



Exploring Urban Densification with Deep Learning: Integrating Remote Sensing and Electrical Infrastructure Data

Álisson de Oliveira Alves, Luisa Christina de Souza,
Luiz Eduardo Nunes Cho Luck,
Raniere Rodrigues Melo de Lima,
Carlos Augusto Teixeira de Moura,
Wesley José dos Santos Marinho,
Rafael de Medeiros Mariz Capuano,
Bruno Cesar Pereira da Costa, Marina de Siqueira,
Arthur Diniz Flor Torquato Fernandes,
Jesaias Carvalho Pereira Silva and Pablo Javier Alsina

EasyChair preprints are intended for rapid dissemination of research results and are integrated with the rest of EasyChair.

January 6, 2025

Explorando o adensamento urbano com *deep learning*: Integrando sensoriamento remoto e dados de infraestrutura elétrica

Álisson de Oliveira Alves* ** Luisa Christina de Souza* **
Luiz Eduardo Nunes Cho Luck** Raniere Rodrigues Melo de Lima**
Carlos Augusto Teixeira** Wesley José dos Santos Marinho**
Rafael de Medeiros Mariz Capuano** Bruno Cesar Pereira da Costa**
Marina de Siqueira** Arthur Diniz Flor Torquato Fernandes***
Jesaias Carvalho Pereira Silva** Pablo Javier Alsina*

* Departamento de Engenharia de Computação e Automação,
Universidade Federal do Rio Grande do Norte, Natal, Brasil

** Instituto SENAI de Inovação em Energias Renováveis, Natal, Brasil

*** Departamento de Engenharia Industrial, Universidade de Nápoles
Federico II, Nápoles, Itália

Abstract: Rapid urban growth poses challenges for efficient city management, demanding the implementation of sustainable principles. In this scenario, the electrical sector faces significant changes with the introduction of new technologies, notably Artificial Intelligence (AI) and Deep Learning (DL), especially when applied to urban remote sensing. This study investigates the urban growth of a Brazilian state using semantic segmentation based on Convolutional Neural Networks (CNNs) in satellite images. Two CNN architectures, LinkNet34 and DLinkNet34, were trained with RGB satellite images from Google Earth, covering geographical and environmental diversity. Both models showed similar performance, with LinkNet34 slightly superior with an accuracy of 0.8457. Segmentation analysis was correlated with data from the Geographic Database of the Distributor's Infrastructure (BDGD), aiming to provide insights for sustainable urban development.

Resumo: O crescimento urbano acelerado apresenta desafios para uma gestão eficiente das cidades, exigindo a implementação de princípios sustentáveis. Neste cenário, o setor elétrico enfrenta mudanças significativas com a introdução de novas tecnologias, com destaque para a Inteligência Artificial (IA) e o Aprendizado Profundo (Deep Learning - DL), que são especialmente aplicados ao sensoriamento remoto urbano. Este estudo investiga o crescimento urbano de Minas Gerais usando segmentação semântica baseada em Redes Neurais Convolucionais (CNNs) em imagens de satélite. Duas arquiteturas CNN, LinkNet34 e DLinkNet34, foram treinadas com imagens RGB de satélites do Google Earth, abrangendo diversidade geográfica e ambiental. Ambos os modelos mostraram desempenho semelhante, com a LinkNet34 ligeiramente superior com acurácia de 0.8457. A análise da segmentação foi correlacionada com dados da infraestrutura elétrica da Base de Dados Geográfica da Distribuidora (BDGD), com o objetivo de oferecer insights para o desenvolvimento urbano sustentável.

Keywords: Convolutional Neural Networks, Remote sensing, Urban Densification, Semantic Segmentation, Electrical Infrastructure.

Palavras-chaves: Redes Neurais Convolucionais, Sensoriamento Remoto, Adensamento Urbano, Segmentação Semântica, Infraestrutura Elétrica.

1. INTRODUÇÃO

O desenvolvimento urbano acelerado, marcado por congestionamentos, altas densidades construtivas e poluição, impõe desafios significativos para a gestão eficiente dos recursos e infraestrutura das cidades, exigindo a implementação de princípios sustentáveis (Oliveira, 2024). A escolha de locais para ocupação urbana está estreitamente relacionada às características da superfície, como localização geográfica vantajosa, disponibilidade de recursos naturais, fertilidade do solo e defensabilidade (Nissinen, 2024).

