



# CLASSIFICAÇÃO AUTOMÁTICA DE PARTÍCULAS DE RESÍDUO DE CONSTRUÇÃO E DEMOLIÇÃO POR ANÁLISE DIGITAL DE IMAGENS<sup>1</sup>

Daisiana Frozi Brisola<sup>2</sup>  
Bruna Maria da Cunha<sup>3</sup>  
Otávio da Fonseca Martins Gomes<sup>4</sup>  
Paulo Roberto Lopes Lima<sup>5</sup>  
Sidnei Paciornik<sup>6</sup>

## Resumo

Os resíduos de construção e demolição (RCD) tornaram-se, em todo mundo, um dos principais problemas ambientais das cidades. A classificação e separação das partículas de RCD constituem-se na principal dificuldade para sua reciclagem. O presente trabalho propõe uma metodologia para a classificação de partículas de RCD que consiste em um típico sistema de classificação supervisionada. Ele utiliza parâmetros de forma, tamanho e textura para discriminar partículas de RCD provenientes de argamassa, cerâmica e concreto, observadas por microscopia eletrônica de varredura. O sistema de classificação foi testado com relativo sucesso, a taxa de acerto total atingiu 73,96% e as taxas de acerto para as classes argamassa e cerâmica foram maiores que 80%. A principal limitação encontrada foi o reconhecimento da classe concreto, o melhor resultado obtido para sua taxa de acerto foi de apenas 56,30%.

**Palavras-chave:** Resíduo de construção e demolição; Classificação supervisionada; Análise de imagens.

## AUTOMATIC CLASSIFICATION OF PARTICLES FROM CONSTRUCTION AND DEMOLITION WASTE THROUGH DIGITAL IMAGE ANALYSIS

### Abstract

Construction and demolition waste (CDW) has become one of the most important environmental problems in large and medium-sized cities around the world. The classification and segregation of CDW particles constitute the main difficulties for their recycling. The present paper proposes a methodology for classification of particles from CDW that consists in a typical supervised classification procedure. It uses size, shape and texture description parameters to discriminate between CDW particles from mortar, ceramic and concrete observed with scanning electron microscopy. The classification system reaches a reasonable success. The total success rate obtained was 73.96% and the success rates for mortar and ceramic were greater than 80%. The main limitation was the recognition of the concrete particles; the best result obtained for its success rate was 56.30%.

**Key-words:** Construction and demolition waste; Supervised classification; Image analysis.

<sup>(1)</sup> Engenheira Química, mestranda – DEMa/PUC-Rio

<sup>(2)</sup> Arquiteta, mestranda – DEMa/PUC-Rio

<sup>(3)</sup> Engenheiro Químico, D.Sc. – CETEM/MCT

<sup>(4)</sup> Engenheiro Civil, D.Sc. – DT/UEFS

<sup>(5)</sup> Engenheiro Eletrônico e Físico, D.Sc. – DEMa/PUC-Rio

## 1 INTRODUÇÃO

A crescente quantidade de resíduos sólidos oriundos da construção civil em cidades de médio e grande porte tem sido fonte de preocupação em todo o mundo devido a aspectos ambientais, econômicos e até mesmo sociais.<sup>(1,2)</sup> No Brasil, os resíduos de construção e demolição (RCD) representam cerca de 50% dos resíduos sólidos urbanos, sendo cerca de 90% de origem mineral.<sup>(3)</sup> Assim, a reutilização e reciclagem desse tipo de resíduo têm despertado grande interesse.

A substituição de agregados naturais por agregados obtidos de RCD é uma das mais promissoras alternativas. No entanto, agregados reciclados ainda não são largamente empregados devido, principalmente, à heterogeneidade da composição dos RCD. As principais dificuldades da reciclagem de RCD são a classificação e a separação dos constituintes dos resíduos.

