11212575>
- Radke, R. J., Andra, S., Al-Kofahi, O., & Roysam, B. (2005). Image change detection algorithms: A systematic survey. *IEEE Transactions on Image Processing*, 14(3), 294–307. <https://doi.org/10.1109/TIP.2004.838698>
- Rajaraman, V. (2014). John McCarthy-Father of Artificial Intelligence (Vol. 4).
- Sang, D. V., & Minh, N. D. (2018). Fully residual convolutional neural networks for aerial image segmentation. *ACM International Conference Proceeding Series*, 289–296. <https://doi.org/10.1145/3287921.3287970>
- Shafique, A., Cao, G., Khan, Z., Asad, M., & Aslam, M. (2022). Deep Learning-Based Change Detection in Remote Sensing Images: A Review. *In Remote Sensing (Vol. 14, Issue 4)*. MDPI. <https://doi.org/10.3390/rs14040871>
- Thwal, N. S. (2019). Change Detection of Land Cover in Yangon Using Remote Sensing and Machine Learning.