

# PCMAT-30: Classificação automática de materiais construtivos em nuvens de pontos

<https://doi.org/10.21814/uminho.ed.77.35>

**Luís Sanhudo<sup>1</sup>, Vasco Pinto<sup>2</sup>,  
João Poças Martins<sup>3</sup>, Nuno M. M. Ramos<sup>4</sup>**

<sup>1</sup> BUILT CoLAB – Collaborative Laboratory for the Future Built Environment, Portugal

<sup>2</sup> ASL – Engineering for People, Porto

<sup>3</sup> CONSTRUCT – Gequaltec, Faculdade de Engenharia da Universidade do Porto, Porto

<sup>4</sup> CONSTRUCT – LFC, Faculdade de Engenharia da Universidade do Porto, Porto

## Resumo

Nos últimos anos, a investigação em torno da classificação automática de materiais construtivos tem vindo a crescer em importância, graças aos seus comprovados benefícios no apoio à gestão de obra. Na sua maioria, trabalhos anteriores focados neste âmbito têm requerido a realização sistemática de levantamentos fotográficos em obra, por forma a suplementar modelos de visão computacional que interpretam e analisam as fotografias obtidas, classificando e quantificando os materiais existentes em estaleiro. Contudo, apesar destes modelos facultarem resultados com alta precisão, os requisitos computacionais a eles associados, bem como o esforço do levantamento fotográfico *in-situ*, restringem a utilização desta metodologia.

Para colmatar esta desvantagem, a tecnologia *laser scanning* tem sido proposta em substituição ao levantamento fotográfico, tornando o processo de levantamento de informação mais expedito e permitindo a utilização de modelos mais eficientes – tipicamente baseados em algoritmos de aprendizagem computacional tradicional.

Neste sentido, o presente artigo desenvolve uma base de dados de materiais obtidos por *laser scanning*, com o objetivo de possibilitar o contínuo desenvolvimento desta nova metodologia. O artigo apresenta ainda testes preliminares para a classificação dos materiais da base de dados, sendo obtida precisão de 98,42% – valor na ordem de grandeza da abordagem por levantamento fotográfico.

## 1. Introdução

A classificação automática de materiais construtivos tem vindo a crescer, ao longo dos últimos anos, como tópico de investigação na indústria da Arquitetura, Engenharia e Construção (AEC). Esta é aplicada em múltiplas vertentes da indústria, desde a gestão, quantificação e localização de materiais em obra, até ao apoio no desenvolvimento de modelos *Building Information Modelling* (BIM) *as-is*, através do fornecimento de dados relevantes para criação de *renderings* realistas ou execução de simulações energéticas [1, 2].

Para automatizar esta classificação, a literatura tem focado a adoção de técnicas de aprendizagem computacional, tendo, como dados de *input*, imagens de cor obtidas por levantamento fotográfico. Contudo, esta abordagem apresenta ainda múltiplas desvantagens, nomeadamente ao nível da aquisição das imagens *in-stu*, da influência das condições atmosféricas e de iluminação, do baixo desempenho na classificação de materiais com pouca textura e, por fim, dos elevados requisitos computacionais.

Tendo por objetivo contribuir para a expansão desta investigação, o presente artigo explora uma segunda opção, na qual os dados de *input* são nuvens de pontos obtidas por *laser scanning*. Neste sentido, é desenvolvido um *dataset* de nuvens de pontos de materiais, denominado PCMat-30, e são apresentados e testados múltiplos algoritmos para a sua classificação.

Além da presente secção introdutória, o artigo encontra-se dividido em quatro secções: a Secção 2 apresenta trabalhos anteriores focados nas temáticas abordadas; a Secção 3 demonstra a metodologia utilizada no desenvolvimento do presente artigo, desde a criação do *dataset* PCMat-30 à identificação dos classificadores a testar; a Secção 4 apresenta e discute os resultados da classificação do *dataset*; e, por fim, a Secção 5 apresenta as principais conclusões.

