

DEEP LEARNING E O SENSORIAMENTO REMOTO DE ÁREAS VERDES URBANAS: UMA ANÁLISE DA EVOLUÇÃO E APLICAÇÕES

Rita Maria Cupertino Bastos^{1,a}

Guilherme Fenelon de Sena Machado^{2,a}

Carla Bernadete Madureira Cruz^{3,a}

RESUMO

O presente trabalho analisa a aplicação do *Deep Learning* (DL) no sensoriamento remoto de áreas verdes urbanas, destacando sua evolução e potencialidades. O DL, uma sub-área da inteligência artificial, oferece soluções para o monitoramento rápido e preciso de fenômenos na superfície terrestre, superando limitações de custo e acesso de metodologias tradicionais. A pesquisa revisa a literatura sobre a origem e aplicações do DL, com foco em sensoriamento remoto, e investiga especificamente seu uso em áreas verdes intraurbanas. Os resultados mostram um crescimento exponencial de publicações sobre DL em sensoriamento remoto desde 2014, com a China liderando a produção acadêmica. No contexto das áreas verdes urbanas, as primeiras publicações surgiram em 2016, com um aumento gradual de estudos focados diretamente no tema a partir de 2018. Apesar de ser uma técnica recente, o DL demonstra resultados satisfatórios, utilizando dados como *LiDAR* e imagens de altíssima resolução espacial. As aplicações mais comuns incluem a identificação de indivíduos arbóreos, classificação da vegetação e detecção de mudanças. A segmentação e diferenciação de alvos urbanos é complexa devido às similaridades espectrais, tornando o DL fundamental para o mapeamento e monitoramento das dinâmicas urbanas. O estudo ressalta a necessidade de ressignificar o conceito de áreas verdes urbanas para incluir espaços privados e incentivar a agricultura familiar urbana e os "telhados verdes". Conclui-se que o DL oferece potencialidades significativas para o mapeamento e monitoramento da vegetação,

Artigo resultado de pesquisa de pesquisa e financiada pela Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ);

¹ritamcuper@ufrj.br; ²guilherme.fenelon@hotmail.com; ³carlamad@gmail.com; ^aLaboratório Espaço de Sensoriamento Remoto e Estudos Ambientais, Universidade Federal do Rio de Janeiro.

auxiliando na gestão e planejamento ambiental, e merece aprofundamento devido à sua capacidade de extrair informações relevantes com alta exatidão.

Palavras-chave: Redes neurais convolucionais; verde urbano; áreas verdes; intraurbano.

ABSTRACT

The present work analyzes the application of Deep Learning (DL) in the remote sensing of urban green areas, highlighting its evolution and potential. DL, a sub-area of artificial intelligence, offers solutions for the rapid and precise monitoring of phenomena on the Earth's surface, overcoming cost and access limitations of traditional methodologies. The research reviews the literature on the origin and applications of DL, with a focus on remote sensing, and specifically investigates its use in intra-urban green areas. The results show an exponential growth of publications on DL in remote sensing since 2014, with China leading academic production. In the context of urban green areas, the first publications appeared in 2016, with a gradual increase in studies focused directly on the topic from 2018. Despite being a recent technique, DL demonstrates satisfactory results, using data such as LiDAR and very high spatial resolution images. The most common applications include the identification of individual trees, vegetation classification, and change detection. The segmentation and differentiation of urban targets is complex due to spectral similarities, making DL fundamental for mapping and monitoring urban dynamics. The study highlights the need to redefine the concept of urban green areas to include private spaces and encourage urban family farming and "green roofs." It is concluded that DL offers significant potential for the mapping and monitoring of vegetation, assisting in environmental management and planning, and deserves further study due to its ability to extract relevant information with high accuracy.

Keywords: Convolutional neural networks; urban green; green areas; intra-urban.

INTRODUÇÃO

O *Deep Learning* é uma sub-área da inteligência artificial que consiste no aprendizado profundo e possui aplicações em diversas áreas, tais como: medicina, análise de discursos, reconhecimento facial e, também, nos estudos referentes ao espaço urbano. As cidades constituem um dos recortes temáticos mais complexos a serem trabalhados tendo em vista seu elevado grau de heterogeneidade ao abarcar elementos sociais, econômicos, biológicos e

físicos, interagindo integradamente em múltiplas escalas (BLASCHKE, 2011). Esse caráter heterogêneo faz parte do espaço urbano capitalista que pode ser compreendido enquanto “conjunto de usos de terra justapostos entre si” (CORRÊA, 1989) no qual esses fragmentos de usos da terra compõem um mosaico urbano fragmentado e articulado.

