

Descritores baseados em pontos de atenção aplicados à classificação de traços de concreto

Keypoint-features-based descriptors applied to concrete traces classification

RESUMO

Alessandra Iolanda Pacheco dos Santos

aleiolandap@hotmail.com

Universidade Tecnológica Federal do Paraná, Toledo, Paraná, Brasil

Eduarda Simonis Gavião

eduardagaviao@hotmail.com

Universidade Tecnológica Federal do Paraná, Toledo, Paraná, Brasil

Marcos Vinícius Schlichting

mvinicius@utfpr.edu.br

Universidade Tecnológica Federal do Paraná, Toledo, Paraná, Brasil

Wilson Leobet

wleobet@utfpr.edu.br

Universidade Tecnológica Federal do Paraná, Toledo, Paraná, Brasil

Carlos Eduardo Tino Balestra

carlosbalestra@utfpr.edu.br

Universidade Tecnológica Federal do Paraná, Toledo, Paraná, Brasil

Fabio Alexandre Spanhol

fspanhol@utfpr.edu.br

Universidade Tecnológica Federal do Paraná, Toledo, Paraná, Brasil

Jefferson Gustavo Martins

martins@utfpr.edu.br

Universidade Tecnológica Federal do Paraná, Toledo, Paraná, Brasil

Recebido: 19 ago. 2020.

Aprovado: 01 out. 2020.

Direito autoral: Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.

Edificações são amplamente dependentes da combinação de estruturas de concreto e aço. A composição do concreto, também chamado traço, é um fator de grande importância, sendo que os principais elementos são cimento, areia, brita e água. Tanto a proporção quanto a origem destes materiais exercem influência nas características finais do traço, dentre as quais tem-se resistência, durabilidade e trabalhabilidade. Inserido neste contexto, o presente artigo avalia três descritores baseado em pontos de atenção na tentativa de identificar diferentes composições de concreto. Os melhores resultados foram obtidos por meio do descritor SURF e atingiram 87,1% de acerto.

PALAVRAS-CHAVE: Construção civil. Defesa civil. Segurança pública. Automação.

ABSTRACT

Buildings are largely dependent on the combination of concrete and metal structures. The composition of concrete, also called dosage or trace, is a factor of great importance, and its main elements are cement, sand, gravel, and water. Both, proportion and the origin of these materials, have influence on the final characteristics of the traces, i.e., resistance, durability, and workability. In this context, this paper evaluates three keypoint-features-based descriptors to identify different concrete compositions. The best results were obtained by using the SURF descriptor and achieved 87.1% of correct classification.

KEYWORDS: Construction. Civil defense. Public security. Automation.



INTRODUÇÃO

A composição do concreto, também chamado traço, é uma característica extremamente importante em qualquer obra e muda de acordo com a finalidade de aplicação: lajes, contrapisos, muros, fundações, calçadas, vigas etc. Tanto a proporção quanto a origem dos materiais exercem influência nas características finais do traço, dentre as quais tem-se resistência, durabilidade e trabalhabilidade. Dentre os materiais comumente utilizados, tem-se cimento, areia, brita e água, mas concretos com características especiais podem ser obtidos com o acréscimo de aditivos, isopor, pigmentos, fibras ou outros tipos de adições (ABNT, 2015; MALTA, 2012; MONTEIRO, 2010).

A quantidade de água deve ser suficiente para envolver os grãos e promover a hidratação do cimento, além de atender os requisitos da ABNT NBR 15900-1, a qual também contempla exigências de utilização da água sob a forma de gelo. Sua função é ativar a reação química que transforma o cimento em uma pasta aglomerante que criará um bloco único com areia e a brita (agregados). Se em excesso, ter-se-á uma pasta mais porosa e melhores níveis trabalhabilidade. Porém, também piores níveis de resistência e aderência entre a pasta e o agregado devido à exsudação. Para a definição de tal proporção é necessário identificar o teor de umidade dos agregados, pois estes podem transportar diferentes quantidades de água para o concreto e ocasionar o decréscimo de sua resistência mecânica (ABNT, 2009; ABNT, 2015; MALTA, 2012; MONTEIRO, 2010).