## 2. Estado da Arte

A utilização de imagens como *input* para a classificação de materiais com recurso a aprendizagem computacional é, atualmente, o método predominante na literatura. São vários os exemplos da sua aplicação. Por exemplo, Son et al. [3] utilizam a informação da cor de imagens fotográficas na avaliação de múltiplos algoritmos de classificação simples, bem como *ensembles*, para classificação de betão, aço e madeira. Noutro estudo, Han e Golparvar-Fard [4] classificam segmentos de imagens quadrangulares em 15 materiais distintos, agregando, para isso, informação relativa à cor e textura do segmento. De forma semelhante, em [5], os autores extraem a cor e textura de imagens de 200×200 *pixels*, para classificar 20 materiais tipicamente encontrados em obra através de *Support Vector Machines* (SVM).

Contudo, esta abordagem apresenta múltiplas desvantagens, como [6]: significativa dependência das condições atmosféricas e de iluminação; reduzida robustez face a ângulos de imagem não-treinados; baixo desempenho face a materiais de reduzida


textura; e elevados requisitos computacionais associados aos algoritmos de visão computacional, tipicamente usados nesta abordagem. Adicionalmente, uma vez que as câmaras de videovigilância em estaleiro apresentam frequentes problemas de obstrução, baixa resolução e falta de cor, é necessário a realização de levantamentos fotográficos periódicos para implementação desta solução num contexto real – o que pode ser um processo moroso e caro.

Neste sentido, a utilização, como *input*, de nuvens de pontos capturadas por *laser scanning* apresenta-se como alternativa à solução atual. Apesar de conter menos literatura, esta abordagem tem vindo a crescer progressivamente em popularidade, devido às suas vantagens em relação ao uso de imagens. As vantagens incluem [1, 2, 7]: maior robustez a variações atmosféricas e de luminosidade; aquisição de mais propriedades intrínsecas do material (i.e., refletividade obtida por análise dos valores de intensidade da nuvem de pontos); e a dispensa de obtenção de nuvens de pontos especificamente para identificação de materiais, devido à sua prévia aquisição para acompanhamento de obra ou criação de modelos BIM *as-is*.

Seguindo esta abordagem, Franceschi et al. [8] focam a classificação de duas rochas sedimentares, utilizando para isso a intensidade da nuvem de pontos. Noutro estudo, Riveiro et al. [9] apresentam um algoritmo inovador para identificação de blocos de alvenaria. Hassan et al. [10] utilizam a cor e intensidade da nuvem de pontos para classificação de três materiais diferentes: betão de estrutura, betão leve e tijolos de argila. Neste estudo, os autores extraíram a refletividade de cada material através dos valores de intensidade, identificando variações desta propriedade em cada um dos materiais estudados. Por fim, Yuan et al. [11] testaram cinco classificadores distintos com 10 materiais diferentes, obtendo uma precisão de classificação de 96,7%. Para *input* dos algoritmos, os autores extraíram, por ponto, três características principais, nomeadamente, a sua rugosidade, reflexão e cor.

### 3. Metodologia


O presente artigo teve como objetivo contribuir para a investigação no âmbito da utilização de nuvens de pontos como *input* de algoritmos de classificação de materiais. Neste sentido, os esforços focaram a expansão do trabalho apresentado por Yuan et al. [11], em múltiplas vertentes, nomeadamente: (1) expansão do número de materiais captados; (2) expansão do número de classificadores testados; e (3) incremento da dificuldade de classificação através da diversificação das nuvens de pontos do *dataset*. Adicionalmente, foi também realizado um refinamento do processo de extração das três características principais, utilizando, para isso, a biblioteca *Scikit-learn* [12] em alternativa às equações apresentadas no trabalho original. Para concretização destes pontos, foi adotada a metodologia apresentada na Figura 1. O desenvolvimento do *dataset* é abordado na Secção 3.1, enquanto a extração das características principais e os algoritmos de classificação são abordados na Secção 3.2.