As mudanças no uso e cobertura do solo “*Land Use and Land Cover*” (LULC), juntamente com o aumento das áreas construídas, exercem influência direta na qualidade de vida da população (Fontana et al., 2023). A expansão urbana desordenada não apenas resulta em uma desigualdade entre o crescimento e o desenvolvimento urbanos, mas também expõe fragilidades frequentemente subestimadas em análises teóricas (Dias et al., 2024). Como, por exemplo, a geração de sobrecarga da infraestrutura elétrica, o que por sua vez ocasiona a cortes e uso ineficiente de energia. Além disso, o aumento da demanda de eletricidade

devido à expansão não planejada pode causar danos ao meio ambiente, caso seja gerada a partir de combustíveis fósseis. Portanto, abordar essa discrepância é crucial para a promoção de uma urbanização e um planejamento energético sustentável (Nathaniel and Bekun, 2021).

Neste contexto, o setor elétrico enfrenta uma era marcada por transformações significativas impulsionadas pela adoção de novas tecnologias de comunicação, sensoriamento, cibersegurança e monitoramento de ativos (Lins and Rodrigues, 2023). Sendo assim, a crescente relevância de técnicas como Inteligência Artificial (IA) e *Machine Learning* (ML) tem sido amplamente destacada, principalmente pelo surgimento do aprendizado profundo - *Deep Learning* (DL). Este emerge como uma abordagem inovadora e promissora, especialmente no contexto do sensoriamento remoto aplicado em análises urbanas (Bastos et al., 2023).

Ao incorporar algoritmos avançados de IA e ML na análise de dados em larga escala e no monitoramento em tempo real, essas tecnologias oferecem percepções valiosas para compreender e otimizar não apenas o mapeamento urbano (Sirko et al., 2021), mas também para aprimorar a eficiência energética e otimizar a gestão de ativos no setor de energia elétrica (Lourenço and da Silva Filho, 2023). Dessa maneira, entender as mudanças regionais e temporais no uso e cobertura do solo (LULC) não é apenas uma preocupação para cientistas, legisladores e planejadores urbanos (Fontana et al., 2023), mas também para empresas do setor elétrico (Cucco and de Oliveira, 2011).

Dentro do campo do *deep learning*, a segmentação semântica se destaca como uma técnica crucial para a análise detalhada de imagens, permitindo a classificação pixel a pixel de diversos elementos em uma cena. Utilizando redes neurais convolucionais (CNNs), esta abordagem não só aprimora a precisão na interpretação de imagens, mas também oferece uma eficiência computacional superior em comparação com métodos tradicionais (Neupane et al., 2021). Com sua aplicação, é possível atribuir uma classe específica a cada pixel, como estradas, edifícios, vegetação e corpos d'água, fornecendo uma análise extremamente detalhada e útil para diversas aplicações.

A integração dessas tecnologias de IA e ML, especialmente as CNNs aplicadas à segmentação semântica, tem desempenhado um papel crucial na análise detalhada do uso e cobertura do solo (Sirko et al., 2021). Ao identificar e classificar cada pixel de uma imagem—seja uma estrada (Zhou et al., 2018), um edifício (Li et al., 2019) ou áreas de vegetação—os especialistas podem obter uma compreensão mais profunda e atualizada das dinâmicas urbanas e naturais. Essa capacidade de detecção e classificação fina apoia a tomada de decisão estratégica nas empresas de energia elétrica, onde a precisão na informação sobre a localização e a extensão de diferentes tipos de cobertura do solo pode influenciar diretamente a gestão de ativos e o planejamento da infraestrutura. Portanto, a eficácia das CNNs em segmentação semântica não apenas eleva o padrão em termos de mapeamento e monitoramento, como também serve de ponte vital entre o conhecimento geoespacial e as necessidades operacionais e estratégicas das indústrias energéticas.

Este estudo investiga o crescimento urbano de Minas Gerais, Brasil, através da análise de imagens de satélite

utilizando técnicas de segmentação semântica baseadas em CNNs, com o objetivo de demonstrar como essas técnicas avançadas podem ser aplicadas para determinar padrões de crescimento urbano e suas implicações para o planejamento e gestão urbana. Para tanto, foram comparadas duas arquiteturas CNN diferentes e foram avaliadas as suas performances na detecção de ocupação de solo. Por fim, busca-se entender a densificação urbana ao correlacionar os resultados da segmentação com dados da infraestrutura elétrica da Base de Dados Geográfica da Distribuidora (BDGD), oferecendo informações que contribuam para o desenvolvimento urbano sustentável, baseadas em análises quantitativas.

