

CLASSIFICAÇÃO DE NUVENS DE PONTOS UTILIZANDO APRENDIZAGEM DE MÁQUINA SUPERVISIONADA Supervised Machine Learning for Point Cloud Classification

Bruna Brito Liberal

Universidade Federal de Pernambuco | Recife | Brasil | bruna.liberal@ufpe.br

Gustavo de Hollanda Cavalcanti Soares

Universidade Federal de Pernambuco | Recife | Brasil | ghcs@cin.ufpe.br

Arthur Henrique da Costa e Silva

Centro Universitário Maurício de Nassau | Recife | Brasil | arthursilva@outlook.com

Adiel Teixeira de Almeida Filho

Universidade Federal de Pernambuco | Recife | Brasil | adiel.filho@cin.ufpe.br

Rachel Perez Palha

Universidade Federal de Pernambuco | Recife, Pernambuco | rachel.palha@ufpe.br

RESUMO

O uso de tecnologias de obtenção de nuvens de pontos para auxílio na elaboração de modelos digitais de elevação, medições e mapeamento de estruturas está cada vez mais presente na indústria AECO (Arquitetura, Engenharia, Construção e Operação). Tendo isso em vista, a pesquisa buscou utilizar um algoritmo de aprendizado de máquina supervisionado capaz de classificar nuvens de pontos de grandes áreas a partir da inserção de um conjunto de dados de nuvens pré-classificadas. O *script* desenvolvido é capaz de classificar regiões das nuvens de pontos em três categorias principais: terreno, edificações e vegetação, sendo especialmente útil para apoiar a construção de modelos de cidades ou obras de infraestrutura. O *script* apresentou métricas de desempenho que indicaram que o aprendizado de máquina supervisionado se comportou de maneira satisfatória, porém foi visto que a qualidade dos dados de entrada pode ser significativa para os resultados. A principal contribuição do algoritmo é a possibilidade de reconhecer e separar as nuvens de pontos em diferentes classes, além de ser capaz de classificar nuvens de pontos obtidas não só via escaneamento a laser (LiDAR) como também por fotogrametria (levantamentos aéreos realizados por sobreposição de imagens obtidas por drone).

Palavras-chave: Nuvens de Pontos; Aprendizagem de Máquina; Random Forest.

ABSTRACT

The use of technologies for obtaining point clouds to aid in creating digital elevation models, measurements, and mapping of structures is increasingly present in the AECO (Architecture, Engineering, Construction, and Operation) industry. With this in mind, the research sought to use a supervised machine learning algorithm capable of classifying point clouds over large areas by inserting a data set of pre-classified clouds. The script developed can classify point cloud regions into three main categories: terrain, buildings, and vegetation, which is especially useful for supporting the construction of city models or infrastructure works. The script presented performance metrics that indicated that supervised machine learning behaved satisfactorily, but it was seen that the quality of the input data could be significant for the results. The main contribution of the algorithm is the possibility of recognizing and separating point clouds into different classes, in addition to being able to classify point clouds obtained not only via laser scanning (LiDAR) but also by photogrammetry (aerial surveys carried out by superimposing images obtained from drones).

Keywords: Point Clouds; Machine Learning; Random Forest.

1 INTRODUÇÃO

O interesse em *Building Information Modeling* (BIM) tem crescido amplamente nos últimos anos, visto que essa metodologia contribui, entre outras coisas, para otimizar o ciclo de vida dos projetos e reduzir custos em todos os níveis (Bensalah; Elouadi; Mharzi, 2019; Chowdhury *et al.*, 2024; Tang *et al.*, 2023). A metodologia BIM envolve diversos fatores que abrangem o processo construtivo, desde o planejamento da obra até a pós-construção (Chuang; Yang, 2023). Ao mesmo tempo, o escaneamento a laser para criar nuvens de pontos em diferentes etapas do projeto também tem sido explorado para otimizar processos (Tan *et al.*, 2024). A combinação de BIM e LiDAR abre novas possibilidades na detecção de defeitos de construção em tempo real e no controle de qualidade (Wang *et al.*, 2015). Diante desse cenário, as nuvens de pontos dentro do AECO podem ter diferentes propósitos, como obter volumes de superfície e terreno, georreferenciar elementos, preparar projetos as-built e monitorar o andamento da obra (Ebrahimi; Hojat Jalali; Sabatino, 2023; Ma *et al.*, 2022; O'donnell *et al.*, 2019; Puri; Turkan, 2020; Yin; Lin; Yeoh, 2023). Embora a construção de um modelo BIM possa ser facilitada por meio de um projeto as-built preexistente, a nuvem de pontos surge como uma alternativa à criação de um modelo 3D.

