

Quantificação de Microesferas de Vidro para Sinalização Horizontal pela Granulometria por Correlação com Pré-Processamento por Rede Convolutacional

Joel M. S. Junior, Laura Nascimento Mazzoni, Liedi Legi Bariani Bernucci, e Hae Yong Kim

Resumo— A marcação horizontal do pavimento é um importante elemento de segurança que deve ser visível tanto de dia quanto de noite. A visibilidade noturna é avaliada pela retrorefletividade e depende da quantidade de microesferas de vidro na pintura. Assim, conhecer a quantidade e distribuição das microesferas na marcação horizontal é indicativo de sua qualidade. Este trabalho propõe a utilização de granulometria baseada em correlação com pré-processamento pela rede convolutacional U-Net para contagem do número de microesferas presentes em imagens digitais. Avaliamos 10 imagens contendo 1468 microesferas. Os resultados são promissores, atingindo uma taxa média de acerto de 0,9334.

Palavras-Chave— sinalização horizontal, granulometria baseado em correlação, U-Net, quantificação de microesferas.

Abstract— The horizontal pavement marking is an important safety feature that must be visible both day and night. The night visibility is assessed by retroreflectivity and depends on the number of glass microspheres on the painting. Thus, knowing the quantity and distribution of microspheres in the horizontal marking are indicative of its quality. This paper proposes to use correlation-based granulometry with pre-processing by U-Net convolutional network for counting the number of microspheres present in digital images. We evaluate 10 images containing 1468 microspheres. The outcomes are promising, reaching an average hit rate of 0.9334.

Keywords— road demarcation, correlation-based granulometry, U-Net, microsphere quantification.

I. INTRODUÇÃO

A sinalização horizontal em pavimentos rodoviários são dispositivos de controle de tráfego [4], e tem como função alertar os motoristas sobre as condições adequadas de utilização da via [2]. Atualmente, o material mais utilizado para a sinalização horizontal são as tintas a base de água [10]. Sua aplicação consiste em jatear a tinta sobre o pavimento e, com a tinta ainda fresca, aplicar microesferas de vidro, essas têm como função refletirem as luzes provenientes dos faróis dos veículos.

A retrorefletividade da sinalização horizontal permite que ela seja visível no período noturno. Além disso, sinalização horizontal com maiores valores de retrorefletividade

E-mails: {joel.ms.junior, laura.mazzoni, liedi, hae.kim}@usp.br. Escola Politécnica, Universidade de São Paulo. Av. Prof. Luciano Gualberto, tr. 3, 158, 05508-010, São Paulo, SP, Brasil.

correlaciona-se positivamente com a percepção do condutor sobre a sinalização horizontal [8].

Salles et al. [3] analisaram vários estudos sobre a interação do condutor com maiores valores de retrorefletividade. Os autores apontam que as evidências empíricas demonstram que uma maior retrorefletividade da sinalização auxilia na visibilidade dos motoristas, bem como, na capacidade dos motoristas perceberem e interpretarem as distâncias durante a noite. Estradas demarcadas com elevados valores de retrorefletividade apresentam dirigibilidade mais adequada, o que contribui para reduções de acidentes noturnos.

Valores maiores de retrorefletividade estão diretamente relacionados a quantidade de microesferas depositadas na pintura ainda fresca [13]. Entretanto, existe uma quantidade máxima de microesferas possíveis de serem depositadas, ultrapassando esse valor máximo, as microesferas não irão aderir na tinta. Assim, há o interesse de desenvolver métodos que possam contar as microesferas para avaliar a quantidade correta que deve ser aplicada. E, mesmo depois de inicialmente depositada a quantidade adequada, o desgaste natural e a passagem de veículos removem microesferas, fazendo com que o valor de retrorefletividade caia e seja necessário repintar a demarcação.

Este trabalho utiliza a granulometria baseada em correlação [7] [1] para contar as microesferas nas faixas reflexivas. A granulometria por correlação exige que os grãos a serem detectados sejam sempre mais escuros (ou mais claros) do que o fundo. Isto não ocorre nas imagens de microesferas devido à transparência, reflexos e sombras (Figura 4(a)). Resolvemos este problema pré-processando as imagens com rede neural convolutacional tipo U-Net, para tornar as microesferas sempre mais claras do que o fundo. Acreditamos que esta técnica (pré-processar a imagem com U-Net antes de aplicar granulometria por correlação) possa ser aplicada em muitos outros problemas semelhantes. No total avaliamos 10 imagens contendo 1468 microesferas, com resultados promissores atingindo taxa média de acerto de 0.9334.