2. METODOLOGIA

Esta seção metodológica descreve o procedimento adotado para a observação do crescimento urbano, por meio da aplicação de técnicas de DL em imagens de satélite para segmentar áreas de ocupação do solo. A Figura 1 descreve as atividades realizadas no presente trabalho.

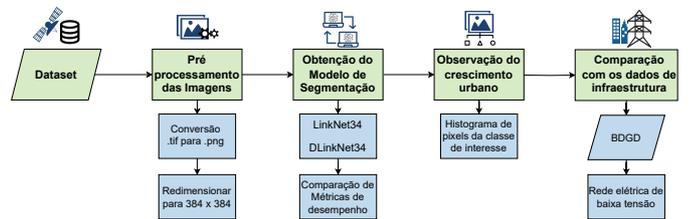


Figura 1. Fluxograma de atividades para obtenção da segmentação de imagens de satélite.

Inicialmente, foram adotadas etapas para a aquisição e pré-processamento das imagens de satélite e das máscaras binárias. Em seguida, foi realizado um treinamento dos algoritmos de segmentação de imagens, utilizando conjuntos de dados rotulados, a fim de permitir a segmentação automática das áreas urbanas. Por fim, foram exibidas quais informações do BDGD serão pertinentes para a análise do adensamento urbano.

2.1 Conjunto de dados de imagens de satélite

Com o objetivo de identificar diferenças no uso e ocupação do solo entre os anos de 2019 e 2023, foi realizada a obtenção de imagens do *Google Earth*. Adotou-se uma abordagem metodológica sistemática, com auxílio do software QGIS (Moyroud and Portet, 2018), para georreferenciar as imagens e definir os parâmetros de interesse, como a área geográfica específica e as datas relevantes para a aquisição das imagens. O georreferenciamento possibilitou o download de cenas provenientes do Estado de Minas Gerais através do *Google Earth Pro* (Ganjirad and Bagheri, 2024).

No total, foram geradas 5 imagens no formato *Tagged Image File Format* (tiff) com dimensões de 8192×3059 pixels e resolução espacial de aproximadamente 60 cm por pixel. Estas foram obtidas por meio de diferentes sensores satelitais utilizados pelo *Google Earth*, como o *Pleiades* (com resolução aproximada de 50 cm por pixel) e o *Quickbird* (com resolução de 60 cm por pixel). A Figura 2 exemplifica uma cena do conjunto de dados com dimensão original de 8192×3059 pixels.



Figura 2. Exemplo de imagem satelital presente no conjunto de dados extraído do Google Earth.

Utilizando a georreferência das imagens de satélite obtidas previamente, foram geradas as máscaras binárias (*ground-truth*) necessárias para o treinamento do algoritmo de segmentação, por meio do *Open Buildings V3 Polygons* (Sirko et al., 2021). Esse serviço oferece um extenso conjunto de dados abertos contendo contornos de edifícios derivados de imagens de satélite de alta resolução. Dessa forma, cada imagem de satélite original em RGB possui uma máscara binária associada, na qual, cada pixel apresenta sua correspondência da classe “ocupação de solo” ou “*background*”.

Como requisito das arquiteturas de DL selecionadas para este estudo, as imagens de satélite devem apresentar o formato *Portable Network Graphics* (png), com *patches* de dimensão 384×384 pixels. Portanto, como exposto na Figura 1, foram realizados os pré-processamentos necessários nos pares de imagens RGB e *groundtruth*, antes do treinamento da rede neural, gerando cerca de 700 pares de imagens. Porém, observando a existência de dados que não apresentavam nenhum pixel com a classe “ocupação de solo”, e sabendo que esse desbalanceamento dos dados pode afetar o aprendizado do modelo (Huyen, 2022), foi implementado um *script* que aplica a técnica de *undersampling* para eliminar os pares onde as máscaras binárias apresentavam menos de 10% dos pixels da classe “ocupação de solo”. Ao final, restaram 501 arquivos para o treinamento e validação do algoritmo. Na Figura 3 pode ser observado um exemplo de par de *groundtruth* e *masks* que foi utilizado no processo de treinamento.



(a) Imagem RGB.

(b) Máscara Binária.

Figura 3. Par de imagens de exemplo de uma região do Brasil contendo um recorte de uma imagem de satélite em sua composição original (RGB) com sua respectiva máscara obtida através do *Open Buildings V3 Polygons*.

2.2 Algoritmos de segmentação de imagens: Arquiteturas e características básicas

Na presente aplicação, foram utilizados dois algoritmos de segmentação semântica, que trata-se de uma técnica que

divide uma imagem em regiões semanticamente significativas, realizando a rotulação de cada pixel da imagem em sua respectiva classe.