Os agregados são materiais adicionados à pasta de cimento e água para aumentar seu volume e torná-la mais econômica. Assim como a água, as propriedades dos agregados têm influências da formação geológica local visto que são extraídas de jazidas próximas ao local da dosagem. O conhecimento das características individuais dos elementos, e também de sua combinação, é essencial para garantir certas características fundamentais ao concreto e a segurança da estrutura. Além disso, materiais com diferentes granularidades podem ser combinados dependendo da finalidade e produzem diferentes características texturais (ABNT, 2015; BAUER, 1994; MEHTA e MONTEIRO, 2008).

Além dos custos devido a degradação das estruturas, o risco em termos de colapsos estruturais merece atenção. Nos últimos anos, têm sido recorrentes os casos de colapsos de estruturas, dentre os quais tem-se o colapso parcial de um viaduto em Brasília no ano de 2018 (VIADUTO, 2018), a interdição do acesso à Rodovia Presidente Dutra em São Paulo no ano de 2019 (PREFEITURA, 2019) e o desabamento de prédios na comunidade de Muzema, na Zona Oeste do Rio, em 2019 (MAIA e GARCIA, 2019). Portanto, estudos pertinentes ferramentas que auxiliem a fiscalização e a prevenção destes acontecimentos são necessários com vistas a garantir estruturas mais seguras e duráveis e manutenções preventivas.

Outro importante fator é caracterizado pelas inspeções para avaliar a composição do concreto e também se este mantém suas propriedades são realizadas visualmente por especialistas humanos. Tais inspeções demandam altos níveis de experiência por ser um fator decisivo para uma correta avaliação. Dentre as possíveis ferramentas a serem empregadas, tem-se filmadoras, máquinas fotográficas, lupas e binóculos (ABNT, 2014; SCHVAICKARDT e MATTOS, 2018).

As imagens da Figura 1 foram obtidas a partir de dois diferentes traços (cimento : areia : brita : água), com as proporções (1 : 1,49 : 2,88 : 0,48) e (1 : 1,49 : 2,70 : 0,48). Nelas, pode-se nitidamente observar a variação na quantidade de britas entre os concretos e o grau de dificuldade a ele inerente.

Figura 1 – Composições de concreto (cimento : areia : brita : água): (a) 1 : 1,49 : 2,88 : 0,48; (b) 1 : 1,49 : 2,70 : 0,48.



(a)



(b)

Fonte: Autoria própria (2020).

Diante do exposto, esta pesquisa busca desenvolver soluções automatizadas que auxiliem nas inspeções realizadas com o objetivo de identificar a composição de um corpo de concreto qualquer. Estas soluções combinarão hardware e software e deverão propiciar as vantagens relativas à rapidez e precisão quando comparado à avaliação realizada por especialistas humanos. A redução de fatores físicos e subjetivos inerentes ao ser humano também reduzirá o número de etapas executadas manualmente e sua influência nos resultados finais. Tal influência compreende questões como subjetividade do especialista humano e características do processo (repetitivo, monótono e demorado), além de requerer alto grau de concentração. Este conjunto de exigências sobrecarrega o profissional que realiza a inspeção e o leva a possíveis distrações e baixas taxas de acerto (CONNERS et al., 1997; PHAM e ALCOCK, 1997; RADOVAN et al., 2001).

MATERIAIS E MÉTODOS

Sistemas para reconhecimento de padrões contemplam as seguintes etapas: aquisição, pré-processamento, segmentação, extração de características e classificação. Cada etapa constitui um diferente contexto, possui diferentes níveis de complexidade e envolve conhecimentos específicos próprios, além daqueles inerentes ao domínio da aplicação. Durante a aquisição, a imagem é capturada e armazenada utilizando sistemas de cores, resolução e quantização específicos. Devido à possibilidade de problemas decorrentes da aquisição, o pré-processamento foca a melhoria da qualidade da imagem. A segmentação constitui a etapa em que se extrai e identifica as áreas de interesse em uma imagem. A partir deste ponto, a extração de características permite identificar uma abstração (descriptor ou conjunto de características) adequada para a representação e a descrição das áreas de interesse. A classificação utiliza as representações anteriores para diferenciar os objetos nas imagens, atribuindo-lhes identificadores e significados de acordo com suas características e descritores (PEDRINI e SCHWARTZ, 2008).

Este trabalho utiliza características extraídas de pontos de atenção. Os pontos de atenção são amplamente empregados na identificação de objetos em problemas relacionados no rastreamento de objetos, principalmente no monitoramento de ambientes como aeroportos. As características extraídas dos pontos de atenção detectados possuem alto potencial devido aos padrões texturais decorrentes das composições dos traços de concreto (Figura 1).

