

## ANÁLISE DA ARQUITETURA U-NET PARA ATUALIZAÇÃO CADASTRAL

### *Analysis of U-Net architecture for cadastre update*

**Vinícius Barbosa Henrique**

**Universidade Estadual Paulista “Júlio de Mesquita Filho”**

Programa de Pós-graduação em Ciências Cartográficas

v.henrique@unesp.br

**Amilton Amorim**

**Universidade Estadual Paulista “Júlio de Mesquita Filho”**

Departamento de Cartografia

a.amorim@unesp.br

**Milton Hirokazu Shimabukuro**

**Universidade Estadual Paulista “Júlio de Mesquita Filho”**

Departamento de Cartografia

milton.h.shimabukuro@unesp.br

### **Resumo**

O desenvolvimento no campo de aprendizado de máquina tem produzido algoritmos de aprendizado profundo – *deep learning* – capazes de detectar e segmentar objetos e pixels em diferentes contextos. Inspirado no comportamento do neurônio humano, a evolução com o uso de redes neurais artificiais vêm proporcionando uma revolução na capacidade de reconhecimento, classificação e agrupamento de dados, aprendendo e melhorando constantemente. Dessa forma, o uso de redes neurais em softwares utilizados em Sistemas de Informações Geográficas (SIG) traz ao usuário comum a possibilidade de aumentar e melhorar modelos de detecção em produtos cartográficos, inclusive com alto nível de detalhes como os urbanos. As necessidades de atualizações constantes em sistemas cadastrais demandam meios eficientes de obtenção de diversos tipos de dados, principalmente para promover a multifinalidade do cadastro, e criar sistemas cadastrais completos que se mantenham atualizados para a gestão pública. Neste trabalho, foi empregada a rede neural *U-Net* para detecção pixel a pixel de edificações em área de expansão urbana do município de Parauapebas/PA, de forma a avaliar as potencialidades da aprendizagem de máquina para atualização cadastral. Os resultados demonstraram que a técnica é capaz de oferecer apoio ao monitoramento periódico da expansão urbana, estimação e definição de áreas para atualização cadastral, delimitação média das áreas das edificações para suporte à futuras atualizações e como base para gestores para a precificação do levantamento cadastral.

**Palavras-chave:** *Deep Learning*; Atualização Cadastral; *U-Net*.

### **Abstract**

Technological development in the machine learning area has produced deep learning algorithms capable of detecting and segmenting objects and pixels in different contexts. Inspired by the behavior of the human neuron, the evolution with the use of artificial neural networks has provided a revolution in the ability to recognize, classify and group data, constantly learning and improving. Thus, the use of neural networks in geographic information system (GIS) brings to the common user the possibility of increasing and improving detection models in cartography products, including a high level of details such as urban ones. The necessity for constant updates in cadastral systems requires efficient means of obtaining different types of data, mainly to promote the multifinality of the cadastre, and to create a complete cadastral system that remain updated for public management. In this work, the U-Net neural network was used for pixel-by-pixel detection of buildings in an urban expansion area in the city of Parauapebas/PA, in order to assess the potential of machine learning for

cadastral updating. The results showed that the technique is capable of offering support for periodic monitoring of urban expansion, estimation and definition of areas for cadastral updating, approximate delimitation of building areas to support future updates, and as a basis for managers pricing the cadastral survey.

**Keywords:** Deep Learning; Cadastre Update; U-Net.

## 1. INTRODUÇÃO

O uso de *deep learning* está cada vez mais presente em diversas tecnologias, como aplicações de smartphones, carros autônomos, reconhecimento de fala e áreas da saúde. Na Cartografia, o uso de redes neurais de *deep learning* para extração de dados das cidades tem se tornado mais comum com o avanço na área. A aplicação de *deep learning* agiliza processos e propicia informações em tempo relativamente menor, identificando e classificando objetos ou pixels por meio de diferentes algoritmos.

Há diversas redes neurais desenvolvidas no campo do aprendizado de máquina, como a arquitetura *U-Net* vista neste trabalho. Essa é uma rede neural completamente convolucional, idealizada para aplicações na área da saúde, mas que pode ser aplicada em outras áreas do conhecimento. A ESRI vem implementando algoritmos de *deep learning* em seus softwares, permitindo ao público o acesso a essa tecnologia em uma interface sem linhas de código.