**Figura 1**  
Metodologia adotada no desenvolvimento do presente artigo.

### 3.1. PCMat-30

Como identificado na introdução, o *dataset* desenvolvido neste artigo é intitulado PCMat-30 ou 30 *Point Cloud Materials*. Este *dataset* é composto por 30 materiais distintos (Tabela 1), obtidos com o *laser scanner Leica ScanStation P20*. A resolução e qualidade utilizadas durante a aquisição das nuvens de pontos foram, respectivamente, 0,8mm@10m e quatro, sendo que os materiais foram obtidos a uma distância inferior a 10 metros, garantindo uma resolução final sub 0,8mm. A resolução fotográfica escolhida foi de 640×640 e as definições de luminosidade foram ajustadas conforme a localização. Mais informação sobre estes parâmetros em [13].




**Tabela 1**  
Exemplos de nuvens de pontos obtidas para cada material.

Assim, a informação por ponto do *dataset* inclui: coordenadas X, Y, Z; cor R, G, B; e intensidade I. Para cada um dos 30 materiais, foram obtidas três nuvens de pontos sobre condições distintas, resultando na aquisição de 90 nuvens de pontos. Para tornar distintas as condições de aquisição, quando possível, foram alterados, por material, vários aspetos: luminosidade (e.g., interior vs exterior de um edifício); ângulo de incidência e plano primário (e.g., muro vs chão de pedra); cor (e.g., tapete azul vs vermelha); padrão (e.g., diferentes estilos de tijolo do mesmo material); tamanho (e.g., perna delgada vs largo tampo de madeira); entre outros. Algumas destas condições são visíveis na Tabela 2.

Posteriormente, cada uma das 90 nuvens de pontos obtidas foram modificadas para expansão artificial do *dataset* e, conseqüentemente, diversificação do mesmo. As modificações incluem:

- Dizimação das nuvens de pontos de sub 0,8mm para três resoluções distintas: 3,1mm; 6,3mm; e 12,5mm; obtendo 270 nuvens de pontos.
- Subdivisão das nuvens obtidas em cinco parcelas de diferentes tamanhos, obtendo 1350 nuvens de pontos;
- Modificação da luminosidade conforme cinco níveis diferentes  $\{-10, -5, 0, 5, 10\}$ %, obtendo 6750 nuvens de pontos;
- E, por fim, implementação de quatro níveis distintos de *random dropout*  $\{0, 5, 10, 15\}$ %, culminando em 27000 nuvens de pontos.

**Tabela 2**  
Exemplos de condições distintas do mesmo material.



Algumas destas modificações podem ser observadas na Tabela 3. De realçar que a redução de resolução e a utilização de *random dropout* (RDp) são intrinsecamente diferentes, uma vez que a primeira reduz o número de pontos de forma sistemática, enquanto a segunda é aleatória.

Res.	3,1mm		6,3mm	12,5mm
RDp	0%	15%	0%	0%

  
**Tabela 3**

Algumas das modificações criadas durante a expansão artificial do dataset.

### 3.2. Obtenção de características e identificação dos classificadores a testar

O código original proposto em [11] encontra-se escrito em *MATLAB* e foi obtido por contacto com os autores. Para aquisição das características previamente mencionadas (rugosidade, refletividade e cor), os autores utilizam as equações apresentadas em [11], sem recurso a qualquer tipo de *package* característico desta linguagem. Ou seja, passos identificados em [11] como aquisição de pontos-vizinhos, regressões lineares, cálculo de planos e mudança de sistema de cores, encontram-se todos implementados de raiz. Neste sentido, por forma a acelerar o processo de extração destas características, o código foi reescrito em *Python*, utilizando algoritmos otimizados da biblioteca *Sckit-learn* [12], como: *KdTree*, *Random Sample Consensus*, *LinearRegression* e *rgb2hsv*. A aceleração obtida permitiu a ampliação do raio para aquisição de pontos-vizinhos, melhorando significativamente o cálculo da rugosidade e refletividade de cada ponto.