O presente trabalho propõe uma metodologia para a classificação de partículas de RCD, baseada em microscopia eletrônica de varredura (MEV) e análise digital de imagens, capaz de distinguir partículas de RCD provenientes de diferentes materiais. Foram analisadas amostras de RCD de argamassa, cerâmica e concreto, a fim de se buscar parâmetros quantitativos que sirvam de atributos em um sistema de classificação automática.

Sistemas de análise de imagens podem facilmente segmentar seções de partículas de RCD, através de seus níveis de intensidade, em imagens adequadas adquiridas ao MEV. O desafio está em compor ou projetar um conjunto de características que agrupe partículas da mesma classe, aceitando sua variabilidade intrínseca, e que, ao mesmo tempo, propicie a discriminação entre as classes. Na prática, uma única característica raramente é suficiente neste tipo de problema. Assim, no presente estudo de caso, diversos parâmetros descritores de forma, tamanho e textura foram testados no sistema de classificação.

## 2 MATERIAIS E MÉTODOS

### 2.1 Seleção e Preparação de Amostras

Três amostras de RCD, provenientes de argamassa, cerâmica e concreto, foram classificadas em série de peneiras. Alíquotas representativas das frações de 125  $\mu\text{m}$  a 250  $\mu\text{m}$  e de 250  $\mu\text{m}$  a 500  $\mu\text{m}$  de cada amostra foram embutidas em resina epóxi, lixadas e polidas de acordo com a preparação metalográfica tradicional. Por fim, os seis corpos de prova foram recobertos com carbono, com o metalizador Bal-Tec SCD 005, para tornarem-se condutores, adequados à análise ao MEV.

### 2.2 Aquisição de Imagens

Um MEV LEO S440 com platina motorizada foi empregado para a aquisição automática das imagens. Para cada amostra, 70 campos regularmente espaçados foram adquiridos, utilizando-se o detector de elétrons retro-espalhados. A magnificação utilizada foi de 100x para as amostras com granulometria entre 500 e 250  $\mu\text{m}$ , e de 200x para as amostras entre 250  $\mu\text{m}$  e 125  $\mu\text{m}$ , resultando em resoluções de 3,07  $\mu\text{m}/\text{pixel}$  e 1,54  $\mu\text{m}/\text{pixel}$ , respectivamente. Assim, no total, foram adquiridas 420 imagens (1024x768 pixels) e 17.756 partículas. A Figura 1 apresenta

imagens típicas de RCD de argamassa, cerâmica e concreto, obtidas como descrito acima.