O artigo está organizado em 4 seções, incluindo esta introdução. Na seção 2, são explicados os dois algoritmos utilizados no sistema. Apresenta-se também o processo de aquisição das imagens, o treinamento da rede neural e as métricas utilizadas para avaliar o sistema. Na seção 3, são



Fig. 1. Comparação entre as microesferas e a tampa de uma caneta.

apresentados os resultados preliminares e uma discussão sobre dificuldades relacionadas a detecção de microesferas. Na seção 4, discutem-se as conclusões e expectativas para futuros trabalhos.

II. MÉTODOS

A. Granulometria baseada em correlação

Granulometria é o processo de medir a distribuição de objetos ou grãos de diferentes tamanhos de um material granular. Usualmente, a granulometria é baseada em morfologia matemática [5] ou na detecção de bordas [9]. No primeiro caso, não é possível localizar individualmente cada objeto, além de ser altamente sensível aos ruídos. No segundo caso, o algoritmo falhará quando as bordas dos objetos não estão claramente definidas.

Para superar tais limitações, Kim et al. [7] propuseram uma abordagem diferente para a granulometria, calculando a correlação cruzada de formas artificialmente geradas na imagem alvo. Essas formas, ou *kernels*, possuem excentricidades, orientações e tamanhos variados a fim de dar robustez ao algoritmo. A Figura 2 mostra as formas utilizadas para localizar as microesferas de vidro. Neste trabalho utilizamos apenas formas circulares de diversos tamanhos como *kernels*, pois as microesferas, via de regra, aparecem como círculos na imagem. Esta abordagem é robusta a pequenos ruídos e consegue localizar individualmente cada grão, superando as limitações do método baseado em morfologia matemática.

A correlação cruzada pode ser sensivelmente acelerada utilizando a transformada rápida de Fourier [6]. Além disso, várias correlações podem ser calculadas em paralelo. Como são gerados vários *kernels* para serem correlacionados, seleciona-se, para uma dada localização (x, y) , a correlação de maior valor. Picos de correlação são locais onde o valor da correlação é maior do que os seus vizinhos

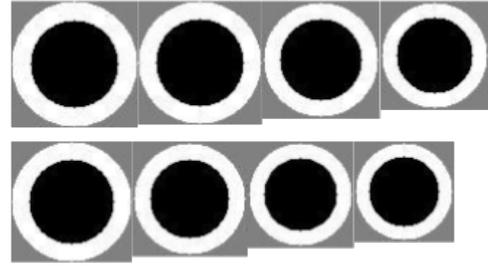


Fig. 2. Modelos utilizados pela granulometria baseada em correlação para localizar as microesferas de vidro.

espaciais. Estes são as localizações prováveis de um objeto com as características do *kernel* que gerou a maior correlação. Contudo, se faz necessário filtrar esses picos, pois muitos deles são falsos positivos.

Para filtrar os falsos picos de correlação são utilizados dois parâmetros. O parâmetro $\tau : 0 \leq \tau \leq 1$ é o valor mínimo de correlação que será aceito. Isso é, os picos de correlação com valor menor que τ serão descartados. O segundo parâmetro $\gamma : 0 \leq \gamma \leq 1$ controla a intersecção que dois grãos podem ter entre si. O algoritmo ordena os picos em ordem decrescente de correlação e primeiro descarta os picos com correlação menor que τ . Depois, descarta um objeto O_j se o conjunto de objetos com correlação maior que o de O_j esconder mais de γ da área do objeto O_j :

$$area[O_j \cap W(O_j)] > \gamma * area[O_j] \quad (1)$$

onde $W(O_j)$ é a união de todos os objetos com correlação maior que o de O_j .