A primeira rede neural de segmentação semântica utilizada foi a *LinkNet34* (Chaurasia and Culurciello, 2017), que utiliza a *ResNet34* pré-treinada no conjunto de dados *ImageNet* como seu codificador. Sua arquitetura é composta por uma série de blocos de codificação (*encoder*) para decompor a imagem, seguidos por blocos de decodificação (*decoder*) responsáveis pela reconstrução da imagem. Além disso, utiliza *batch normalization* entre as camadas convolucionais e a função de ativação *ReLU*. Esta arquitetura incorpora elementos de design que permitem alcançar segmentação eficiente e precisa, como o uso de conexões de salto (*skip connections*) e esquemas de ponderação de classe personalizados.

A segunda rede neural convolucional profunda de segmentação semântica *D-LinkNet34* (Zhou et al., 2018) foi inicialmente projetada para segmentar estradas em imagens de satélite de alta resolução. No entanto, sua aplicação em outros domínios pode ser realizada através de ajustes nos parâmetros de treinamento e nos rótulos fornecidos à rede neural.

Sua arquitetura é dividida em três blocos A, B e C. Na qual o bloco A representa o *encoder* do modelo, que também é *ResNet34*, encarregado de transformar os dados de entrada em uma representação latente mais compacta e informativa. Dada a complexidade das imagens de satélite, é significativo preservar detalhes espaciais para a detecção dos dados de interesse. No intuito de enfrentar esse desafio, o bloco B expande o campo receptivo e, ao mesmo tempo, preserva informações espaciais detalhadas utilizando convoluções dilatadas. A inclusão dessas convoluções dilatadas permite que a *D-LinkNet34* tenha um campo receptivo superior ao da rede neural *LinkNet34*, ao mesmo tempo em que mantém os detalhes das informações dos pixels. O bloco C do modelo é a unidade *decoder*, muito semelhante à da *LinkNet34*, que utiliza camadas de convolução transposta para expandir, restaurando assim a resolução do mapa de características para a dimensão original da imagem de entrada (Zhou et al., 2018).

2.3 Definição de parâmetros de treinamento

A definição adequada dos cenários de treinamento é um passo crucial no desenvolvimento de modelos de aprendizado profundo (Afaq and Rao, 2020). Os hiperparâmetros, como *Initial learning rate* = 0.001, *batchsize* = 8 e o *threshold* de binarização = 0.3, foram adotados conforme sugerido pela literatura (Zhou et al., 2018; Akyel and Arıcı, 2022).

A função de perda *Binary Cross Entropy Intersection over Union (BCEIoU)*, que combina *Binary Cross Entropy (BCE) loss* e *Intersection over Union (IoU) loss*, é aplicada para otimizar os parâmetros do modelo, visando minimizar a disparidade entre as segmentações previstas e reais, além de maximizar a sobreposição entre elas. A quantidade de épocas é determinante, pois o número insuficiente resulta em dificuldades de aprendizado, e uma quantidade excessiva leva ao sobreajuste (*overfitting*). Para mitigar o risco de *overfitting*, foram inicialmente aplicadas

60 épocas com um critério de parada baseado na curva de perda.

2.4 Base de Dados Geográfica da Distribuidora (BDGD)

A BDGD é disponibilizada pela Agência Nacional de Energia Elétrica (ANEEL) (Neto, 2023). Foi criada para emular geograficamente o sistema elétrico das distribuidoras, fornecendo um leque de informações sobre os ativos, tanto técnicas quanto comerciais. Para a análise em questão, foram utilizados os dados da rede de distribuição de baixa tensão. A rede de média tensão frequentemente se sobrepõe à de baixa tensão. Porém, estende-se somente até os transformadores de tensão. Já a rede de baixa tensão tem maior capilaridade, pois é a que efetivamente chega aos consumidores finais.

3. RESULTADOS E DISCUSSÃO

Os algoritmos foram implementados em linguagem de programação *Python*, em uma máquina com CPU AMD Ryzen Threadripper 3970X x64, GPU NVIDIA GeForce RTX 4090 com 24 GB, e memória RAM de 256 GB. O conjunto de dados, composto por 501 imagens, foi dividido em treinamento e validação. Para isso, 80% das imagens foram designadas para o conjunto de treinamento, enquanto 20% foram reservadas para o processo de validação. Adicionalmente, como estratégia para evitar o *overfitting* dos dados, foi realizado o processo de *data augmentation* das imagens. Esse processo visa expandir ou diversificar o conjunto de imagens de treinamento, melhorando assim a capacidade de generalização do modelo treinado e tornando-o mais robusto a diferentes variações nas imagens.