Dentro da AECO, é essencial economizar tempo e outros custos, como recursos humanos (Liao *et al.*, 2022). Além disso, atrasos na entrega do projeto podem resultar em penalidades contratuais. Investir em inovação também se torna necessário, pois traz vantagem competitiva às empresas e proporciona soluções mais eficazes para os problemas existentes (Tezel; Papadonikolaki; Yitmen, 2019). Por essas razões, embora o uso de nuvens de pontos na engenharia ainda esteja em estágios iniciais (Zhao; Taib, 2022), é necessário investir nessa tecnologia e entender suas peculiaridades para explorá-la. Apesar dos desafios e barreiras a serem superados para criar um modelo BIM diretamente a partir de nuvens de pontos de forma automática, nuvens de pontos são cada vez mais comuns para os mais diversos objetivos na engenharia.

Este trabalho busca uma possível solução para otimizar a modelagem e o reconhecimento de grandes áreas a partir de nuvens de pontos, pois propõe a criação de um algoritmo de aprendizado de máquina supervisionado capaz de classificar regiões de nuvens de pontos em três categorias principais: terreno, edificações e vegetação. Ao longo do estudo, serão apresentados os resultados obtidos com a utilização do algoritmo mencionado. Possíveis limitações quanto à utilização desse algoritmo também serão delineadas. O algoritmo proposto se destaca por poder ser utilizado a partir de qualquer conjunto de dados de nuvens de pontos pré-classificado contendo informações mínimas, como cores e coordenadas. Além disso, ele também pode ser usado para classificar nuvens obtidas usando LiDAR ou fotogrametria.

O termo "Scan-to-BIM" refere-se à integração de tecnologias de escaneamento a laser com o desenvolvimento de modelos BIM. Bosché *et al.* (2015) apontam que o crescimento exponencial do mercado de hardware e software focado em escaneamento a laser na última década é um grande indicativo do valor dessa tecnologia. Com o surgimento dos modelos de aprendizado de máquina, algoritmos como redes neurais para análise de nuvens de pontos 3D foram desenvolvidos, adicionando diferentes funcionalidades na literatura, como segmentação semântica e segmentação de objetos (WANG *et al.*, 2022). Métodos de aprendizado de máquina são usados de forma semelhante em um contexto específico de classificação de objetos de nuvens de pontos (Diab; Kashef; Shaker, 2022). Diferentes metodologias baseadas em vários algoritmos são usadas para processar digitalmente dados de nuvens de pontos, especialmente para reconhecer padrões, características ou objetos em nuvens de pontos (Xu *et al.*, 2021).

Dentro desse contexto, o Random Forest (RF) consiste em um algoritmo de aprendizado de máquina supervisionado amplamente utilizado para classificação de dados e foi proposto inicialmente em 2001 por Breiman (Breiman, 2001). Essa classificação pode ser definida como a rotulagem coerente de elementos de um grupo e, especificamente no caso de RF, é realizada utilizando classificadores independentes (Parmar; Katariya; Patel, 2019). Os classificadores são utilizados para gerar estruturas chamadas árvores de decisão e atuam sobre subconjuntos randomizados dos dados de treinamento, justificando o nome do algoritmo (Breiman, 2001). A intenção central dessa metodologia é permitir previsões generalizadas para um conjunto de dados a partir da combinação do processamento desses subconjuntos (Breiman, 2001);(Parmar; Katariya; Patel, 2019).