Com as características obtidas, foram identificados 10 classificadores a serem testados. Estes incluem cinco classificadores tradicionais: *SVM*, *Logistic Regression*, *Multi-layer Perceptron*, *k-Nearest Neighbours*, e *Decision Tree*; bem como cinco *ensembles*: *AdaBoost*; *Extremely Randomized Forest*; *Gradient Boosting*; *Random Forest*; e *Voting*. Novamente, para a implementação destes classificadores foi utilizada a biblioteca *Sckit-learn* [12].

## 4. Classificação do PCMat-30

Com o *dataset* criado, as características calculadas e os classificadores escolhidos, procedeu-se ao treino e teste dos algoritmos. Neste sentido, foram testadas duas *splits* distintas para classificação do PCMat-30, como visível na Tabela 4.

A primeira tem como objetivo a seleção do melhor classificador de entre os algoritmos identificados na Seção 3.2, utilizando, para isso, as 1350 nuvens de pontos obtidas após parcelamento das nuvens originais em diferentes tamanhos. Esta *split* divide os dados de treino e teste em, respectivamente, 80% e 20%, resultando em 1080 nuvens para treino e 270 para teste. O mesmo protocolo aplicado em [13] é usado para seleção de hiper-parâmetros.

A segunda *split* tem como objetivo a avaliação do melhor classificador num ambiente de acrescida dificuldade, no qual são adicionados aos dados de teste as respectivas nuvens de pontos com diferentes níveis de luminosidade e *random dropout*. Ou seja, como esta expansão dos dados de teste não é reproduzida nos dados de treino, o algoritmo selecionado é testado em condições de luminosidade e *random dropout* desconhecidas.

Em termos de métricas de avaliação, foram utilizadas a precisão global ( $oAcc$ ) e média ( $mAcc$ ):

$$oAcc = \frac{\text{Previsões Corretas}}{\text{Total de Previsões}} \times 100 \quad (1)$$

$$mAcc = \frac{\sum_S^m (\text{Previsões Corretas}_S / \text{Total de Previsões}_S)}{m} \times 100 \quad (2)$$

onde  $m$  representa o total de classes semânticas (i.e., materiais) do *dataset* PCMat-30 e  $S$  representa a classe semântica avaliada.

**Tabela 4**  
Splits testadas para  
classificação do *dataset*  
PCMat-30.

Split #	Treino	Teste
1	1080 nuvens de pontos de diferentes resoluções e tamanhos, mas mesmo nível de luminosidade e <i>random dropout</i> (i.e., 0%)	270 nuvens de pontos de diferentes resoluções e tamanhos, mas mesmo nível de luminosidade e <i>random dropout</i> (i.e., 0%)
2	nuvens de pontos de diferentes resoluções e tamanhos, mas mesmo nível de luminosidade e <i>random dropout</i> (i.e., 0%)	5400 (i.e., 270×5×4) nuvens de pontos de diferentes resoluções e tamanhos, bem como diferentes níveis de luminosidade {-10, -5, 0, 5, 10}% e <i>random dropout</i> {0, 5, 10, 15}%

A Tabela 5 apresenta os resultados da primeira *split*. As Tabelas 6, 7 e 8 apresentam os resultados da segunda *split*.

Focando a primeira *split*, à parte do classificador SVM e *Logistic Regression*, os restantes algoritmos obtiveram precisões melhores que 96,51% e 94,94%, respectivamente para a precisão global e média. O *Random Forest* foi considerado o melhor classificador por apresentar a melhor precisão global (98,42%) e a segunda melhor precisão média (97,75%), para além de ser considerado, pela literatura, como robusto face a *datasets* de elevado número de classes – assegurando a possibilidade de expansão do PCMat-30. Estas precisões são melhores que as apresentadas por [11], apesar do



número acrescido de materiais. Este ganho pode ser justificado pela melhoria do cálculo da rugosidade e refletividade (Secção 3.2), bem como pelo uso do *Random Forest*, algoritmo não testado em [11].