Granulometria por correlação funciona apenas para imagens em níveis de cinzas em que os objetos que estamos buscando são mais escuros (ou mais claros) do que o fundo. As imagens de microesferas são coloridas e apresentam várias características que dificultam o uso da granulometria por correlação: transparências, reflexos, sombras, etc. Para superar este problema, propõe-se pré-processar a imagem com rede neural convolucional tipo U-Net.

B. U-Net

A imagem colorida das microesferas foi pré-processada utilizando uma rede convolucional U-Net para produzir uma imagem em níveis de cinza adequada para granulometria por correlação. A escolha por U-Net decorre do sucesso na segmentação de material biológico [11] e na localização de crateras lunares [12].

U-Net é uma rede neural convolucional em que existem dois caminhos de transformação da imagem, sendo um caminho contração e outro de expansão. Tais transformações irão produzir uma imagem em níveis de cinza onde, quanto mais branco um pixel, mais provável que este pertença a uma microesfera. Na Figura 4(d) vemos um exemplo de saída de U-Net.

A Figura 3 ilustra a arquitetura da U-Net utilizada. Na parte de contração, não há diferenças entre uma rede convolucional típica e a arquitetura da U-Net. A diferença

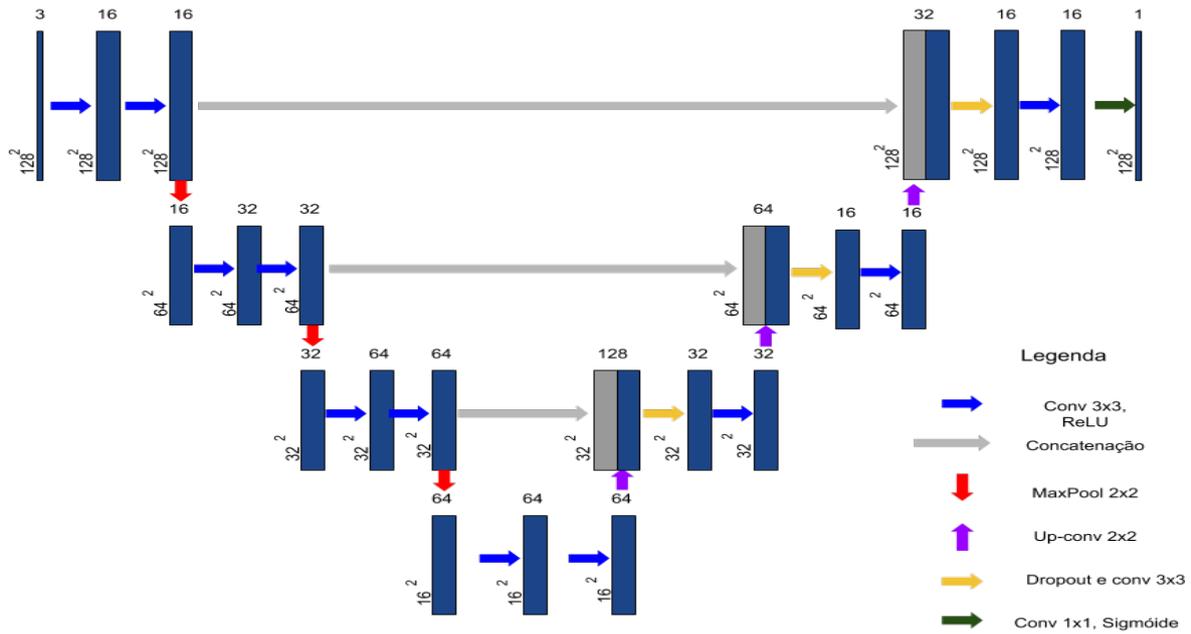


Fig. 3. Arquitetura geral da rede U-Net utilizada no trabalho.

está no caminho de expansão que aumenta o mapa de atributos que foi produzido no caminho de contração. Além disso, para cada expansão concatenam-se os parâmetros do mesmo nível do caminho de contração. Desse modo, informações de alto nível produzidas na contração (se numa região tem ou não microesfera) serão fundidas com as informações de baixo nível (a localização precisa da microesfera na imagem original).

Originalmente, U-Net foi desenvolvida para aplicações biológicas, nas quais o material disponível para o treino de redes neurais é normalmente escasso [11]. Por isso, U-Net faz uso intensivo de distorções nas imagens de entrada para que o conjunto de treinamento seja efetivamente bem maior do que o coletado.