Com 400 pares de treinamento utilizados, foram obtidos 4800 arquivos após o pré-processamento dos dados. Como as imagens de validação do modelo não passaram pelo processo de *augmentation*, foram utilizadas as 101 cenas. A rede neural LinkNet34 apresentou um treinamento mais extenso, que atingiu 28 épocas antes do critério de parada ser acionado, enquanto o algoritmo DLinkNet34 treinou durante 17 épocas. A Tabela 1 exhibe os resultados das métricas de desempenho para o conjunto de validação para as duas redes neurais de segmentação semântica.

Tabela 1. Desempenho das redes neurais de segmentação de ocupação de solo.

Arquitetura	Acurácia	F1-Score	IoU	Tempo de Treinamento
LinkNet34	0.8457	0.7319	0.7525	4 h 15 min
DLinkNet34	0.8381	0.7273	0.7415	2 h 57 min

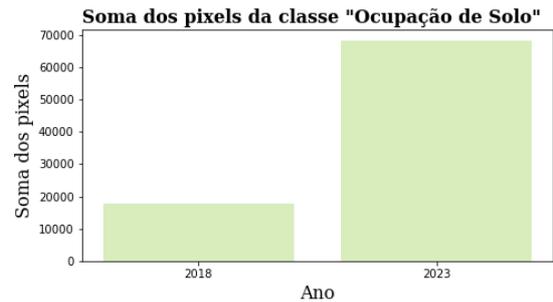
A acurácia representa a relação de proximidade entre o conjunto de *pixels* da máscara predita com os da máscara binária de referência. Por outro lado a métrica IoU apresenta a relação de sobreposição entre a máscara predita e de referência (também denominada *Jacard*) enquanto a métrica *F1-Score* busca avaliar a relação de similaridade entre as duas máscaras.

Embora a DLinkNet34 seja mais indicada para a segmentação em imagens de satélite devido às suas convoluções dilatadas, seus resultados de acurácia, F1-score e IoU foram inferiores aos da LinkNet34. Isso pode ser atribuído a

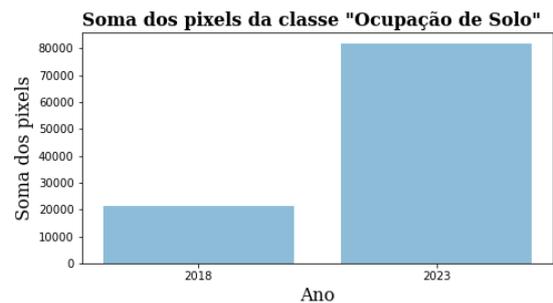
vários fatores, principalmente ao fato de a LinkNet34 ter sido treinada por um maior número de épocas, permitindo à este modelo uma melhor convergência para os padrões presentes nos dados. Além disso, a LinkNet34 é menos complexa que a DLinkNet34, reduzindo assim a susceptibilidade ao *overfitting*.

A seguir, serão exibidos, na Figura 4, os resultados da segmentação de cenas não vistas pelo modelo em nenhuma etapa do treinamento. As imagens são de recortes de um município localizado em Minas Gerais, que apresentou um crescimento urbano perceptível desde 2018.

As segmentações expostas na Figura 4 apresentam menos resultados falso negativos para a cena de 2023, ou seja, ocupação de solo não detectada corretamente. Isto pode ser resultado da similaridade do padrão de coloração que essa imagem apresenta com as imagens presentes no conjunto de treinamento. Isto ocorre devido às variações dos parâmetros de obtenção de imagens, como iluminação e ângulo azimute do satélite. Para uma compreensão mais aprofundada da evolução da ocupação do solo segmentada, foram gerados histogramas dos *pixels* detectados em cada classe, "Background" e "Ocupação de solo", para cada cena analisada. Essa análise permite observar o crescimento da área ocupada, considerando que cada pixel corresponde a 0,6 metros quadrados. A Figura 5 exhibe os histogramas obtidos a partir da segmentação dos dois modelos.



(a) Histograma para LinkNet34.



(b) Histograma para DLinkNet34.

Figura 5. Histograma da evolução de *pixels* da classe "ocupação de solo" dos anos 2018 e 2023 para cada modelo de segmentação.