Para a construção da base de imagens, foram preparados os corpos de prova de concreto cilíndricos com 10 cm de diâmetro e 20 cm de altura. Foram utilizados pelo menos 2 corpos de prova de concreto para cada um dos diferentes traços analisados, pois este procedimento é utilizado nas construções.

Os traços utilizados para os corpos de prova consideraram a proporção 1: 1,41: 2,01: 0,49 utilizando cimento do Portland do tipo CII, areia média, brita zero e água potável. Para avaliar a variação da granularidade do agregado brita, foi utilizada uma variação do traço padrão com a troca da brita zero pela brita um, gerando o traço 1: 1,49: 2,60: 0,49. Nesta variação de traço, tem-se um uso maior dos agregados (areia e brita) devido a um maior volume e superfície de cada unidade do agregado brita, sendo necessária menor quantidade de cimento para a construção de peças com um mesmo volume final (Figura 1).

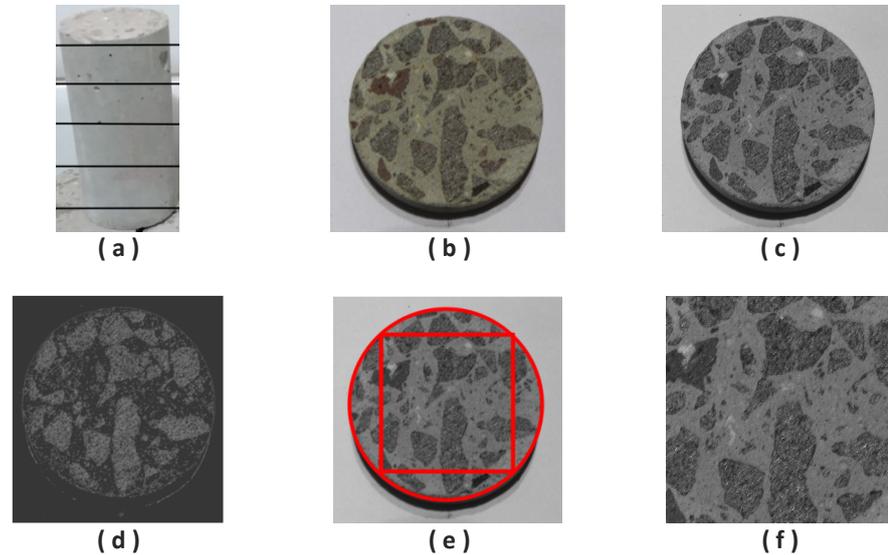
Na sequência, foram realizados cortes transversais a cerca de 5 mm da base e outro 5 mm do topo do corpo de prova (Figura 2(a)). O objetivo de ambos os cortes é eliminar a camada superficial e expor a caracterização da composição real do concreto (Figura 2(b)). A partir disto, foram realizados outros 8 cortes transversais em cada corpo de prova de concreto. Considerando que as lâminas de corte têm aproximadamente 2 mm, sendo obtido um total de 9 amostras distintas para cada corpo de prova. Considerando as duas faces de cada amostra, chegou-se a um total de 18 imagens para cada corpo de prova. Ao todo, foram utilizadas 72 imagens para construção dos modelos de reconhecimento dos traços de concreto.

O pré-processamento (Figura 2(c)) aplica operações para realçar as características importantes das classes existentes no problema. Assim, após a obtenção da base de dados obtida a partir dos corpos de prova fatiados, iniciou-se a etapa do pré-processamento de imagem, a fim de adequá-las e facilitar a extração das características. Passo no qual utilizou-se principalmente da biblioteca OpenCV para converter a base toda em escala de cinza.

A segmentação (Figura 2(d-f)) compreende a próxima etapa do processo e busca separar apenas a região de interesse da imagem original. O processo de segmentação refere-se ao método de “fragmentar” uma imagem em múltiplas regiões, com o objetivo de simplificar ou mudar sua representação, a fim de facilitar sua análise. O sucesso de um modelo de identificação ou de classificação depende fortemente da etapa de segmentação. O primeiro passo desta etapa foi segmentar a imagem pré-processada e selecionar a área de interesse, ou seja, o retângulo circunscrito (Figura 2(e-f)). Nesta etapa utilizou-se a técnica de limiarização para destacar o objeto na imagem, o algoritmo de detecção de bordas Canny (BUENO, 2020) para ressaltar os contornos das bordas dos objetos e a função *findContours* da biblioteca OpenCV para identificar os objetos. Esta função retorna os contornos de todos os possíveis objetos presentes na imagem, o que aqui poderia ser o próprio traço de concreto (Figura 2(d)), as britas ou qualquer outra região com contraste em relação a seu entorno. Ao final,

selecionaram-se os pontos pertencentes ao maior contorno e, após identificar o raio do objeto (Figura 2(e)), recortou-se a área de interesse (Figura 2(f)).