Como a imagem das microesferas tem tamanho de 480×480 e a entrada de U-Net é 128×128 , é necessário “passear” pela imagem, amostrando janelas 128×128 . Regiões das imagens de saída sobrepostas por mais de uma janela são normalizadas pelo média das previsões.

Diferente de Ronneberge et al. [11], adicionamos bordas pretas de 64 pixels na imagem de entrada quando fizemos previsão, aumentando os lados das imagens para 544 pixels. Com isso, mesmo as microesferas que aparecem parcialmente na imagem aparecem no mapa de segmentação.

C. Aquisição e preparação das imagens

O material usado para a aquisição de imagens foram microesferas de vidros para sinalização horizontal viária. Elas atendem aos requisitos prescritos na norma brasileira ABNT NBR 16184:2013 para o tipo IIC.

A amostra foi preparada despejando 10g de microesferas em um pedaço de plástico adesivo transparente de $10\text{cm} \times 10\text{cm}$. No lado liso foram feitas marcações de 1cm

$\times 1\text{cm}$, que na Figura 1 aparecem como pontos azuis. As marcações foram inseridas como referências para as dimensões das partículas na imagem.

Após a preparação da amostra, realizou-se a aquisição de imagens com um *scanner* de mesa Epson V19, na resolução de 1200 dpi. A amostra foi posicionada com o lado liso para baixo, em contato direto com o vidro do *scanner*. Na parte de cima da amostra, colocou-se uma folha branca de papel sulfite A4 para tornar o fundo da imagem branco. A tampa do *scanner* ficou fechada durante a aquisição da imagem.

Nessa configuração, $1\text{cm} \times 1\text{cm}$ equivale aproximadamente a uma imagem com 480×480 pixels. Um operador selecionou 15 imagens desse tamanho e, usando um programa desenvolvido pelos autores, pintou manualmente um círculo branco em cada microesfera (de forma que o círculo cubra toda a esfera). Denominamos de máscara esta imagem de círculos brancos sobre fundo preto. Como subproduto deste processamento para criar máscaras, obteve-se a posição e o raio de cada microesfera, juntamente com o número total de esferas em cada imagem recortada. Microesferas cujos centros estavam fora da imagem recortada foram desconsideradas na contagem. Além disso, desconsideraram-se também os centros que estavam até a distância de 10 pixels da borda, menor diâmetro identificado pelo operador.

D. Treinamento e avaliação dos resultados

Das 15 imagens recortadas, 5 foram utilizadas como conjunto de treinamento da rede U-Net. Na fase de treinamento, a U-Net recebia imagens recortadas coloridas como amostras de entrada e as respectivas máscaras como

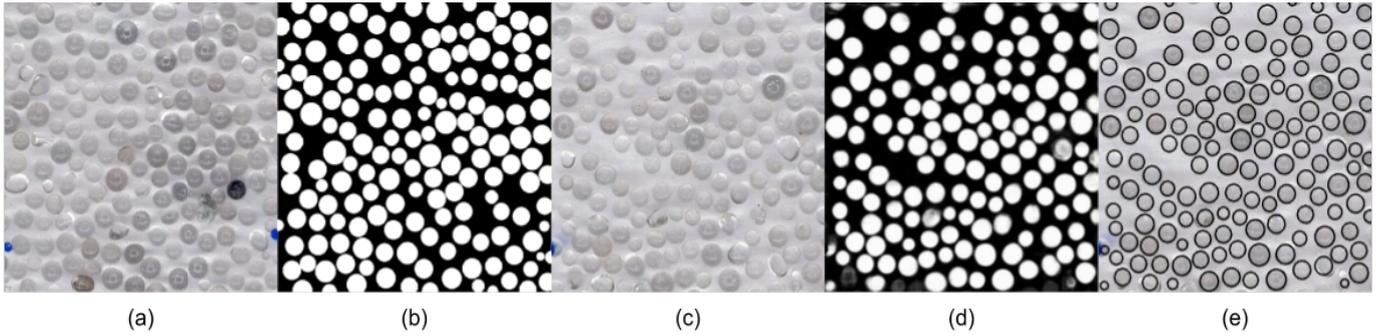


Fig. 4. (a) Imagem recortada de entrada para o treino de U-Net. (b) Imagem fornecida como alvo para o treino. (c) Exemplo de imagem para avaliar o sistema. (d) Mapa de segmentação produzida por U-Net. (e) Resultado final ao aplicar granulometria por correlação no mapa de segmentação.

amostras de saída. O treinamento durou 2 horas utilizando uma placa Nvidia K80 no Google Cloud.