Os dois modelos de segmentação mostram uma notável evolução em relação aos anos de 2018 e 2023. No entanto, é importante destacar que houve um maior número de falsos negativos em 2018, resultando em uma discrepância maior na contagem de exemplos da classe "ocupação de solo" entre os dois anos. Todavia, o resultado se mantém relevante,

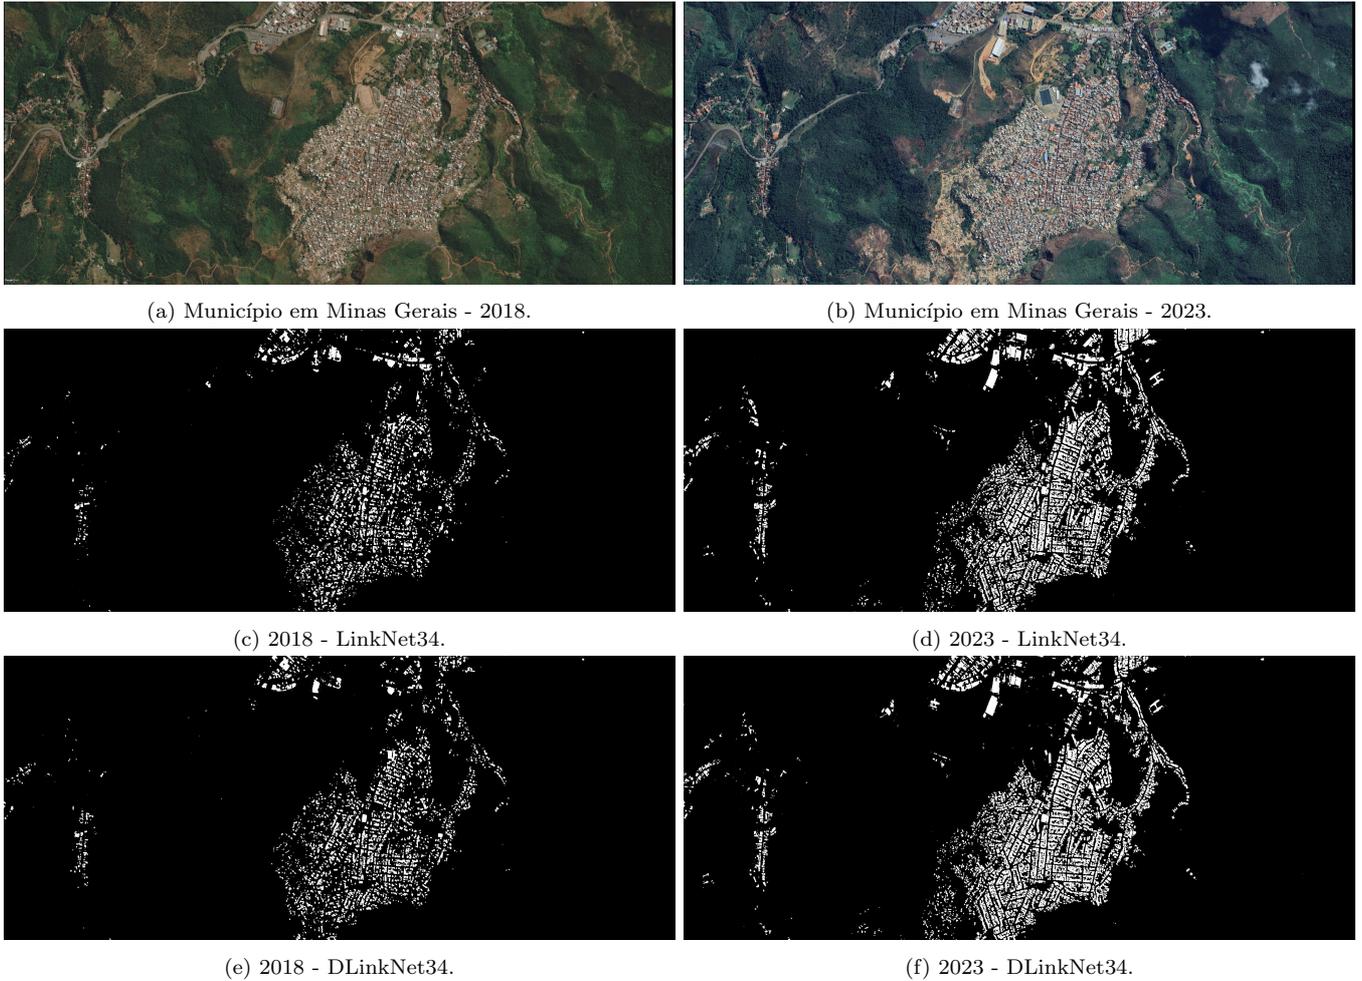


Figura 4. Resultado da segmentação de duas cenas do Brasil obtidas para os anos de 2018 e 2023. As imagens (a) e (b) são as cenas originais para 2018 e 2023, (c) e (d) são as máscaras de predição oferecidas pela LinkNet34, (e) e (d) são as máscaras de predição da DLinkNet34.

visto que o objetivo é observar adensamento urbano, e não realizar uma contagem de ocupações propriamente ditas.