Classificador	oAcc (%)	mAcc (%)
Support Vector Machine	59,30	52,01
Logistic Regression	72,29	50,51
Multilayer Perceptron	96,51	94,94
k-Nearest Neighbours	97,75	96,67
Decision Tree	97,78	96,90
AdaBoost	98,16	97,39
Gradient Boosting	98,38	<b>97,81</b>
Voting	98,38	97,52
Extremely Randomized Forest	98,39	97,61
Random Forest	<b>98,42</b>	97,75

**Tabela 5**

Resultados da classificação para os algoritmos escolhidos e os dados da primeira *split*.

No que diz respeito à segunda *split*, por análise das Tabelas 6, 7 e 8 é possível concluir que o algoritmo *Random Forest* mantém boas precisões de classificação, obtendo médias mínimas de 97,78% para a precisão global e 94,58% para a precisão média, ambas relativas à resolução de 12,5mm (Tabela 6). Como médias máximas, foi obtida a precisão global de 98,99% e média de 98,22%, referentes à resolução de 3,1mm. Assim, é possível concluir que a resolução da nuvem afeta significativamente as precisões obtidas, com resoluções inferiores a originarem piores precisões.

De forma semelhante, o *random dropout* também afeta significativamente as precisões, apresentando reduzidas precisões para maiores percentagens de *dropout*. Contudo, o algoritmo aparenta ser mais robusto a este tipo de ruído, uma vez que, o *random dropout* máximo testado (15%), resulta em perdas de apenas 0,13% de precisão global.

Por fim, focando a Tabela 8, é possível concluir que a luminosidade não apresenta grande influência sobre a precisão dos resultados, uma vez que esta permanece praticamente constante ao longo das diferentes luminosidades testadas.

Resolução (mm)	oAcc (%)	mAcc (%)
3,1	98,99	98,22
6,3	98,61	97,01
12,5	97,78	94,58

**Tabela 6**

Média, por resolução, dos resultados da classificação para o algoritmo *Random Forest* e os dados da segunda *split*.

Random Dropout (%)	oAcc (%)	mAcc (%)
0	98,53	96,73
5	98,48	96,64
10	98,41	96,51
15	98,40	96,54

**Tabela 7**

Média, por *random dropout*, dos resultados da classificação para o algoritmo *Random Forest* e os dados da segunda *split*.

**Tabela 8**

Média, por luminosidade, dos resultados da classificação para o algoritmo *Random Forest* e os dados da segunda *split*.

Nível de Luminosidade (%)	<i>oAcc</i> (%)	<i>mAcc</i> (%)
-10	98,45	96,58
-5	98,47	96,65
0	98,47	96,66
+5	98,43	96,51
+10	98,47	96,63

## 6. Conclusões

O presente artigo teve como objetivo contribuir para a automatização da classificação de materiais construtivos por nuvens de pontos. Neste sentido, o artigo focou a continuação de um estudo anterior por Yuan et al. [11], duplicando os classificadores a serem testados e triplicando os materiais a serem identificados (materiais incluídos no *dataset* desenvolvido). Adicionalmente, a diversidade de aquisição dos materiais foi aumentada, dificultando a capacidade de classificação. Por fim, a metodologia para extração de *features* proposta em [11] foi refinada, através da utilização de algoritmos otimizados da biblioteca *Sckit-learn*.

Durante o caso de estudo foram obtidas precisões na ordem dos 98% para o classificador *Random Forest*, superando a precisão de 96,7% demonstrada por Yuan et al. [11], apesar das condições mais adversas. A obtenção desta grandeza de precisão suporta a contínua investigação da classificação automática de materiais construtivos com recursos a nuvens de pontos, como alternativa à abordagem mais comum de utilização de imagens RGB.