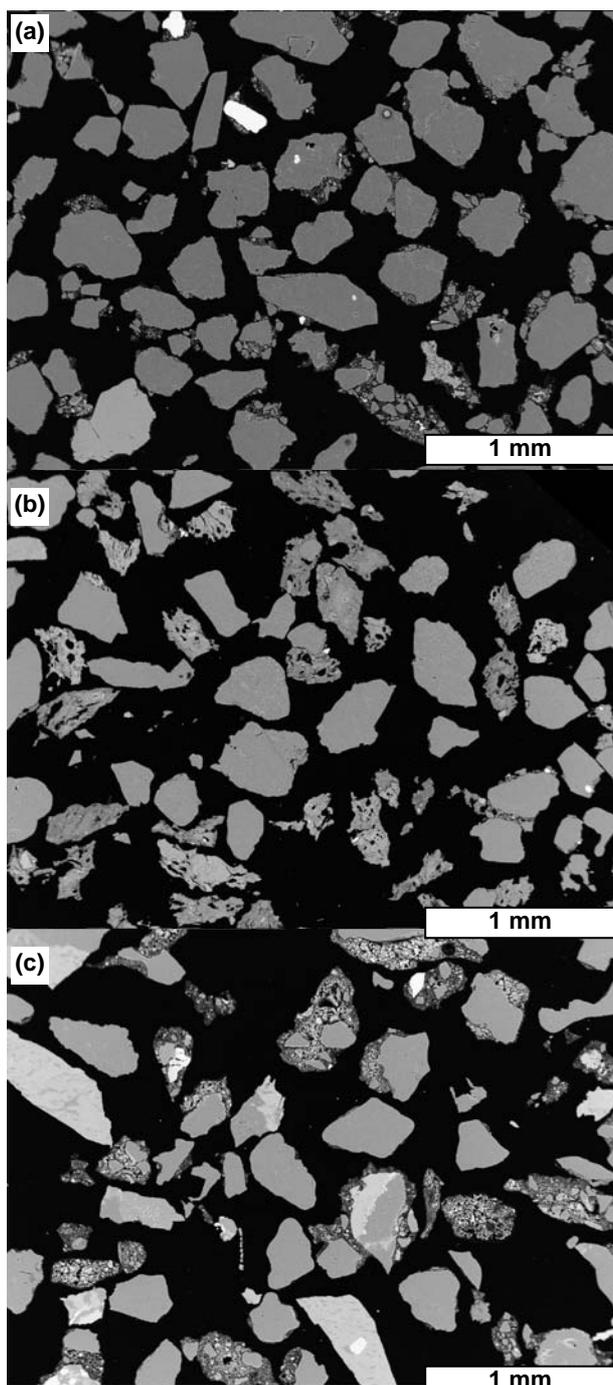


Figura 1 – Imagens típicas de RCD de: (a) argamassa; (b) cerâmica; e (c) concreto.

### 2.3 Análise de Imagens

O procedimento de análise de imagens, assim como o projeto e teste do sistema de classificação, foi realizado através de uma rotina implementada como macro no software Zeiss KS 400. A rotina seguiu a seqüência padrão de análise de imagens,<sup>(4)</sup> sendo composta pelas seguintes etapas:

- a) segmentação das partículas através da limiarização do histograma de intensidades das imagens, usando um limiar fixo;



- b) separação das partículas que se tocam, pelo método dos divisores de águas;<sup>(5)</sup>
- c) pós-processamento lógico e morfológico para eliminar objetos espúrios, partículas muito pequenas e partículas nas bordas da imagem;
- d) extração de atributos; e
- e) classificação.

O cuidadoso ajuste das condições operacionais do MEV garantiu a reprodutibilidade do brilho e contraste das imagens adquiridas. Assim, o limiar de intensidade foi estabelecido interativamente e então fixado para todas as imagens.

A etapa de extração de atributos consistiu na medição de parâmetros descritores de forma, tamanho e textura de cada partícula obtida. A Tabela 1 lista os fatores de forma utilizados e suas definições. Os parâmetros de tamanho empregados foram área e calibre máximo (Feret máximo). A textura foi medida através da média e do desvio padrão dos níveis de intensidade das partículas e dos chamados parâmetros de Haralick,<sup>(6)</sup> que são medidas estatísticas da co-ocorrência de níveis de intensidade em pixels vizinhos. Especificamente, foram usados os onze primeiros parâmetros de Haralick.

**Tabela 1** – Fatores de forma

Nome	Definição <sup>a</sup>
Solidez	$S = \frac{A}{A_c}$
Convexidade	$Conv = \frac{P_c}{P}$
Fator de Forma Circular	$FFC = \frac{4 \cdot \pi \cdot A}{P^2}$
Circularidade	$C = \frac{4 \cdot A}{\pi \cdot F_{max}^2}$
Razão de Aspectos	$RA = \frac{F_{min}}{F_{max}}$

a. Notação: A: área, A<sub>c</sub>: área convexa, P: perímetro, P<sub>c</sub>: perímetro convexo, F<sub>min</sub>: Feret mínimo, F<sub>max</sub>: Feret máximo.

A classificação foi supervisionada.<sup>(7)</sup> Os parâmetros de forma, tamanho e textura foram utilizados como características e um classificador de Bayes<sup>(7)</sup> foi empregado para reconhecer as três classes de RCD (argamassa, cerâmica e concreto). O classificador foi treinado e validado com as próprias imagens das amostras, em um procedimento de auto-validação.<sup>(8)</sup> Foram realizados quatro treinamentos, variando-se as características usadas: parâmetros de forma; de forma e tamanho; de textura; e todos os parâmetros medidos.