No Brasil, até 2050, cerca de 92,4% da população estará concentrada nas cidades (ONU, 2022) e, sendo assim, há urgência no planejamento e gestão visando a adaptação, resiliência e continuidade do desenvolvimento socioeconômico das cidades a nível global (WORLD BANK, 2013). Ao pensar na organização territorial das cidades, é necessário um olhar atento aos espaços verdes intraurbanos. A cobertura vegetal apresenta alto grau de importância no desenvolvimento urbano (NUCCI, 2001) desempenhando importante papel estético, ecológico e de lazer, apesar de terem sido historicamente negligenciados (BARGOS E MATIAS, 2011). A valorização e o monitoramento dessas áreas são essenciais para garantir a saúde ambiental e o bem-estar da população urbana.

No exercício de se pensar as áreas verdes intraurbanas como entidade concreta do fenômeno espacial urbano, podemos caracterizá-las conforme sua espacialidade e os elementos inerentes a qualquer geoinformação. Essa perspectiva auxilia nas tomadas de decisões (BATISTELLA E MORAN, 2008) e é importante para compreensão dos fundamentos epistemológicos e metodologias adequadas para sua aplicação (RODRIGUEZ, 2015). Nesse sentido, é essencial o desenvolvimento de estudos que abordem a temática das áreas verdes intraurbanas visando contribuir com um planejamento urbano-ambiental mais eficaz e mapeamentos que possibilitem identificar essas áreas, bem como metodologias que abarquem o contexto de monitoramento do verde intraurbano de forma otimizada. A integração de tecnologias avançadas, como o sensoriamento remoto e o *Deep Learning*, pode potencializar a precisão, a velocidade e a eficiência desses estudos, fornecendo dados cruciais para a gestão urbana-ambiental.

De acordo com Costa e Colesanti (2011), os problemas urbanos atuais como enchentes, poluição sonora, do ar e das águas representam sérios riscos à saúde física e mental da população. Com isso, diversos estudos têm sido realizados sobre as áreas verdes nas cidades. A conceituação referente à vegetação presente no espaço urbano não possui um conceito propriamente formado e definido. Com isso, muitos trabalhos utilizam conceitos como áreas

verdes, cobertura vegetal, arborização urbana, espaços livres, verde urbano, entre outros, como sinônimos apesar de serem conceitos distintos (LIMA et al., 1994; LONDE E MENDES, 2023).

Diversos autores apontam a função de lazer e estética associada às áreas verdes. Contudo, esses espaços possuem uma diversidade de funções em diferentes perspectivas como ecológico, biológico, social e econômica (Figura 1). De acordo com Loboda e De Angelis (2005), os espaços verdes nas cidades desempenham funções a partir das demandas culturais das sociedades.

Organograma dos Principais Benefícios das Áreas Verdes Urbanas				
Fatores Urbanos		Principais Formas de Degradação		Principais Benefícios das Áreas Verdes Urbanas
Físico	Clima/ar	Alterações micro-climáticas.	Deterioração da qualidade do ar Poluição Sonora.	Conforto micro-climático. Controle da poluição atmosférica Controle da poluição sonora.
	Água	Alterações da quantidade de água.	Deterioração da qualidade hídrica.	Regularização hídrica Controle da poluição hídrica.
	Solo/subsolo	Alterações físicas do solo.	Alterações químicas e biológicas do solo.	Estabilidade do solo Controle da poluição edáfica.
Biológico	Flora	Redução da cobertura vegetal.	Redução da biodiversidade.	Controle da redução da biodiversidade.
	Fauna	Proliferação de vetores.	Destruição de habitats naturais.	Controle de vetores.
Territorial	Uso/ocupação do solo	Desconforto ambiental das edificações. Poluição visual.	Alterações micro climáticas.	Conforto ambiental nas edificações. Controle da poluição visual.
	Infra-estrutural/serviços	Dificuldades no deslocamento. Aumento da necessidade de saneamento. Redução da sociabilidade	Desperdício de energia.	Racionalização do transporte. Saneamento ambiental. Conservação de energia.
Social	Demografia Equipamentos e serviços sociais.	Concentração populacional.	Crescimento das necessidades sociais.	Conscientização ambiental. Atendimento das necessidades sociais.
Econômico	Setores produtivos Renda/Ocupação	Valor e desvalorização da atividade/propriedade Concentração de pobreza e desemprego.	x	Valorização das atividades e propriedades
Instituição	Setor Público. Instrumentos Normativos.	Redução da capacidade de gestão urbana. Instrumental insuficiente.	x	Apoio à capacidade de gestão urbana. Instrumento de regulamentação específica.