Para avaliar o sistema, foram utilizados os 10 recortes restantes. Nesta fase, cada imagem recortada foi inserida na rede para obter saída semelhante à máscara (Figura 4(d)). Nesta imagem, aplicou-se granulometria por correlação para encontrar a localização e o raio de cada uma das microesferas. Nas 10 imagens recortadas, a quantidade de microesferas variou entre 117 e 177 por imagem.

Consideramos que um grão g foi corretamente localizado quando as duas condições abaixo são satisfeitas:

- (a) Se a distância entre o centro verdadeiro do grão g e o centro do grão localizado pela granulometria diferem menos de 25% do raio verdadeiro do grão g .
- (b) Se o raio verdadeiro do grão g e o raio obtido pela granulometria diferem menos de 25% do raio verdadeiro.

O valor 25% escolhido é arbitrário – outros valores podem ser usados. A partir desta definição, calculou-se a quantidade de verdadeiros positivos (quando um grão g foi corretamente localizado pela granulometria, VP), os falsos negativos (quando um grão g não foi localizado pela granulometria, FN) e os falsos positivos (quando a granulometria localizou um grão inexistente, FP). Note que neste problema, não existem verdadeiros negativos. Daí calcula-se a taxa de acerto T como:

$$T = \frac{VP}{VP + FP + FN} \quad (2)$$

Os parâmetros de correlação mínima e intersecção máxima de granulometria foram selecionados para maximizar a taxa de acerto média.

III. DISCUSSÕES E RESULTADOS PRELIMINARES

A Figura 4 mostra imagens em diferentes passos do sistema. (a) é uma das imagens recortadas de 480×480 que foi utilizada como amostra de entrada de treino de U-Net. (b) é a máscara produzida manualmente pelo operador e que foi utilizada como imagem alvo na fase de treino. Depois de U-Net estar treinada, utilizaram-se imagens como (c) para avaliar o sistema. (d) mostra a predição

TABELA I

RESULTADOS OBTIDOS PARA CADA UMA DAS 10 IMAGENS UTILIZADAS PARA AVALIAR O SISTEMA. O VALOR REAL É A QUANTIDADE DE MICROESFERAS CONTABILIZADAS PELO OPERADOR.

Imagem	real	VP	FP	FN	T
1	157	155	1	2	0.9810
2	177	173	7	4	0.9402
3	150	139	11	11	0.8633
4	176	166	7	10	0.9071
5	145	142	2	3	0.9659
6	138	135	4	3	0.9507
7	138	132	12	6	0.88
8	117	115	2	2	0.9663
9	142	138	7	4	0.9261
10	128	124	2	4	0.9538
T_{media}					0.9334

feita por U-Net para a imagem (c). E, por fim, procurou-se pelas microesferas utilizando granulometria por correlação na imagem (d), obtendo a imagem (e).

No total um conjunto com 10 recortes da imagem original foram avaliados, com 1468 microesferas, dos quais 1419 foram corretamente localizadas pelo sistema.

A Tabela I sumariza os resultados que foram obtidos pelo sistema. Nela é possível verificar a quantidade contabilizada pelo operador (*real*), a quantidade acertos que o sistema alcançou (*VP*), quantos erros que foram cometidos (*FP*, *FN*), bem como a taxa T . No pior caso, o sistema obteve 0,8633 de acerto, e no melhor caso, 0,9810. A média de acertos para os 10 recortes foi de 0,9334.

A. Código fonte e imagens

No repositório <https://github.com/joeljunior05/microspheres-sbrrt> é possível encontrar a imagem original, o código que gerou as imagens de treino, o código que treina a rede neural e o código que prediz o resultado final. Além disso, nesse mesmo repositório encontram-se recortes de 480×480 pixel (aproximadamente 1cm^2) com suas correspondentes máscaras e distribuição de esferas.