Figura 2 – Ilustração do processo de reconhecimento de padrões: (a) corpo de prova de concreto; (b) corte do corpo de prova; (c) pré-processamento com conversão para níveis de cinza; (d-e) segmentação.



Fonte: Autoria própria (2020).

Para a etapa de Extração de Características, busca-se representar a imagem por meio de um vetor numérico de medidas. Nesta etapa foram utilizados os descritores Transformação de Características Invariantes à Escala (*Scale Invariant Feature Transform - SIFT*), Características Robustas Aceleradas (*Speed-Up Robust Feature - SURF*) e Regiões Extremas Maximamente Estáveis (*Maximally Stable Extremal Regions - MSER*). SIFT foi proposto por Lowe (1999) para ser aplicado a imagens de objetos ou cenas capturadas de diferentes perspectivas. Os pontos identificados apresentam diferenças máximas e mínimas da função Gaussiana. Estas altas variações das regiões e escalas constituem as principais garantias para a estabilidade do descritor e para a invariância a translação, escala e rotação, além de invariância parcial a mudanças de iluminação e projeções 3D. Cada ponto de atenção acumula a avaliação dos gradientes nas oito direções possíveis, cada ponto é representado por um vetor de características com 128 elementos. Além disso, geralmente são detectados centenas ou até milhares de pontos para cada imagem, todos potencialmente candidatos a compor o conjunto de suas características (LOWE, 1999; LOWE, 2004; VEDALDI e FULKERSON, 2008).

Proposto por Bay *et al.* (2006), SURF apresenta semelhanças ao SIFT e permite detecção e descrição de regiões de interesse. Porém, reduz a alta dimensionalidade e custo computacional do descritor SIFT. SURF considera uma região quadrada (8x8) centrada no ponto de interesse e alinhada com a orientação previamente identificada. Para cada um dos 64 elementos, obtém-se a resposta da wavelet de Haar nas direções x e y, denominadas respectivamente d_x e d_y . Para cada sub-região 2x2, d_x , d_y , $|d_x|$ e $|d_y|$ são acumuladas separadamente, gerando 16 conjuntos com as quatro características ($\sum d_x$, $\sum d_y$, $\sum |d_x|$ e $\sum |d_y|$), num total de 64 elementos. Ao final, podem ser detectados até milhares de pontos para cada imagem, todos invariantes à translação, escala e

rotação, além de ser parcialmente invariante a mudanças de iluminação e projeções 3D e candidatos a compor o conjunto de características que descreve a imagem. Também há a variante SURF-128, a qual duplica o número de características que compõem o vetor final. Esta variante acumula d_x e $|d_x|$ separadamente para $d_y < 0$ e $d_y \geq 0$, sendo o mesmo considerado para d_y e $|d_y|$ de acordo com o sinal de d_x . Embora esta variação garanta descritores mais discriminantes, a maior dimensionalidade do vetor de características exige maiores recursos computacionais (BAY *et al.*; 2006; BAY *et al.*, 2008).

Em 2002, Matas *et al.* (2002) conceituaram regiões extremas (*Extremal Regions* - ER) e propuseram o algoritmo MSER para detectá-las. ERs são caracterizadas como componentes conexos invariantes a transformações das coordenadas das imagens e a transformações das intensidades de seus pixels. De forma simplificada, as regiões extremas são identificadas por meio de uma sequência de limiarizações da imagem original (em níveis de cinza) e das imagens binárias geradas. Tal sequência de imagens inicia com um quadro totalmente branco e termina com um outro totalmente negro, passando por diversas imagens intermediárias nas quais as regiões de interesse são identificadas. Tais regiões se tornam cada vez maiores e se fundem à medida que o valor utilizado como limiar é incrementado (LÓPEZ, 2011; MATAS *et al.*, 2002).