Elencada como uma dificuldade recorrente na expansão do cadastro, a atualização cadastral ainda não é constante por limitações tecnológicas, e necessita de tecnologias que viabilizem esse aspecto. Um sistema cadastral constantemente atualizado propicia maior qualidade nas decisões dos gestores públicos, retornando o investimento em bem estar da população.

Dessa forma, este trabalho tem por objetivo aplicar a arquitetura *U-Net* para detecção de edificações em área urbana pelos pacotes disponíveis no ArcGIS, para avaliação da capacidade de fornecimento de produtos para atualização cadastral, e analisar as possibilidades atuais do *deep learning* e *U-Net* para a gestão dos sistemas cadastrais.

## 2. APRENDIZADO DE MÁQUINA

### 2.1. Deep Learning

*Deep learning*, ou aprendizado profundo, surgiu em 2006 como um novo campo de pesquisa na área de aprendizagem de máquina, e nos últimos anos tem propiciado um grande avanço no processamento de informações em larga escala, em diversas áreas do conhecimento (DENG; YU, 2014).

Segundo Deng e Yu (2014), há diversas definições para *deep learning*, sendo uma delas a de que é um campo do aprendizado de máquina (*machine learning*) baseado em aprender níveis de representação, na qual os níveis superiores são conceitos definidos a partir dos níveis inferiores, e os níveis inferiores podem auxiliar a definir os níveis superiores.

As aplicações são diversas, abrangendo desde reconhecimento de voz até a detecção e classificação de objetos, ou pixel, em imagens. E essa capacidade de resolução de problemas tem se tornado cada vez maior, com o passar dos anos, devido ao avanço de redes neurais profundas (LECUN et al. 2015).

A forma mais comum de aprendizado de máquina, segundo Lecun et al. (2015), é o aprendizado supervisionado. O aprendizado supervisionado é feito coletando um grande

conjunto de imagens para treinamento, sobrepostas ou não, que são rotuladas em categorias. Cada objeto da paisagem pode ser rotulado para o treinamento, permitindo criar modelos para identificação de uma ou mais categorias.

As categorias recebem pesos como saída do processamento, e o maior peso indica a categoria prevista pela rede, conforme aprendeu a prever na etapa de treinamento. Segundo Lecun et al. (2015), um sistema comum de *deep learning* pode possuir milhões de pesos que são ajustados interativamente durante o treinamento, e são vistos como parâmetros adaptáveis.

Com um conjunto de pesos é verificado o erro no aprendizado, e a variação dos pesos implica em variação do erro, sendo que a decisão de aumentar ou diminuir os pesos considera o impacto dessa ação no erro, buscando minimizá-lo (LECUN et al. 2015).


O uso de *deep learning* para classificação se diferencia dos classificadores tradicionais (lineares) por possuir redes neurais de aprendizagem. Este fato implica em que, objetos poderiam ser classificados mesmo que houvesse variabilidade entre si, como forma ou luminosidade. Para classificadores tradicionais, esses objetos estariam classificados em categorias diferentes quando houvesse a variação.

## 2.2. Redes Neurais e Redes Neurais Convolucionais

O funcionamento do neurônio humano é o fundamento para as redes neurais artificiais, pelo cérebro – conjunto de neurônios – ser um órgão capaz de realizar tarefas complexas de forma rápida e paralela, dessa forma, as redes neurais artificiais são projetadas para simular a forma como o cérebro processa informações (HAYKIN, 2004).

A convolução pode ser entendida, segundo Bracewell (1986), como um operador, composto de duas funções, que fornece uma terceira função a partir das áreas sobrepostas, em função do deslocamento entre elas. Há diversos filtros para imagens baseados em matriz de convolução, permitindo que transformações possam ser aplicadas, como exemplificado na Figura 1.

Figura 1: Representação da convolução em imagens



Fonte: GIMP (2020).

A Figura 1 representa a atuação do núcleo (imagem central) na área de bordas verdes da imagem matricial (a esquerda) de forma convolucional. O resultado da convolução é a imagem da direita. A mudança de valor do pixel em vermelho decorre das sucessivas multiplicações e somas provocadas pela matriz de convolução:  $(40 \cdot 0) + (42 \cdot 1) + (46 \cdot 0) + (46 \cdot 0) + (50 \cdot 0) + (55 \cdot 0) + (52 \cdot 0) + (56 \cdot 0) + (58 \cdot 0) = 42$  (GIMP, 2020).