2 MÉTODO

O desenvolvimento da solução proposta pode ser subdividido em diferentes etapas. A primeira dessas etapas foi a aquisição e preparação dos dados que serão utilizados como entrada do sistema. Em seguida, o *Visual Code Studio* foi escolhido como IDE (*Integrated Development Environment*), e o *software CloudCompare* foi utilizado para visualizar os resultados. A partir disso, um script de aprendizado de máquina baseado em Random Forest foi desenvolvido, e o script foi testado para corrigir possíveis erros até que os resultados obtidos fossem aceitáveis.

Para adquirir os dados necessários ao treinamento do modelo, foi utilizado o GeoSampa, uma plataforma da cidade de São Paulo (Brasil) que permite o acesso gratuito a mapas oficiais, com dados georreferenciados da cidade. Nessa plataforma, estão disponíveis dados aéreos LiDAR de todo o município, separados por quadrantes com informações rotuladas de alguns objetos. O GeoSampa permite o download de arquivos .laz e .laz(color) e a visualização dos metadados do levantamento e a visualização das nuvens online. No caso desta pesquisa, foram utilizadas nuvens no formato .laz(color), que possuem informações adicionais de cor para cada ponto.

2.1 PREPARAÇÃO DE DADOS

Dada a diversidade de morfologias de nuvens de pontos espalhadas pela cidade de São Paulo, foram escolhidas nuvens de pontos que abrangessem visualmente o maior número possível de categorias, com presença equilibrada das classificações que compõem o objetivo deste trabalho (vegetação, construção e terreno). Para isso, foram escolhidas nuvens com edificações variadas com diferentes cores de telhado, áreas de vegetação densa com pouca vegetação e terrenos em geral, especialmente rodovias e estradas. Dada a facilidade de manipulação dos dados como arquivos de texto, optou-se por trabalhar com nuvens de pontos no formato .xyz. Portanto, os arquivos no formato .laz(color) foram convertidos para .xyz utilizando um software de processamento de nuvens de pontos. As nuvens nativas do GeoSampa possuem uma estrutura de texto semelhante a uma planilha no formato .xyz, onde a primeira linha se refere ao cabeçalho da nuvem de pontos e cada uma das colunas contém informações diferentes provenientes dos equipamentos utilizados no escaneamento LiDAR. Para o estudo desenvolvido e dada a necessidade de reduzir o processamento computacional, apenas as colunas referentes às coordenadas (X, Y, Z), cores dos pontos (R, G, B) e a coluna "Classification", que contém a classificação das informações do tipo de objeto presente na nuvem de pontos, foram o foco deste estudo.

2.2 DESENVOLVIMENTO DO SCRIPT

Para desenvolver o script, foi utilizado o software Visual Studio Code, em linguagem Python, com as seguintes bibliotecas: *pickle*, para salvar o modelo treinado; *time*: para contabilizar o tempo de execução do código; *pandas*, para manipular o banco de dados; *scikit-learn*, biblioteca de aprendizado de máquina que possui diversos algoritmos, como Random Forest; *matplotlib*, para criação de gráficos. Dentro da biblioteca *scikit-learn*, foram importados os seguintes módulos: *RandomForestClassifier*: algoritmo de aprendizado de máquina baseado em árvores de decisão; *train_test_split*: função que divide os dados em conjuntos de treinamento e teste para avaliar o desempenho do modelo; *classification_report*: gera métricas de avaliação para modelos de classificação, fornecendo dados como precisão, *recall* e *F1-score*; *StandardScaler*: realiza a normalização dos dados. O software CloudCompare foi utilizado de apoio, tendo em vista que permite processar nuvens de pontos, converter o tipo de arquivo, filtrar classificações de nuvens de pontos e diversas outras funções. No estudo, o CloudCompare foi utilizado tanto para converter arquivos .laz para .xyz quanto para visualizar e comparar visualmente os resultados obtidos pelo script.

3 RESULTADOS

Após o processamento dos dados de entrada, treinamento do algoritmo e consolidação do modelo de treinamento o primeiro teste foi realizado com conjunto de dados com 10.638.403 pontos, que pode ser observado na Figura 1, onde do lado esquerdo é a visão real da nuvem de pontos e a direita é a classificação dos pontos em três categorias provenientes o GeoSampa: vegetação em verde escuro; terreno em vermelho; e construções em verde claro. Essa primeira nuvem de pontos foi organizada aleatoriamente de tal como que 80% dos pontos foram alocados para treino e 20% para teste.