Figura 1: Organograma dos principais benefícios das áreas verdes urbanas. Fonte: Adaptado de Fundação Cide 2004 apud Ferreira (2005).

Miguez (2001) aponta a precariedade no mapeamento sistematizado de áreas verdes urbanas no Brasil tendo por consequência a complexidade de obtenção de uma malha cartográfica atualizada e confiável. Nesse contexto, a análise espacial da cobertura vegetal urbana consiste em suporte na tomada de decisões, estipulação de legislações ambientais e organização de sistemas de manejo, uma vez que permitem um monitoramento sistemático (MILANO, 1995). Assim, as geotecnologias permitem o monitoramento das áreas verdes urbanas com redução de esforços, maximizando resultados e proporcionando uma visão ampla cujos objetos se encontram classificados e quantificados (HORTA, 2015). Além disso, o uso de geotecnologias permite a geração de indicadores de qualidade ambiental pautados no mapeamento das áreas verdes (ÁVILA, 2011), a mitigação de problemas ambientais urbanos mediante avaliação e manejo adequado (HORTA, 2015) e tomadas de decisão em projetos de cunho integrativo (BATISTELLA E MORAN, 2008).

Com o aumento da produção de dados de observação terrestre e o desenvolvimento cada vez mais rápido de diversas atividades há necessidade de monitoramento de fenômenos que ocorrem na superfície de forma mais rápida e precisa. As soluções metodológicas para se trabalhar com nível de detalhamento visando monitoramento frequentemente apresentam valor econômico custoso e de difícil acesso, limitando a capacidade de respostas às mudanças de forma rápida. Surge a demanda por uma solução metodológica que possibilite agilizar o mapeamento com exatidão e permitindo o acompanhamento das dinâmicas o mais próximo possível do tempo real. Nesse contexto, a inserção do *Deep Learning* no tratamento de dados, extração de informações e classificação de dados de sensoriamento remoto preenche esses requisitos e apresenta resultados satisfatórios. Com isso, o objetivo deste trabalho é analisar a utilização de *Deep Learning* aplicado ao sensoriamento remoto e em estudos de áreas verdes intraurbanas e compreender suas aplicações e potencialidades na delimitação de feições em imagens de satélite, na identificação de padrões e na geração de mapeamentos.

METODOLOGIA

As principais etapas metodológicas desta pesquisa estão dispostas conforme a Figura 2 a seguir.

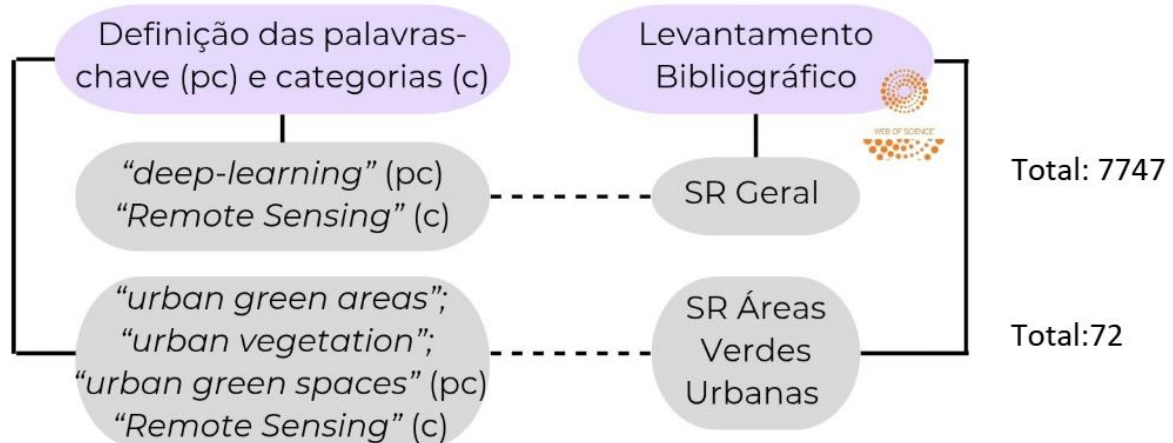


Figura 2: Fluxograma metodológico.