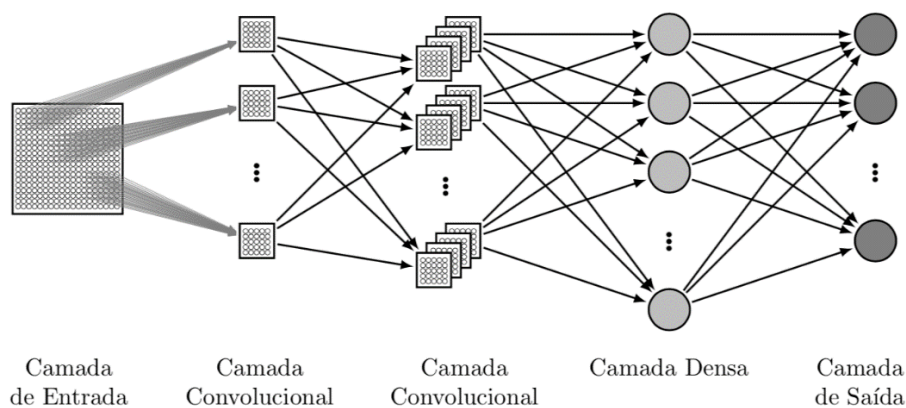
Nesse sentido, as redes neurais convolucionais (em inglês, *convolutional neural network* – CNN) são baseadas no processo biológico do córtex da visão humana, sendo uma das abordagens mais usadas no campo de reconhecimento visual por duas razões: sua precisão e predição (GOODFELLOW et al. 2016). Consiste primordialmente em: múltiplas camadas

hierárquicas convolucionais, com uma camada de entrada e sucessivas camadas convolucionais.

Há também arquiteturas com a adição de uma camada densa (ou *fully connected*) (Figura 2) com intensa conexão entre as camadas, similar as conexões sinápticas do cérebro, que requisitam maior poder de processamento dos componentes, comparado com uma rede neural convolucional sem a camada densa.

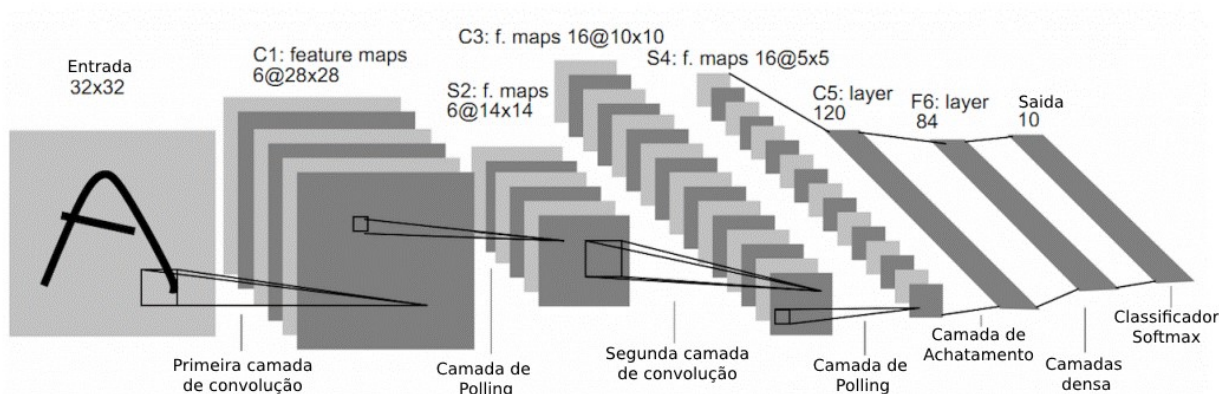
Um exemplo de arquitetura de rede neural convolucional com camada densa é a LeNet-5 (Figura 3), criada em 1998 por Yann LeCun, composta por duas camadas convolucionais e de *pooling*, uma camada convolucional achatada, e duas camadas densas, finalizando com um classificador *softmax* (LECUN et al. 1998).

Figura 2: Exemplo de arquitetura CNN com camada densa



Fonte: SAKURAI (2017)

Figura 3: Representação da arquitetura LeNet-5.