Como trabalhos futuros está planeada a expansão do *dataset* PCMat-30, não só através da aquisição de novos materiais por parte do autor, mas também através da disponibilização *online* do *dataset*. Este será acompanhado por guias que especifiquem os procedimentos a seguir para aquisição de novos materiais e introdução dos mesmos no *dataset*. Ao longo da expansão do *dataset*, os algoritmos de aprendizagem computacional aqui apresentados continuarão a ser testados e reavaliados face à expansão.

## 7. Agradecimentos

Este trabalho foi financiado por: Financiamento Base – UIDB/04708/2020 e Financiamento programático – UIDP/04708/2020 da Unidade de Investigação CONSTRUCT – Instituto de I&D em Estruturas e Construções – financiada por fundos nacionais através da FCT/MCTES (PIDDAC). Este trabalho é também cofinanciado pelo Fundo Social Europeu (FSE), através do Programa Operacional Regional do Norte (Norte 2020) [Referência de Financiamento: NORTE-06-3559-FSE-000176].

## Referências

- [1] J. DeGol, M. Golparvar-Fard e D. Hoiem, “Geometry-informed material recognition”, em *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Estados Unidos da América, 2016
- [2] Q. Lu e S. Lee, “Image-based technologies for constructing as-is building information models for existing buildings”, *Journal of Computing in Civil Engineering*, vol. 31, 2017
- [3] H. Son, C. Kim, N. Hwang, C. Kim e Y. Kang, “Classification of major construction materials in construction environments using ensemble classifiers”, *Advanced Engineering Informatics*, vol. 28, 2014.
- [4] K. K. Han, M. Golparvar-Fard, “Appearance-based material classification for monitoring of operation-level construction progress using 4D BIM and site photologs”, *Automation in Construction*, vol. 53, 2015.
- [5] A. Dimitrov e M. Golparvar-Fard, “Vision-based material recognition for automated monitoring of construction progress and generating building information modeling from unordered site image collections”, *Advanced Engineering Informatics*, vol. 28, 2014.
- [6] Q. Lu, S. Lee e L. Chen, “Image-driven fuzzy-based system to construct as-is IFC BIM objects”, *Automation in Construction*, vol. 92, 2018.
- [7] S. Y. Chen, Y. F. Li, W. Wang e J. Zhang, *Active sensor planning for Multiview vision tasks*, Springer, 2008.
- [8] M. Franceschi, G. Teza, N. Preto, A. Pesci, A. Galgaro e S. Girardi, “Discrimination between marls and limestones using intensity data from terrestrial laser scanner”, *Journal of Photogrammetry and Remote Sensing*, vol. 64, 2009.
- [9] B. Riveiro, P. B. Lourenço, D. V. Oliveira, H. González Jorge e P. Arias, “Automatic morphologic analysis of quasi-periodic masonry walls from LiDAR”, *Computer-Aided Civil and Infrastructure Engineering*, vol. 31, 2016.
- [10] M. U. Hassan, A. Akcamete-Gungor e C. Meral, “Investigation of terrestrial laser scanning reflectance intensity and RGB distributions to assist construction material identification, lean and computing in construction congress”, em *Proceedings of the Joint Conference on Computing in Construction*, 2017.
- [11] Y. Liang, J. Guo e Q. Wang, “Automatic classification of common building materials from 3D terrestrial laser scan data”, *Automation in Construction*, vol. 110, 2020.

- [12] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot e E. Duchesnay, “Scikit-Learn: Machine Learning in Python”, *Journal of Machine Learning Research*, vol. 10, 2011.
  
- [13] L. Sanhudo, “Artificial Intelligence for an Enhanced As-Is BIM Energy Analysis – Enabling an efficient energy retrofit through the automation of the scan-to-BIM process”, Tese de Doutoramento, Porto, Faculdade de Engenharia da Universidade do Porto, Portugal, 2021.