A primeira etapa consistiu na revisão da literatura voltada à origem, à trajetória evolutiva e as aplicações do *Deep Learning*. Posteriormente, realizou-se uma investigação bibliográfica direcionada especificamente à aplicação de técnicas de *Deep Learning* no campo do sensoriamento remoto na plataforma *Web of Science* utilizando “*deep-learning*” como palavra chave e “*Remote Sensing*” como categoria de principal área de estudo. Até o final do ano de 2022 foram encontrados 7.747 artigos em revista, *reviews*, trabalhos completos e resumos expandidos.

Em seguida, uma busca mais refinada do *Deep Learning* no sensoriamento remoto de áreas verdes intraurbanas resultou na obtenção de 72 trabalhos. A organização tabular das publicações foi feita por meio do *software Excel*, considerando variáveis como temática abordada, ano de publicação, tipo de segmentação, país de desenvolvimento da pesquisa, sensor orbital utilizado, resolução espacial das imagens e algoritmos empregados. A partir dessa base, foi realizada a análise dos dados e a construção de gráficos utilizando os *softwares Excel* e *Power BI*.

RESULTADOS E DISCUSSÃO

Os primeiros trabalhos de DL em sensoriamento remoto surgiram em 2014: dois resumos expandidos utilizando algoritmos de DL em classificações utilizando hiperespectral (ÖZDEMİR et al., 2014; ROMERO et al., 2014); dois trabalhos completos utilizando DL na

extração e classificação de dados de radar (LV et al., 2014; XIE et al., 2014); e um artigo completo (CHEN et al., 2014) propondo uma nova forma de classificação de imagens digitais de sensores hiperespectrais combinando regressão logística, análise de componentes principais (PCA) e o algoritmo de *Deep Learning* SAE-LR, resultando em uma maior precisão na classificação (Figura 3).




Figura 3: Gráfico de número de publicações por ano de *Deep Learning* aplicado ao Sensoriamento Remoto. Elaboração: A autora. Fonte: *Web of Science*.

Em menos de uma década a publicação de trabalhos da área de sensoriamento remoto utilizando algoritmos aumentou exponencialmente e a tendência é continuar aumentando. Contudo, a produção desse conhecimento ainda é muito restrita espacialmente e destaca-se a produção acadêmica da China muito superior em comparação aos demais países, demonstrando um interesse espacialmente localizado nas pesquisas, seguida dos Estados Unidos, Alemanha, França e Canadá (Figura 4).




Figura 4: Gráfico de número de publicações de *Deep Learning* aplicado ao Sensoriamento Remoto pelos 10 principais países filiados dos autores. Elaboração: A autora. Fonte: *Web of Science*.

As principais expressões associadas aos trabalhos analisados (Figura 5) aponta um predomínio de uso no “NDVI” (*Normalized Difference Vegetation Index*), utilizado para classificação de áreas de vegetação, indicando uma possível predominância dos trabalhos sobre vegetação em alguma instância. Além disso, é possível compreender os tipos e algumas características dos produtos de sensoriamento remoto utilizados nos estudos, como por exemplo o uso de imagens de radar, dados *LiDAR* e altíssima resolução espacial. Técnicas como a fusão de imagens e a transformada fracional de Fourier também aparecem como principais associadas aos trabalhos, indicando a possibilidade do emprego dessas técnicas nas etapas metodológicas dos trabalhos analisados.




Figura 5: Principais expressões citadas no acumulado total de artigos de uso de *Deep Learning* aplicado ao Sensoriamento Remoto. Elaboração: A autora. Fonte: *Web of Science*.

As primeiras publicação de DL no estudo de áreas verdes urbanas data de 2016 (Figura 6) e consiste em um trabalho completo no qual Yao et al. (2016) utilizaram redes neurais convolucionais na segmentação semântica de dados *LiDAR* para a classificação de objetos urbanos incluindo vegetação, entretanto, o objetivo do trabalho não consistia nas áreas verdes intraurbanas. Posterior a esse trabalho, em 2018 foi publicado o primeiro artigo que, de fato, tinha como objetivo a classificação do verde intraurbano. Griffith e Hay (2018) combinaram a classificação GEOBIA e DL para mapear vegetação urbana em telhados e obteve 88.5% de acurácia. No que tange às áreas de cobertura verde intraurbana, é possível observar o crescimento em menor escala do uso de técnicas de DL, destacando a China na pesquisa e produção de artigos (Figura 7).