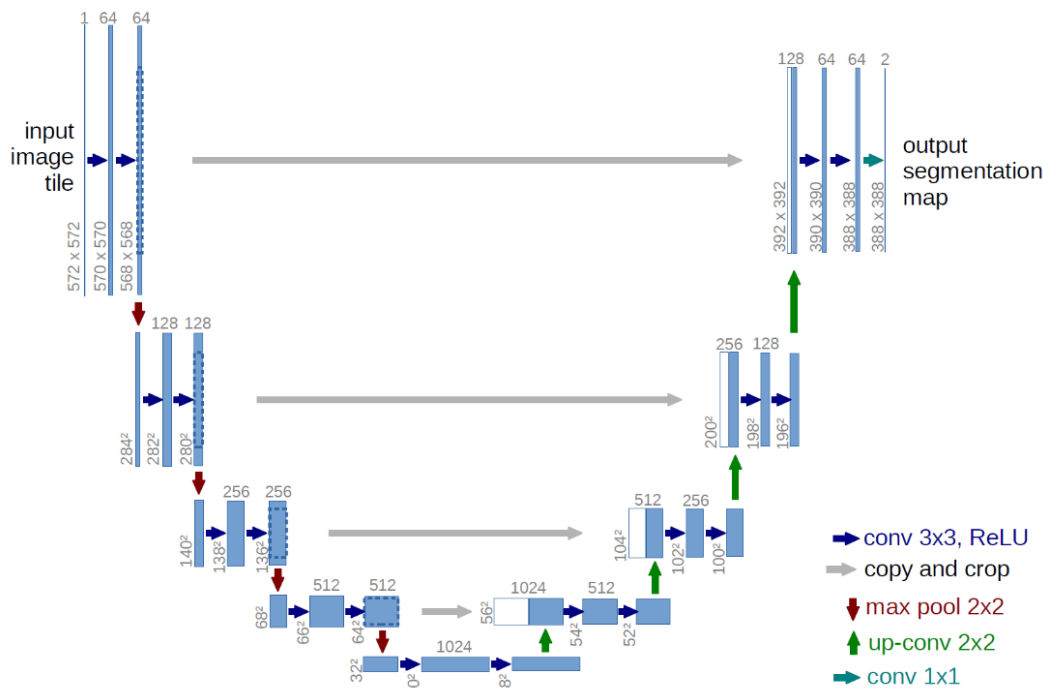
Fonte: adaptado de LECUN et al. (1998)

### 2.3. U-NET

A arquitetura U-net é embasada em uma rede neural completamente convolucional, criada em 2015, com enfoque na classificação de imagens biomédicas (RONNEBERGER et al. 2015). Essa arquitetura tem como princípio de funcionamento dois caminhos, redução e

expansão (*contracting* e *expansive*) vistos na Figura 4, e é amplamente utilizada por permitir segmentação com dados de treino limitados.

Figura 4: Arquitetura U-net.



Fonte: RONNEBERGER et al. (2015)

Segundo Ahmed et al. (2020), os modelos atuais mais sofisticados de extração de edificações, estradas e telhados são baseados na arquitetura U-net, com imagens de satélite e de *Remotely Piloted Aircraft System* – RPAS, ou Sistema de Aeronave Remotamente Pilotada em diversas escalas e resoluções.

A aplicação de algoritmos de *deep learning* tem sido facilitada com a inserção de ferramentas em softwares de SIG, como o ArcGIS, que em sua versão PRO 2.5 com a instalação de bibliotecas em Python (*TensorFlow*, *PyTorch* ou *Keras*) permite a detecção, classificação de objetos e de pixels em *deep learning*.

A presença dessas ferramentas no ArcGIS oportuniza o treinamento de modelos para mais usuários que não dominam ambientes de programação convencionais, aumentando o número de modelos de treino disponíveis para a comunidade, e o desenvolvimento de novos algoritmos especializados.

### 3. CADASTRO E ATUALIZAÇÃO CADASTRAL

A concepção fiscal do Cadastro, como somente depósito de documentos para a garantia de direitos e tributação sobre a terra, está mudando para uma visão multifinalitária. De certo, a multifinalidade do cadastro ocorre quando o registro passa a contemplar, além dos aspectos

econômicos, os dados físicos, jurídicos, ambientais, sociais e das pessoas que habitam o imóvel (LOCH; ERBA, 2007).

Os sistemas cadastrais não são um fim em si mesmos, podendo apoiar mercados financeiros imobiliários, aumentando a produtividade da agricultura, facilitando o desenvolvimento sustentável, gerenciamento ambiental, a estabilidade política e a justiça social (WILLIAMSON, 1995).

Para fomentar isso, um cadastro pleno deve conter informações referentes a todas as parcelas territoriais, públicas ou privadas, urbanas e rurais (CARNEIRO, 2003). Sendo que a parcela deve indicar a extensão da terra ocupada, associado a parcela com um código único que oportuniza a acessibilidade aos dados (LOCH; ERBA, 2007).