### 3 RESULTADOS E DISCUSSÃO

A Tabela 2 apresenta os resultados da validação do sistema de classificação. Ela mostra as taxas de acerto obtidas na classificação das partículas de RCD nos quatro diferentes treinamentos. A segunda, a terceira e a quarta coluna exibem, respectivamente, as taxas de acerto dos treinamentos em que o conjunto de

características foi composto pelos parâmetros de forma, forma e tamanho, e textura. Na última coluna, as taxas de acerto referem-se ao treinamento realizado utilizando-se todos os parâmetros testados.

**Tabela 2** – Resultados da validação

Classe	Taxa de Acerto (%)			
	Forma	Forma e Tamanho	Textura	Todos os parâmetros
Argamassa	55,00	55,60	80,94	80,91
Cerâmica	37,65	43,82	83,67	82,85
Concreto	40,26	40,15	52,02	56,30
Total	44,47	46,77	72,95	73,96

Usando somente parâmetros de forma no conjunto de características, a taxa de acerto total foi muito baixa (44,47%). A adição de parâmetros de tamanho a esse conjunto de características também não foi capaz de propiciar uma melhora significativa na taxa de acerto (46,77%). Esses resultados indicam que não há diferença de forma relevante entre as classes de partículas de RCD.

Por outro lado, ao empregarem-se somente os parâmetros de textura, como conjunto de características, a taxa de acerto total obtida foi bem mais alta (72,95%). Além disso, as taxas de acerto para as classes argamassa e cerâmica ficaram acima de 80%. De fato, como pode ser observado na Figura 1, as partículas das diferentes classes têm textura claramente diversa.

Utilizando-se todos os parâmetros testados, como características, a taxa de acerto total atingiu 73,96% e as taxas de acerto para as classes argamassa e cerâmica, apesar de uma pequena queda, mantiveram-se altas, acima de 80%. Todavia, a taxa de acerto para classe concreto subiu, mas ainda permaneceu muito baixa (56,30%). A Tabela 3 apresenta a matriz de confusão do sistema de classificação com o conjunto de características formado por todos os parâmetros testados. A segunda linha mostra como as 6.155 partículas de RCD de argamassa foram classificadas: 4945 foram corretamente classificadas como argamassa e as demais foram erroneamente classificadas como cerâmica (534) e concreto (633). A terceira e a quarta linha referem-se, do mesmo modo, respectivamente, às partículas de RCD de cerâmica e concreto.

**Tabela 3** – Matriz de confusão

Classe	Argamassa	Cerâmica	Concreto	Total
Argamassa	4.945	534	633	6.155
Cerâmica	415	5.035	627	6.132
Concreto	1.182	1.208	3.079	5.469
Total	6.542	6.777	4.339	17.756

Conforme mostrado na Tabela 3, o erro na classificação das partículas de concreto ocorre devido ao sistema atribuir a elas tanto a classe argamassa quanto a classe cerâmica.

#### 4 CONCLUSÃO

Um sistema automático de classificação de partículas de RCD foi desenvolvido e testado com relativo sucesso. A taxa de acerto total atingiu 73,96% e as taxas de acerto para as classes argamassa e cerâmica foram maiores que 80%.

Os parâmetros de forma foram insuficientes para diferenciar as classes. O uso de parâmetros de textura foi fundamental para o bom desempenho do sistema de classificação.

A principal limitação encontrada foi o reconhecimento da classe concreto. O melhor resultado obtido para sua taxa de acerto foi baixa (56,30%).

Como os parâmetros de Haralick se baseiam na co-ocorrência de tonalidades em pares de pixels, seus valores dependem da distância entre estes pixels. No presente estudo esta distância foi mantida em 1 pixel. É possível que o uso de distâncias maiores leve a um aumento das taxas de acerto, dependendo da escala típica associada à textura de cada um dos materiais. Outros testes deverão ser realizados para verificar o impacto destas mudanças.