Figura 1: Nuvem de pontos com 10.638.403 pontos.



Fonte: Os autores.

Após a realização dos testes, métricas características de algoritmos de aprendizagem foram verificadas para validar a eficácia do processo de treinamento. Os valores de precisão, *recall* e *f1-score* foram calculados para o aprendizado. Nas equações, TP representa verdadeiros positivos, FN representa falsos negativos e FP representa a contagem de falsos

positivos. Os valores obtidos no relatório de aprendizado a partir das equações (1), (2) e (3) podem ser vistos na Tabela 1.

$$Precisão = \frac{TP}{TP+FP} \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (3)$$


Tabela 1: Resultado das métricas de avaliação.

Classificação	Precisão	Recall	F1-score
Buildings	0,99	0,99	0,99
Ground	0,25	0,01	0,03
Others	0,96	0,99	0,97
Vegetation	0,98	0,96	0,97

Fonte: Os autores.

A taxa de aprendizado das camadas de construção e vegetação foi superior a 98%, mas o terreno apresentou um valor de aprendizado de apenas 25%. Isso pode ser explicado pelo fato de a camada nativa do conjunto de dados utilizado, que se refere ao terreno, ter baixa densidade em comparação às demais categorias. A camada de classificação original do Geosampa, referente ao terreno, apresenta bastante ruído; seus pontos são dispersos e pouco densos. Isso mostra que a qualidade dos dados de entrada pode interferir significativamente no aprendizado.


Figura 2: Classificação visual do resultado.



Fonte: Os autores.

A Figura 3 mostra a visualização de cada classe separadamente, para melhor compreensão dos resultados obtidos. Da esquerda para a direita, 'vegetação', 'edificações' e 'outros'.

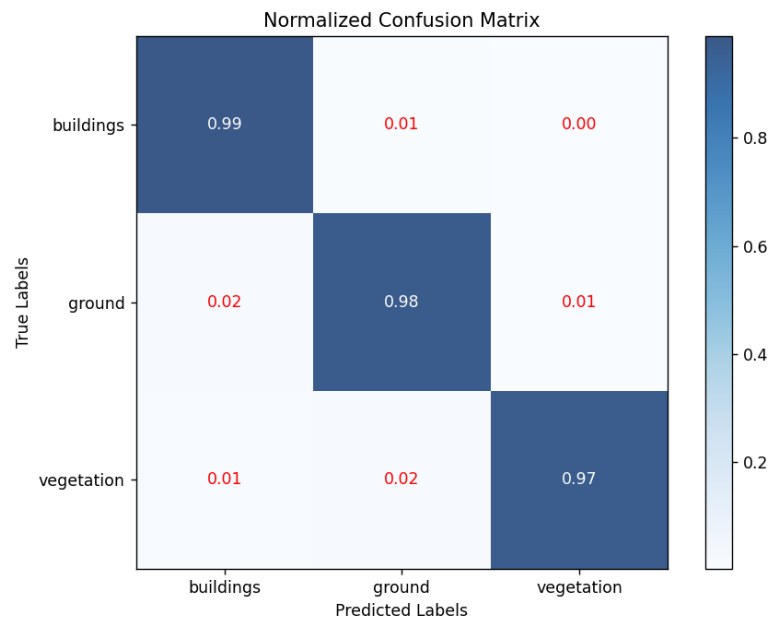
Figura 3: Classificação visual do resultado.



Fonte: Os autores.

A partir desse resultado, foi gerada uma matriz de confusão, comumente usada para avaliar modelos de classificação em aprendizado de máquina supervisionado. Cada linha da matriz representa uma classe prevista, enquanto cada coluna representa a instância atual da classe. Nesse caso específico, a primeira linha representa edificações, a segunda representa solo e a terceira representa vegetação. A matriz de confusão foi normalizada; os valores foram ajustados para demonstrar as porcentagens de valores referentes às classes, não seus valores absolutos. Para isso, cada valor na matriz é dividido pelo número total de pontos verdadeiros em suas respectivas classes. Isso faz com que os valores variem de 0 a 1, e quanto mais próximo o valor na diagonal principal estiver de 1, maior a proporção de predições corretas para a classe. Consequentemente, valores fora da diagonal principal devem ser próximos de 0, o que indica que uma baixa proporção de previsões foi erroneamente atribuída a outras classes. O resultado da matriz normalizada pode ser visto na Figura 4.