A próxima etapa da análise consiste em observar o avanço da infraestrutura da rede elétrica. Para isto, foram utilizados os dados da rede de baixa tensão, disponibilizadas pelo BDGD, do mesmo recorte do município localizado em Minas Gerais, a fim de observar se, entre os anos de 2018 e 2023, houve mudanças na infraestrutura da rede. A Figura 6 exibe, para os anos de 2018 e 2023, a evolução da infraestrutura de baixa tensão para um recorte do município.

Em contrapartida ao progresso no monitoramento do adensamento urbano pelo algoritmo de detecção de ocupação de solo, as informações provenientes do BDGD não revelam grandes diferenças na infraestrutura da rede elétrica de baixa tensão. Isso se reflete na persistência de áreas de ocupação de solo desprovidas de rede elétrica, o que gerou indícios de ocupações clandestinas não oficialmente registradas como usuárias do serviço elétrico. Tal fato foi posteriormente confirmado pela concessionária de energia responsável fornecimento de energia elétrica ao município.

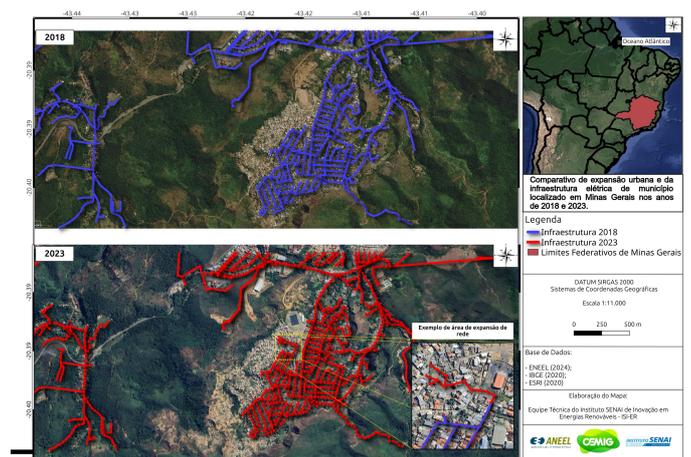


Figura 6. Modelo geográfico fornecido pelo BDGD que representa o sistema real elétrico do município de localizado em Minas Gerais, para 2018 e 2023.

4. CONCLUSÃO

O presente trabalho faz uso de duas redes neurais de segmentação semântica, a LinkNet34 e a DLinkNet34, trei-

nadas com imagens RGB de satélite provenientes de municípios brasileiros, obtidas do *Google Earth*, garantindo a representatividade geográfica e a diversidade de condições ambientais. Os resultados obtidos indicam que ambos os modelos são capazes de segmentar as áreas de interesse nas imagens de satélite, com a LinkNet34 apresentando desempenho ligeiramente superior a DLinkNet34. Além disto, a integração dos resultados obtidos pelo modelo e os dados de infraestrutura, gerou *insights* sobre a discrepância entre o crescimento urbano e da rede elétrica.

Como perspectivas para futuras pesquisas, planejamos realizar treinamentos adicionais com um conjunto de dados expandido. Visamos aumentar a diversidade das condições de iluminação, levando em consideração as variações sazonais ao longo do ano, dada a influência significativa que elas apresentam nos padrões de cores nas imagens. Antecipamos que essa abordagem resultará em um modelo mais generalizado, tornando-o mais adequado para uma variedade de aplicações em diferentes regiões do Brasil.

A segmentação de imagens em ambientes dinâmicos é complexa e influenciada pela resolução das imagens. É crucial entender como as redes neurais se adaptam a diferentes resoluções, considerando a eficácia da segmentação, o intervalo entre revisitas de satélites e os custos associados a diferentes fontes de dados. Esta pesquisa buscou correlacionar a capacidade de segmentação da rede, características temporais dos dados e implicações financeiras. Essa investigação contribuirá para uma compreensão mais ampla do desempenho do modelo em ambientes de resolução variada e permitirá otimizações estratégicas em termos de eficácia e custo.