O modelo cadastral do Brasil tem se apresentado deficiente, sob o ponto de vista dos recursos humanos disponíveis nas prefeituras para a gestão dos sistemas cadastrais, pela dificuldade geralmente encontrada. No momento em que se propõem mudanças, nota-se a falta de capacitação dos recursos humanos.

É recomendado, nestes casos, que haja profissionais da área técnica especializada, e que estes incentivem a implantação de uma base cartográfica de qualidade (CARNEIRO, 2003).

Além dos obstáculos já citados, geralmente há conflitos políticos que limitam a implantação de um cadastro eficiente, como a comum descontinuidade das atividades na troca de gestão das prefeituras, fato comum no Brasil (CARNEIRO, 2003). Dessa forma, é importante que despesas com atualização e implantação de sistemas cadastrais sejam vistas como um investimento na gestão pública (AMORIM et al. 2018).

Segundo Amorim et al. (2018) os métodos envolvidos em atualização cadastral devem ser constantes, e com informações públicas, permitindo o questionamento e controle da atividade pública. Ademais, pesquisas que tragam propostas para aumentar a velocidade de aquisição e atualização de dados cadastrais são diretamente benéficas para a sociedade.

Para Amorim et al. (2018) é determinante que o termo “atualização cadastral” não seja entendido como a execução de um novo levantamento cadastral, pois a atualização propicia a criação de um histórico dos dados. Sobre a importância da atualização em sistemas cadastrais, podemos afirmar que:

É importante que se estabeleçam métodos economicamente viáveis para a atualização de sistemas cadastrais, bem como de mapeamentos, possibilitando a manutenção de sistemas cadastrais adequados à sua utilização, como principal fonte de informações à atividade de planejamento municipal. (AMORIM et al, 2018, p. 137.2)

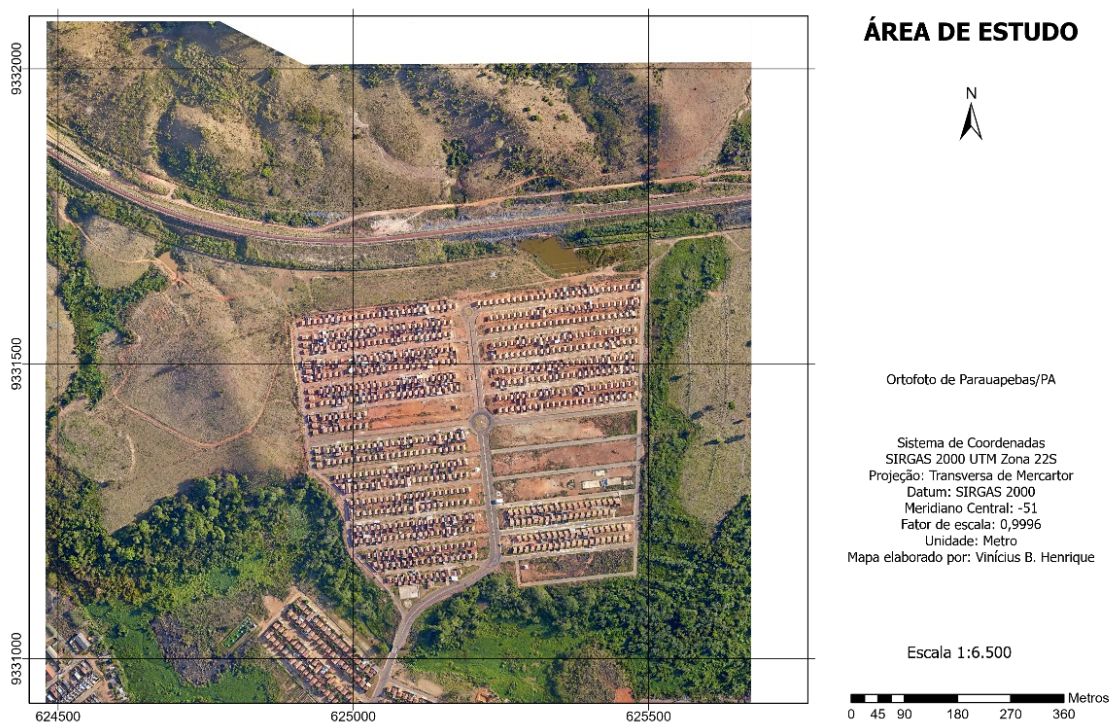
Dessa forma, a arquitetura U-Net pode contribuir para a atualização cadastral por sua agilidade em processamento de dados e confecção de produtos úteis ao cadastro.