Figura 6: Gráfico de número de publicações por ano de *Deep Learning* aplicado ao Sensoriamento Remoto de áreas verdes intraurbanas. Elaboração: A autora. Fonte: *Web of Science*.




Figura 7: Gráfico de número de publicações de *Deep Learning* aplicado ao Sensoriamento Remoto de áreas verdes intraurbanas pelos 10 principais países. Elaboração: A autora. Fonte: *Web of Science*.

Apesar de ser uma técnica inovadora e recente, os estudos com uso de DL demonstram resultados satisfatórios. Constatou-se que os dados mais utilizados consistem no *LiDAR* e

imagens de altíssima resolução espacial, podendo alcançar 0.3m (METZLER et al., 2023). A segmentação semântica é a mais utilizada, seguida da combinação entre segmentação semântica e segmentação de instância. As aplicações mais comuns foram a identificação de indivíduos arbóreos no geral, classificação da vegetação, identificação de espécies e detecção de mudanças. Vale ressaltar que dentre essa totalidade de trabalhos a maior parte apenas tangencia o tema, sendo poucos com foco diretamente nas áreas verdes urbanas

A segmentação e diferenciação dos alvos do meio urbano é complexa tendo em vista as similaridades de respostas espectrais dos mesmos. Por isso, o desenvolvimento de metodologias automatizadas como o DL é fundamental para o mapeamento e monitoramento das dinâmicas urbanas. É necessário ressignificar o conceito de áreas verdes urbanas para abranger o espaço privado, incluindo o âmbito residencial. A inserção da agricultura familiar urbana e os chamados “telhados verdes” são formas de vegetação intraurbana que devem ser incentivadas pela esfera pública visando ampliar as áreas verdes na cidade. O Piloto Floresta Urbana Horta (2015) é um exemplo de prática inovadora. Ao pensar no contexto das mudanças climáticas, tais medidas são fundamentais.

CONSIDERAÇÕES FINAIS

Atualmente, os mapeamentos não possuem mais um foco no objeto em si, mas sim nos eventos e dinâmicas referentes ao objeto. Há uma emergência de técnicas que possibilitem o monitoramento dos fenômenos no período temporal mais curto possível. O mapeamento de vegetação tem almejado o avanço na velocidade do processo, visando mapear as dinâmicas dessa vegetação visando o monitoramento das dinâmicas que essas áreas sofrem e, assim, auxiliar na gestão e planejamento ambiental.

Como o nosso cérebro, a DL busca definir modelos de reconhecimento baseados em um extenso treinamento, sendo este um dos maiores desafios de todo o processo. O principal aporte do uso destas metodologias em sensoriamento remoto, envolve a possibilidade de não só mapear, mas também trazer informações relevantes extraídas diretamente sobre as imagens e com um nível de exatidão promissor. Considerando a velocidade e emergência das demandas por informações atualizadas e precisas, a DL oferece potencialidades significativas no atendimento a muitas questões, merecendo um aprofundamento das mesmas.