As implementações de granulometria baseada na correlação e da rede U-Net foram feitas com o auxílio da

biblioteca de processamento de imagem OpenCV (2.4.9) e da biblioteca de aprendizado profundo Keras (2.0.9).

IV. CONCLUSÃO E TRABALHOS FUTUROS

Neste trabalho, foi proposto o uso da U-Net para pré-processar imagens a serem analisadas pela granulometria baseada em correlação. Com esta técnica, foi possível localizar individualmente as microesferas, atingindo taxa de média de acerto de 0,9334. As microesferas não podem ser facilmente identificadas pois são transparentes, com efeitos de reflexão e sombras que dificultam localizá-las. A técnica proposta poderia ser utilizada para contar e localizar grãos em muitos outros tipos de imagens.

Zhang et al. [13] demonstraram que existe uma forte correlação entre a quantidade e distribuição das microesferas e o valor de retrorrefletividade da pintura de sinalização. Como trabalho futuro, propõe-se o emprego da mesma abordagem em campo para efetuar a contagem de microesferas em sinalizações desgastadas. Ao realizar este estudo em campo, tem-se como desafio o uso de um dispositivo computacional com menor poder de processamento do que a placa gráfica que foi utilizada neste experimento.

REFERÊNCIAS

- [1] Sidnei Alves Araújo, Jorge Henrique Pessor, and Hae Yong Kim. Beans quality inspection using correlation-based granulometry. *Engineering Applications of Artificial Intelligence*, 40:84–94, 2015.
- [2] Departamento Nacional de Infraestrutura e Transporte. *Manual de Sinalização Viária*. Instituto de Pesquisas Rodoviárias, 2010. 743 p.
- [3] Lucio Salles de Salles, Deividi da Silva Pereira, Daniel Luis Krachefski Teixeira, and Luciano Pivoto Specht. Avaliação retrorrefletiva de pintura de demarcação horizontal: peculiaridades e considerações sobre a norma e os requisitos mínimos nacionais. *TRANSPORTES*, 23(3):5–17, 2015.
- [4] Eric T Donnell and Zoltan Rado. Use of digital imaging methods to assess pavement marking retroreflectivity. Technical report, 2011.
- [5] Edward R Dougherty, John T Newell, and Jeff B Pelz. Morphological texture-based maximum-likelihood pixel classification based on local granulometric moments. *Pattern Recognition*, 25(10):1181–1198, 1992.
- [6] Rafael C. Gonzalez and Richard E. Woods. *Digital Image Processing (3rd Edition)*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 2006.
- [7] Hae Yong Kim, Ricardo Hitoshi Maruta, Danilo Roque Huanca, and Walter Jaimes Salcedo. Correlation-based multi-shape granulometry with application in porous silicon nanomaterial characterization. *Journal of Porous Materials*, 20(2):375–385, 2013.
- [8] D Lee and ET Donnell. Analysis of pavement marking effects in nighttime driver behavior using fuzzy inference system. *Journal of Computing in Civil Engineering*, 21(3):200–210, 2007.
- [9] Norbert H Maerz, Tom C Palangio, and John A Franklin. Wipfrag image based granulometry system. In *Proceedings of the FRAGBLAST 5 Workshop on Measurement of Blast Fragmentation, Montreal, Quebec, Canada*, pages 91–99. AA Balkema, 1996.
- [10] James Migletz and Jerry L Graham. *Long-term pavement marking practices: A synthesis of highway practice*, volume 306. Transportation Research Board, 2002. 94 p.
- [11] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, pages 234–241. Springer, 2015.
- [12] Ari Silburt, Mohamad Ali-Dib, Chenchong Zhu, Alan Jackson, Diana Valencia, Yevgeni Kissin, Daniel Tamayo, and Kristen Menou. Lunar crater identification via deep learning. *Icarus*, 317:27–38, 2019.
- [13] Guanghua Zhang, Joseph E Hummer, and William Rasdorf. Impact of bead density on paint pavement marking retroreflectivity. *Journal of Transportation Engineering*, 136(8):773–781, 2009.