#### **4. ESTUDO DE CASO**

A área de estudo se concentrou em uma região de expansão urbana, no município de Parauapebas/PA, na região norte brasileira (Figura 5). O local foi escolhido para o estudo por

ter fotografias aéreas ortorretificadas do ano de 2018 com resolução de 10 cm, separadas em 4 blocos fotográficos, sendo três usados para treino e criação do modelo e um para teste da classificação.

Figura 5: Área de estudo




Os materiais utilizados foram: arquivo vetorial de edificações obtido por restituição fotogramétrica; quatro fotografias ortorretificadas compreendendo uma área de aproximadamente 1,5km<sup>2</sup> em SIRGAS 2000 com coordenadas em UTM Zona 22; software ArcGIS Pro 2.5 com as bibliotecas em Python (*tensorflow 1.14.0*, *keras 2.2.4*, *scikit-image 0.15.0*, *pillow 6.1.0*, *fastai 1.0.54*, *pytorch 1.1.0*, *libtiff 4.0.10*) e com o módulo *Image Analyst*; um computador com placa de vídeo *Nvidia GeForce GTX 1660 Ti* com núcleos *CUDA*.

#### 4.1. Metodologia

O estudo aplicou como fluxo de trabalho o diagrama da Figura 6.

Figura 6: fluxo de trabalho

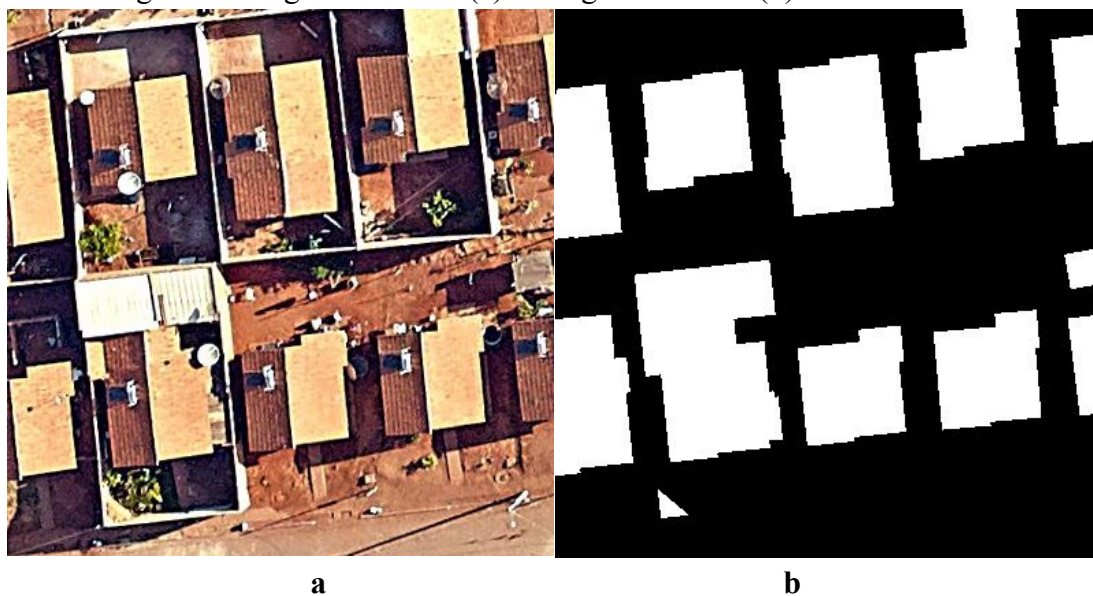


Apesar do ArcGIS apresentar os módulos de *deep learning*, todos os pacotes precisam ser importados para o funcionamento. Portanto, todas as bibliotecas de *deep learning* tiveram de ser instaladas no ArcGIS Pro 2.5, usando o gerenciador de pacotes *Conda*.

Com os algoritmos instalados, foi feita uma seleção das edificações restituídas para serem usadas no treinamento do modelo, totalizando 579 edificações. Essa escolha foi feita usando 3 das 4 áreas do mosaico, sendo a quarta área reservada para ser usada na classificação posterior.