REFERÊNCIAS

- ÁVILA, Marcelo Rodrigues de. **O uso do geoprocessamento para mapear as áreas verdes urbanas como indicador de qualidade ambiental no município de Americana/SP**. 2011.
- BARGOS, Danúbia Caporusso; MATIAS, Lindon Fonseca. Áreas verdes urbanas: um estudo de revisão e proposta conceitual. **Revista da Sociedade Brasileira de Arborização Urbana**, v. 6, n. 3, p. 172-188, 2011.
- BATISTELLA, Mateus; MORAN, Emilio F. **Geoinformação e monitoramento ambiental na América Latina**. Senac, 2008.
- BLASCHKE, T. et al. Collective sensing: Integrating geospatial technologies to understand urban systems—An overview. **Remote Sensing**, v. 3, n. 8, p. 1743-1776, 2011.
- CHEN, Yushi et al. Deep learning-based classification of hyperspectral data. **IEEE Journal of Selected topics in applied earth observations and remote sensing**, v. 7, n. 6, p. 2094-2107, 2014.
- CORRÊA, R. L. **O Espaço Urbano**. São Paulo, Ática, 1989.
- COSTA, R. G. S.; COLESANTI, M. M. **The contribution of environmental perception to studies of green areas**. *RA'E GA-Geographic Space in Analysis*, p. 238-251, 2011.
- GRIFFITH, David C.; HAY, Geoffrey J. Integrating GEOBIA, machine learning, and volunteered geographic information to map vegetation over rooftops. **ISPRS International Journal of Geo-Information**, v. 7, n. 12, p. 462, 2018.
- HORTA, Isabela Taici Lopes Gonçalves. **O uso de geotecnologias para mapeamento de áreas verdes urbanas e análise da percepção ambiental no município de São Paulo**. 2015.
- LIMA, Ana Maria Liner Pereira et al. **Problemas de utilização na conceituação de termos como espaços livres, áreas verdes e correlatos**. Anais, 1994.
- LOBODA, Carlos Roberto; DE ANGELIS, Bruno Luiz Domingues. **Áreas verdes públicas urbanas: conceitos, usos e funções**. *Ambiência*, v. 1, n. 1, p. 125-139, 2005.
- LONDE, P. R.; MENDES, P. C. **A INFLUÊNCIA DAS ÁREAS VERDES NA QUALIDADE DE VIDA URBANA**. *Hygeia - Revista Brasileira de Geografia Médica e da Saúde*, Uberlândia, v. 10, n. 18, p. 264–272, 2014. DOI: 10.14393/Hygeia1026487. Disponível em: <https://seer.ufu.br/index.php/hygeia/article/view/26487>. Acesso em: 29 set. 2023.
- LV, Qi et al. Classification of land cover based on deep belief networks using polarimetric RADARSAT-2 data. In: **2014 IEEE Geoscience and Remote Sensing Symposium**. IEEE, 2014. p. 4679-4682.

METZLER, A. Barbara et al. Phenotyping urban built and natural environments with high-resolution satellite images and unsupervised deep learning. **Science of The Total Environment**, p. 164794, 2023.

MIGUEZ, LUIS ALBERTO LOPEZ. **Mapeamento e monitoramento dos maciços vegetais do município de Curitiba-PR**. Monografia do curso de Especialização em Administração, Monitoramento e Controle de Qualidade de Vida Urbana, Curitiba: Faculdade de Administração e Economia do Paraná, Instituto de Engenharia do Paraná, 2001.

MILANO, Miguel Serediuk. Arborização Urbana. In: **Curso Sobre Arborização Urbana Curitiba**, 1995. Universidade Livre do Meio Ambiente. P. 7-49.

NUCCI, João Carlos. **Qualidade ambiental e adensamento urbano: um estudo da ecologia e do planejamento urbano aplicado ao distrito de Santa Cecília**. Humanitas/USP, São Paulo, 2001.

ONU - HABITAT. **População mundial será 68% urbana até 2050**. Disponível em <<https://brasil.un.org/pt-br/188520-onu-habitat-populacao-mundial-sera-68-urbana-ate-2050>>.

ÖZDEMİR, A. Okan Bilge; GEDIK, B. Ekin; ÇETIN, C. Yasemin Yardımcı. **Hyperspectral classification using stacked autoencoders with deep learning**. In: 2014 6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). IEEE, 2014. p. 1-4.

RODRIGUEZ, J. M. M. **Teoría y Metodología de la Geografía**. Editorial Universitaria Félix Varela, La Habana, v. 363, 2015.

ROMERO, Adriana; GATTA, Carlo; CAMPS-VALLS, Gustavo. **Unsupervised deep feature extraction of hyperspectral images**. In: 2014 6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). IEEE, 2014. p. 1-4.

WORLD BANK. World Development Report 2014: **Risk and Opportunity — Managing Risk for Development**. Washington, DC, pp. 363, 2013.

XIE, Huiming et al. Multilayer feature learning for polarimetric synthetic radar data classification. In: 2014 **IEEE Geoscience and Remote Sensing Symposium**. IEEE, 2014. p. 2818-2821.

YAO, Wei; POLESWKI, P.; KRZYSZEK, P. **Classification of urban aerial data based on pixel labelling with deep convolutional neural networks and logistic regression**. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. 41, p. 405-410, 2016.