AGRADECIMENTOS

Agradecemos à CEMIG, ANEEL (PD-04950-0664/2023), CNPq e CAPES pelo essencial apoio financeiro e colaboração. Esse suporte é fundamental para o avanço deste estudo e para o progresso em pesquisa, desenvolvimento e inovação (PD&I) no setor elétrico.

REFERÊNCIAS

- Afaq, S. and Rao, S. (2020). Significance of epochs on training a neural network. *Int. J. Sci. Technol. Res.*, 9(06), 485–488.
- Akyel, C. and Arıcı, N. (2022). Linknet-b7: noise removal and lesion segmentation in images of skin cancer. *Mathematics*, 10(5), 736.
- Bastos, R.M.C., de Sena Machado, G.F., Frauches, N., and Cruz, C.B.M. (2023). Potencialidades e aplicações do uso de deep learning no sensoriamento remoto em análises urbanas.
- Chaurasia, A. and Culurciello, E. (2017). Linknet: Exploiting encoder representations for efficient semantic segmentation. In *2017 IEEE visual communications and image processing (VCIP)*, 1–4. IEEE.
- Cucco, J. and de Oliveira, F.H. (2011). Modelo de propensão a ocupações irregulares em linhas de transmissão de energia elétrica. *GEOUSP Espaço e Tempo (Online)*, 15(3), 107–120.
- Dias, F.T., Clemente, C.M.S., Pereira, D.M., and Leite, M.E. (2024). Desenvolvimento, crescimento e expansão urbana: Implicações socioespaciais do aumento de edificações em uma cidade de pequeno-médio porte. *Caderno de Geografia*, 34(76), 237. doi:10.5752/p.2318-2962.2024v34n76p237.
- Fontana, A.G., Nascimento, V.F., Fernandes, R.P., Mendes, D.F., da Rocha, A.d.M., and do Amaral, F.H.F. (2023). Análise do crescimento urbano passado e futuro usando sensoriamento remoto e aprendizado de máquina.
- Ganjirad, M. and Bagheri, H. (2024). Google earth engine-based mapping of land use and land cover for weather forecast models using landsat 8 imagery. *Ecological Informatics*, 80, 102498.
- Huyen, C. (2022). *Designing machine learning systems*. "O'Reilly Media, Inc."
- Li, W., He, C., Fang, J., Zheng, J., Fu, H., and Yu, L. (2019). Semantic segmentation-based building footprint extraction using very high-resolution satellite images and multi-source gis data. *Remote Sensing*, 11(4), 403.
- Lins, F.H.F. and Rodrigues, S.A. (2023). Smart grids como alternativa para combate às perdas não técnicas na distribuição de energia elétrica. *Revista Ibero-Americana de Humanidades, Ciências e Educação*, 9(5), 788–799.
- Lourenço, F. and da Silva Filho, J.I. (2023). Gestão de ativos em concessionárias de energia elétrica: o uso de sistema especialista paraconsistente para elevação de eficiência e qualidade através da predição. *Revista de Gestão e Secretariado*, 14(9), 15625–15641.
- Moyroud, N. and Portet, F. (2018). Introduction to qgis. *QGIS and generic tools*, 1, 1–17.
- Nathaniel, S.P. and Bekun, F.V. (2021). Electricity consumption, urbanization, and economic growth in nigeria: New insights from combined cointegration amidst structural breaks. *Journal of Public Affairs*, 21(1), e2102.
- Neto, S.d.A.F. (2023). Agência nacional de energia elétrica-aneel.
- Neupane, B., Horanont, T., and Aryal, J. (2021). Deep learning-based semantic segmentation of urban features in satellite images: A review and meta-analysis. *Remote Sensing*, 13(4), 808.
- Nissinen, C.J.L. (2024). Evolução da ocupação urbana sobre os tipos de formas de relevo do município de torresrs.
- Oliveira, A.M.d. (2024). Metodologia para análise das relações entre regulação dos uso do solo, preços imobiliários e mobilidade urbanas.
- Sirko, W., Kashubin, S., Ritter, M., Annkah, A., Bouchareb, Y.S.E., Dauphin, Y., Keysers, D., Neumann, M., Cisse, M., and Quinn, J. (2021). Continental-scale building detection from high resolution satellite imagery. *arXiv preprint arXiv:2107.12283*.
- Zhou, L., Zhang, C., and Wu, M. (2018). D-linknet: Linknet with pretrained encoder and dilated convolution for high resolution satellite imagery road extraction. In *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, 182–186.