Pela ferramenta *Export Train Data for Deep Learning* foram exportadas 183 imagens TIFF com dimensões de 400x400 pixels (Figura 7-a), com pixel de tamanho 0.1m, no formato *Classified Tiles* (necessário para a arquitetura U-Net). O arquivo *shapefile* de edificações das três áreas foi usado para rotular os locais, exportando em TIFF binário (Figura 7-b) – 1 para edificações e 0 para área não edificada – e para cada imagem é criado um arquivo de coordenadas em extensão TFW com a localização da área. O arquivo de treino é em formato EMD, com um arquivo JSON contendo estatísticas dos dados.


Figura 7: Imagem de treino (a) e imagem rotulada (b) na mesma área.



Com os dados de treino é construído o modelo de treino, pela ferramenta *Train Deep Learning Model*, com 30 épocas (uma época indica que o conjunto de dados de treino será passado uma vez para frente e para trás na rede neural) com o tipo de modelo definido em *U-Net - Pixel classification*, e com um *Batch Size* definido em 4 (número de amostras processadas antes do ajuste dos pesos). O *Backbone Model* escolhido foi o *resnet34*, sendo esse um modelo pré-configurado – rede pré-treinada – com mais de 1 milhão de imagens e 34 camadas de profundidade que auxilia na transferência de aprendizado – *transfer learning* – entre os modelos. O tamanho da amostra para validação foi de 10% do total, feito de forma randômica.


Ao final do processamento, a acurácia do modelo foi de 0.94528, ou seja, 94.528%, e o gráfico da Figura 8 mostra a curva de aprendizagem e a de validação, que após 30 épocas já não apresentava perdas. O tempo de processamento foi de 20 minutos.

Figura 8: gráfico de aprendizagem e de validação por processamento em lote e perdas.



A segmentação por pixel foi feita na área (Figura 9-a) pela ferramenta *Classify Pixel Using Deep Learning*, com *padding* definido em 100 (valor em pixel da borda que serão usados como comparação). A classificação retornou a Figura 9-b com tempo de processamento de 1 hora.

Figura 9: área de segmentação (a) e imagem segmentada por *deep learning* (b)



## 5. RESULTADOS E DISCUSSÃO

A imagem segmentada apresentou ruídos nas edificações devido a segmentação pixel a pixel, com bordas irregulares (Figura 10-a). Esse aspecto ocorre devido a arquitetura de rede neural aplicada e a dimensão do pixel do projeto, sendo possível atenuar esse efeito com outros

processamentos em ferramentas SIG.

Detectou-se a segmentação desnecessária de algumas áreas, como na Figura 10-b, onde o algoritmo classificou locais de construção ou demolição, e quadras com piso concretado, como edificação. Tal ocorrência é provocada pela presença de residências, no modelo de treino, com lajes sem telhado, ou telhas, com textura semelhante a encontrada em pisos de concreto.

O modelo também teve dificuldades em tratar edificações próximas entre si, como na Figura 11, onde a classificação uniu duas edificações separadas por muros. Com os vetores dos lotes seria possível separá-los, mas não poderiam ser corrigidas em estruturas dentro do mesmo lote.

Em comparação com a área edificada levantada por restituição, e a área segmentada pela arquitetura *U-Net* (Tabela 1), houve uma correspondência de aproximadamente 94.7%, em acordo com a acurácia do modelo de treino. Esse valor pode ser melhorado ao aumentar o conjunto de treino do modelo.

Figura 10: Imagem segmentada em escala 1:300 (a) e a segmentação incorreta (b)



Figura 11: segmentação entre edificações de lotes distintos.



Tabela 1: comparação das áreas entre restituição e U-net

Metodologia	Área edificada (m <sup>2</sup> )
Levantamento por restituição	25541.267
Extração por U-Net	26970.552

## 6. CONCLUSÕES

O ArcGIS facilitou a aplicação dos algoritmos de aprendizagem profunda por permitir a extração rápida dos dados para treino, a construção do modelo, e segmentação, dentro de uma única interface. Essas ferramentas também estão acessíveis pela aplicação web *Jupyter Notebook* no ArcGIS Pro pelo módulo *arcgis.learn*. Isso tende a aproximar o usuário comum do uso dos algoritmos de *deep learning* para detecção e segmentação em SIG, sem a necessidade de conhecimentos profundos em programação.

De todo modo, por não ser funções proprietárias do ArcGIS, o uso pode ser feito fora da interface do programa, em linhas de código e com maior nível de configuração, permitindo a inserção de novas arquiteturas e aprimoramentos nos algoritmos existentes. Essa opção pode propiciar maior acurácia nos modelos gerados, mas tende a requisitar maior entendimento de programação por parte do usuário.