De forma geral, as ERs são identificadas em função dos níveis de cinza dos pixels que as compõem e daqueles externos a elas. Ou seja, tais regiões são ou mais escuras ou mais claras que sua vizinhança, sendo estáveis diante de diferentes limiares no processo de binarização. Os autores afirmam que essas regiões são estáveis e invariantes a escalas, a transformações das coordenadas das imagens e a transformações das intensidades de seus pixels. A enumeração destas regiões inicia com a ordenação dos pixels da imagem. Em seguida, tal sequência é percorrida e as posições dos pixels na imagem permitem que os componentes conexos e suas áreas sejam identificados e mantidos por meio do algoritmo *union-find*. Níveis de cinza caracterizados como mínimos locais da taxa de mudança da área são selecionados como limiares produzindo regiões extremas maximamente estáveis (MATAS *et al.*, 2002).

A extração dos descritores para SIFT, SURF e MSER empregou a implementação disponível no software MatLab 2016. Para SIFT foram gerados vetores com 128 elementos para cada ponto de atenção identificado nas imagens. Já para SURF e MSER foram consideradas as versões com 64 e 128 elementos para cada ponto de atenção identificado. Devido à variação do número de pontos identificados em cada imagem, optou-se por utilizar momentos estatísticos para padronizar sua representação. Foram calculadas média, variância, obliquidade e curtose para cada coluna dos vetores gerados pelos descritores, dando origem a vetores com dimensões de 64 ou 128 elementos para cada um dos quatro momentos estatísticos utilizados. Esta abordagem é comumente utilizada com filtros de Gabor (YANG e NEWSAM, 2008; ZHU *et al.*, 2008).

Na etapa de classificação foi utilizado o algoritmo Máquinas de Vetores de Suporte (*Support Vector Machine* - SVM), por meio da implementação LibSVM 3.2 disponibilizada no endereço eletrônico <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>. Dentre as possibilidades disponibilizadas pela biblioteca, os melhores resultados foram obtidos com a função de base radial Gaussiana e uma busca gulosa para

encontrar os melhores parâmetros C e γ . A normalização dos dados considerou a escala linear de cada atributo dos vetores de características no intervalo $[-1,+1]$.

Diferentes avaliações foram consideradas a partir dos vetores de características com os momentos estatísticos anteriormente descritos, além de uma avaliação utilizando apenas número de pontos de atenção identificados em cada imagem como característica. Para a definição dos conjuntos de treinamento e teste, dividiu-se a base de imagens em 3 partes (*folds*), os quais mantinham a representatividade das classes pertencentes ao problema em questão. Foi empregada validação cruzada com 3 execuções, sendo que em que execução, um parte era usada como conjunto de teste e as outras duas eram utilizadas como conjunto de treinamento. Os resultados finais são expressos pela acurácia média (acertos do classificador) e desvio padrão (dp) das taxas de classificações corretas das três execuções.

RESULTADOS E DISCUSSÃO

Para cada etapa do processo de reconhecimento de padrões foram testados diferentes parâmetros, muitos dos quais já identificados anteriormente na seção de materiais e métodos. Para SIFT, os melhores resultados alcançados foram 85,0% (dp = 8,0). Utilizando MSER atingiu 84,7% (dp = 7,1) para a versão com 128 atributos, num total de 513 atributos no vetor de características. Estes vetores foram obtidos com a concatenação dos vetores de características dos quatro momentos estatísticos e também o número de regiões detectadas. Por fim, SURF, com vetores de características com apenas o momento estatístico média para a versão com 64 atributos, obteve-se 87,1% (dp = 3,1).

O problema em questão envolve segurança e vidas humanas, além dos altos valores monetários envolvidos na construção e manutenção das edificações. Os resultados obtidos se mostraram importantes, principalmente com os bons resultados alcançados com os experimentos preliminares apresentados. Além do exposto, destaca-se o descritor SURF com os melhores resultados utilizando apenas vetores de características com 64 atributos.

CONSIDERAÇÕES FINAIS

Este trabalho avaliou a aplicação de classificadores construídos a partir de três descritores baseados em pontos de atenção ao problema de reconhecimento de traços de concreto por meio de imagens. Os resultados alcançados são bastante promissores para problema abordado. Nossos resultados ficaram acima de 84%, sendo que a melhor taxa de reconhecimento foi 87,1% (dp = 3,1) usando apenas 64 atributos extraídos para o descritor SURF.