Figura 4: Matriz de confusão.



É possível concluir que o desempenho do modelo foi satisfatório, com todas as três classes apresentando valores de predição corretos e próximos do ideal, variando entre 97% e 99% de acurácia. Outra questão a ser discutida é como a qualidade dos dados de entrada no algoritmo afeta a classificação, considerando que em nenhum dos relatórios de aprendizado a camada "ground" apresentou boas métricas individualmente, apenas quando combinada com as demais camadas.

4 DISCUSSÕES

Este trabalho apresentou um script desenvolvido a partir do algoritmo de classificação Random Forest, que foi capaz de classificar nuvens de pontos de LiDAR em construção, vegetação e terreno. Como limitação do trabalho, observou-se que a qualidade dos dados de entrada influencia o aprendizado do algoritmo, portanto, grande atenção deve ser dada à densidade das camadas de nuvens de pontos ao escolher o conjunto de dados. Outra limitação é que, para o algoritmo aprender a classificar, um conjunto de dados pré-classificado de nuvens de pontos deve ser inserido, o que pode não ser tão simples de conseguir, com a possibilidade de classificar as nuvens de pontos manualmente, que pode não ser uma tarefa simples. Como principal contribuição, o script desenvolvido pode ser usado para aprender qualquer conjunto de dados de nuvem de pontos, desde que o formato da nuvem tenha informações sobre as coordenadas, cores e classificação de cada ponto na nuvem. Um ponto de destaque é que os dados do Geosampa foram usados apenas para treinamento do modelo, mas o algoritmo suporta qualquer conjunto de dados de nuvem de pontos que contenha informações de coordenadas e cores. Da mesma forma, o script pode classificar qualquer nuvem de pontos, desde que tenha informações de coordenadas e cores. Isso é particularmente útil para separar classes específicas em nuvens de pontos sobre grandes áreas, como nuvens obtidas por meio de levantamentos aéreos com drones.

Acredita-se que quanto mais representativo o conjunto de dados, com nuvens densas, melhor o aprendizado e, conseqüentemente, melhor a classificação das nuvens. Como perspectivas futuras deste estudo, pretende-se aprimorar o algoritmo e refinar os dados de entrada. Com a classificação mais definida, algoritmos de agrupamento de nuvens de pontos poderiam transformar cada objeto na nuvem em superfícies, conhecidas como malhas. A partir daí, elas poderiam ser transformadas em famílias do Revit, por exemplo. Não há necessidade de modelar esses objetos que não requerem parametrização. Isso tornaria o projeto mais fiel ao "real", sem a necessidade de busca de famílias Revit online, e economizaria tempo de modelagem.

O reconhecimento automático de objetos individuais em nuvens de pontos também será estudado utilizando uma combinação de algoritmos de segmentação e classificação, visto que apenas um algoritmo de classificação foi utilizado neste estudo. No entanto, adicionar segmentação ao processo facilita o reconhecimento de objetos de nuvem e a possibilidade de transformá-los em elementos BIM parametrizados, o que ainda representa um desafio em toda a literatura analisada. A intenção é tornar a modelagem BIM cada vez mais prática com o auxílio de nuvens de pontos. Neste trabalho, foram utilizadas apenas as informações de cor e coordenadas nas nuvens para tornar o algoritmo mais "universal" a qualquer formato de nuvem de pontos. Contudo, acredita-se que a utilização de outros parâmetros oriundos do escaneamento a laser também possa aprimorar o aprendizado, tendo em vista que facilitariam o reconhecimento de determinados padrões existentes nas camadas. Para trabalhos futuros, propõe-se também que o algoritmo seja adaptado apenas para nuvens de pontos de LiDAR e que os demais parâmetros sejam utilizados para avaliar o impacto que isso teria nos resultados obtidos.