O produto do modelo feito pela arquitetura *U-Net* correspondeu ao objetivo de segmentar as áreas edificáveis, mas apresentou ruídos e divergências na segmentação. Para melhores resultados é indicado que sejam adquiridos dados para treino em uma área maior, aliado com o uso de modelos *backbone* com maior número de camadas de aprendizagem. Essas modificações trazem um impacto no poder de processamento necessário da máquina, e, portanto, maior tempo para construção dos modelos.

Os ruídos, apesar de serem recorrentes nessa arquitetura, conforme mostra o estudo de AHMED et al. (2020), podem ser atenuados com outras ferramentas de SIG. O uso e desenvolvimento de outras arquiteturas para segmentação de edificações pode propiciar melhores resultados, como a arquitetura *Mask-RCNN*, que não usa a segmentação pixel a pixel, e que gera um produto vetorizado das edificações.

Para a extração de edificações, o produto necessita de conversão para formato vetorial e uma generalização cartográfica, atenuando e reduzindo os cantos arredondados vistos na *U-Net*, e é preciso separar as edificações próximas, aumentando a carga de processo manual. Nesse sentido, o produto pode ser aplicado para outros fins na atualização cadastral, como o monitoramento periódico da expansão urbana, estimação e definição de áreas para atualização cadastral, delimitação média das áreas das edificações para suporte à futuras atualizações e como base para gestores na precificação do levantamento cadastral.

Portanto, conclui-se que o uso da arquitetura *U-Net* oferece apoio para atualização cadastral, permitindo aplicação na classificação de objetos da paisagem urbana (como presença de piscinas e tipos de cobertura), tornando-se uma técnica promissora para viabilização da constante atualização cadastral.

### Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

## Referências

AHMED, Nahian; MAHBUB, Riasad Bin; RAHMAN, Rashedur M. **Learning to extract buildings from ultra-high-resolution drone images and noisy labels**. International Journal of Remote Sensing, p. 1-22, 2020.

AMORIM, Amilton; PELEGRINA, Marcos Aurélio; JULIÃO, Rui Pedro. **Cadastro e gestão territorial**. São Paulo: Editora Unesp Digital, 2018. ISBN 9788595462823.

BRACEWELL, Ronald Newbold. **The Fourier transform and its applications**. New York: McGraw-Hill, 1986.

CARNEIRO, Andréa Flávia Tenório. **Cadastro imobiliário e registro de imóveis**. Porto Alegre: Instituto de Registro Imobiliário do Brasil, 2003.

DENG, Li; YU, Dong. **Deep learning: methods and applications**. Foundations and trends in signal processing, v. 7, n. 3-4, p. 197-387, 2014.

GIMP, G. N. U. **Programa de manipulação de imagens GNU - Manual do Usuário**. Disponível em: <[https://docs.gimp.org/2.10/pt\\_BR/gimp-filter-convolution-matrix](https://docs.gimp.org/2.10/pt_BR/gimp-filter-convolution-matrix). 2020>. Acesso em: 20 agosto 2020.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. MIT press, 2016.

HAYKIN, Simon. **A comprehensive foundation**. Neural networks, v. 2, n. 2004, p. 41, 2004.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. **Deep learning**. nature, v. 521, n. 7553, p. 436-444, 2015.

LECUN, Yann; BOTTOU, Léon; BENGIO, Yoshua; HAFFNER, Patrick. **Gradient-based learning applied to document recognition**. Proceedings of the IEEE, v. 86, n. 11, p. 2278-2324, 1998.

LOCH, Carlos; ERBA, Diego Alfonso. **Cadastro técnico multifinalitário rural e urbano**. Cambridge, MA: Lincoln Institute of Land Policy, p. 104-112, 2007.

RONNEBERGER, Olaf; FISCHER, Philipp; BROX, Thomas. **U-net: Convolutional networks for biomedical image segmentation**. In: International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, 2015. p. 234-241.

SAKURAI, Rafael. **Implementando a estrutura de uma Rede Neural Convolutacional utilizando o MapReduce do Spark**. Disponível em: <<http://www.sakurai.dev.br/cnn-mapreduce/>>. Acesso em: 20 agosto 2020.

WILLIAMSON, Ian. **Appropriate cadastral systems**. Australian Surveyor, Taylor & Francis, v. 40, n. 4, p. 57-59, 1995.