Outras medidas de textura, tais como aquelas baseadas em *wavelets*<sup>(9)</sup> podem também ser testadas.

É possível que a discriminação esteja intrinsecamente limitada pela técnica de microscopia utilizada. Neste sentido, pode ser interessante combinar os resultados obtidos com os de microscopia óptica, em um procedimento típico de microscopia co-localizada MO-MEV conforme proposto por Gomes<sup>(10)</sup> e Gomes e Paciornik<sup>(11-13)</sup> para classificação de minérios.

A metodologia empregada no presente trabalho pode ser aplicada ao estudo de outros materiais em que algum tipo de classificação de partículas seja necessário.

#### Agradecimentos

Daisiana Frozi Brisola agradece ao programa PIBIC/CNPq e ao CETEM pela bolsa de iniciação científica.



## REFERÊNCIAS

- 1 MOTTA, R.S. **Estudo laboratorial de agregado reciclado de resíduo sólido da construção civil para aplicação em pavimentação de baixo volume de tráfego.** 2005. 134 f. Dissertação (Mestrado em Engenharia de Transportes) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2005.
- 2 RAO, A.; JHA, K.N.; MISRA, S. Use of aggregates from recycled construction and demolition waste in concrete. **Resources, Conservation and Recycling**, v. 50, p. 71-81, 2005.
- 3 ANGULO, S.C. **Caracterização de agregados de resíduos de construção e demolição reciclados e a influência de suas características no comportamento de concretos.** 2005. 167 f. Tese (Doutorado em Engenharia) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2005.
- 4 GONZALEZ, R.C.; WOODS, R.E. **Digital Image Processing.** 2. ed. Upper Saddle River: Prentice-Hall, 2002.
- 5 BEUCHER, S.; LANTUÉJOUL, C. Use of watersheds in contour detection. In: Proceedings of International Workshop on Image Processing, Real-time Edge and Motion detection/estimation, Rennes (França). 1979. p. 2.1-2.12.
- 6 HARALICK, R.M.; SHANMUGAM, K.; DINSTEN, I. Textural Features for Image Classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 3, n. 6, p. 610-621, 1973.
- 7 DUDA, R.O.; HART, P.E.; STORK, D.G. **Pattern classification.** 2 ed. Wiley-Interscience, 2001.
- 8 TOUSSAINT, G.T. Bibliography on estimation of misclassification. **IEEE Transactions on Information Theory**, v. 20, p. 472-479, 1974.
- 9 TEIXEIRA, G.N.; FEITOSA, R.Q.; PACIORNIK, S. Towards Automatic Painting Authentication. In: IAPR Workshop on Machine Vision Applications, 2002, Nara. Proceedings of MVA 2002, 2002. p. 530-533.
- 10 GOMES, O.D.M. **Microscopia Co-Localizada: Novas Possibilidades na Caracterização de Minérios.** 2007. 103 f. Tese (Doutorado em Engenharia Metalúrgica e de Materiais) – Departamento de Ciência dos Materiais e Metalurgia, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2007.
- 11 GOMES, O.D.M.; PACIORNIK, S. Co-Site Microscopy: combining Reflected Light and Scanning Electron Microscopy to perform Ore Mineralogy. In: Ninth International Congress on Applied Mineralogy, 2008, Brisbane. Carlton: AusIMM, 2008. p. 695-698.
- 12 GOMES, O.D.M.; PACIORNIK, S. Iron Ore Quantitative Characterisation Through Reflected Light-Scanning Electron Co-Site Microscopy. In: Ninth International Congress on Applied Mineralogy, 2008, Brisbane. Carlton: AusIMM, 2008. p. 699-702.
- 13 GOMES, O.D.M.; PACIORNIK, S. Caracterização Quantitativa de Minério de Ferro por Microscopia Co-localizada. **Tecnologia em Metalurgia, Materiais e Mineração**, v. 6, n. 2, p. 91-95, out.-dez. 2009.