REFERÊNCIAS

- BENSALAH, M.; ELOUADI, A.; MHARZI, H. Overview: the opportunity of BIM in railway. **Smart and Sustainable Built Environment**, v. 8, n. 2, p. 103–116, 2019.
- BOSCHÉ, F. et al. The value of integrating Scan-to-BIM and Scan-vs-BIM techniques for construction monitoring using laser scanning and BIM: The case of cylindrical MEP components. **Automation in Construction**, v. 49, p. 201–213, 1 jan. 2015.
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, out. 2001.
- CHOWDHURY, M. et al. Comprehensive analysis of BIM adoption: From narrow focus to holistic understanding. **Automation in Construction**, v. 160, p. 105301, 1 abr. 2024.
- CHUANG, T. Y.; YANG, M. J. Change component identification of BIM models for facility management based on time-variant BIMs or point clouds. **Automation in Construction**, v. 147, p. 104731, 1 mar. 2023.
- DIAB, A.; KASHEF, R.; SHAKER, A. Deep Learning for LiDAR Point Cloud Classification in Remote Sensing. **Sensors** **2022**, Vol. **22**, Page **7868**, v. 22, n. 20, p. 7868, 16 out. 2022.
- EBRAHIMI, M.; HOJAT JALALI, H.; SABATINO, S. Probabilistic condition assessment of reinforced concrete sanitary sewer pipelines using LiDAR inspection data. **Automation in Construction**, v. 150, p. 104857, 1 jun. 2023.
- LIAO, L. et al. Knowledge synthesis of intelligent decision techniques applications in the AECO industry. **Automation in Construction**, v. 140, p. 104304, 1 ago. 2022.
- MA, Y. et al. Point cloud-based optimization of roadside LiDAR placement at constructed highways. **Automation in Construction**, v. 144, p. 104629, 1 dez. 2022.
- O'DONNELL, J. et al. LiDAR point-cloud mapping of building façades for building energy performance simulation. **Automation in Construction**, v. 107, p. 102905, 1 nov. 2019.
- PARMAR, A.; KATARIYA, R.; PATEL, V. A Review on Random Forest: An Ensemble Classifier. **Lecture Notes on Data Engineering and Communications Technologies**, v. 26, p. 758–763, 2019.

- PURI, N.; TURKAN, Y. Bridge construction progress monitoring using lidar and 4D design models. **Automation in Construction**, v. 109, p. 102961, 1 jan. 2020.
- TAN, Y. et al. Automated geometric quality inspection for modular boxes using BIM and LiDAR. **Automation in Construction**, v. 164, p. 105474, 1 ago. 2024.
- TANG, S. et al. Skeleton-guided generation of synthetic noisy point clouds from as-built BIM to improve indoor scene understanding. **Automation in Construction**, v. 156, p. 105076, 1 dez. 2023.
- TEZEL, A.; PAPADONIKOLAKI, E.; YITMEN, I. Preparing Construction Supply Chains for Blockchain: An Exploratory Analysis. 2019.
- WANG, B. et al. Object verification based on deep learning point feature comparison for scan-to-BIM. **Automation in Construction**, v. 142, p. 104515, 1 out. 2022.
- WANG, J. et al. Integrating BIM and LiDAR for Real-Time Construction Quality Control. **Journal of Intelligent and Robotic Systems: Theory and Applications**, v. 79, n. 3–4, p. 417–432, 26 ago. 2015.
- XU, Y. et al. Machine learning in construction: From shallow to deep learning. **Developments in the Built Environment**, v. 6, p. 100045, 1 maio 2021.
- YIN, H.; LIN, Z.; YEOH, J. K. W. Semantic localization on BIM-generated maps using a 3D LiDAR sensor. **Automation in Construction**, v. 146, p. 104641, 1 fev. 2023.
- ZHAO, Y.; TAIB, N. Cloud-based Building Information Modelling (Cloud-BIM): Systematic literature review and Bibliometric-qualitative Analysis. **Automation in Construction**, v. 142, p. 104468, 1 out. 2022.