Os trabalhos futuros compreenderão a ampliação da base de imagens, com maior variedade de traços e imagens. Ao mesmo tempo, serão investigados novos descritores e opções para seleção e combinação de classificadores, tais como as apresentadas por Martins, Oliveira e Sabourin (2012).

AGRADECIMENTOS

Os autores agradecem aos docentes Dr. Jefferson Gustavo Martins, Dr. Fabio Alexandre Spanhol e Dr. Carlos Eduardo Tino Balestra pela oportunidade e orientação, bem como o apoio incondicional dos técnicos de laboratório Marcos Vinícius Schlichting e Wilson Leobet. Sem este suporte, não seria possível o desenvolvimento do projeto.

REFERÊNCIAS

ABNT – Associação Brasileira de Normas Técnicas. **ABNT 15900-1**: Água para amassamento do concreto Parte 1: Requisitos. Rio de Janeiro, 2009.

ABNT – Associação Brasileira de Normas Técnicas. **ABNT 6118**: Projeto de estruturas de concreto – Procedimento. Rio de Janeiro, 2014.

ABNT – Associação Brasileira de Normas Técnicas. **ABNT 12655**: Concreto de cimento Portland – Preparo, controle, recebimento e aceitação – Procedimento. Rio de Janeiro, 2015.

BAUER, L. A. F. **Materiais de Construção**. 5.ed. Vol 1. Rio de Janeiro: LTC – Livros técnicos e Científicos Editora S.A., 1994.

BAY, H.; TUYTELAARS, T.; e VAN GOOL, L. SURF: Speeded up robust features. In **ECCV**, 2006, p. 404-417.

BAY, H.; ESS, A.; TUYTELAARS, T.; e VAN GOOL, L. Speeded-up robust features (SURF). **Compute Vision. Image Understanding**, v. 110, n. 3, 2008, p. 346-359.

BUENO, M. L. **Deteção de Bordas através de Algoritmo Canny**. Disponível em: <http://www.inf.ufsc.br/~aldo.vw/visao/2000/Bordas/index.htm>. Acesso em: 20 jan. 2020.

CONNERS, R. W.; KLINE, D. E.; ARAMAN, P. A.; DRAYER, T. H. Machine vision technology for the forest products industry. In **Computer**, v. 30, n. 7, p. 43-48, 1997.

LÓPES, G. A. P. **Aforapro**: reconhecimento de objetos invariante sob transformações afins. Dissertação de Mestrado, Escola Politécnica da Universidade de São Paulo, São Paulo, 2011.

LOWE, D.G. Object recognition from local scale-invariant features. In **International Conference on Computer Vision**, v. 2, p. 1150-, Washington, DC, USA, 1999.

LOWE, D.G. Distinctive image features from scale-invariant keypoints. In **Int. Journal of Computer Vision**, v. 60, n. 2, p. 91-110, 2004.

Maia, D. e Garcia, D. Dois prédios desabam na zona oeste do Rio de Janeiro. **Folha de São Paulo**, São Paulo - SP, 12 de abr. de 2019. Disponível em: <https://www1.folha.uol.com.br/cotidiano/2019/04/dois-predios-desabam-na-zona-oeste-do-rio-de-janeiro.shtml#:~:text=%E2%80%8B%20desabamento%20de%20dois,adolescent e%20est%C3%A3o%20entre%20as%20v%C3%ADtimas.&text=%E2%80%8B%20pr%C3%A9dios%20ca%C3%ADram%20por%20volta%20das%206h30>. Acesso em: 20 de jun. de 2019.

MALTA, J. O. **Dosagem de concretos produzidos com agregado miúdo reciclado de resíduo de construção e demolição**. Dissertação de Mestrado em Engenharia Ambiental Urbana. Escola Politécnica (EPUFBA). Universidade Federal da Bahia (UFBA). Salvador, 2012.

MARTINS, J.G.; OLIVEIRA, L.E.S.; SABOURIN, R. Combining textural descriptors for forest species recognition. In **38th Annual Conference on IEEE Industrial Electronics Society**, p. 1483-1488, 2012.

MATAS, J.; CHUM, O.; MARTIN, U.; e PAJDLA, T. Robust wide baseline stereo from maximally stable extremal regions. In **British Machine Vision Conference**, p. 384–393, 2002.

MEHTA, P.K.; MONTEIRO, P. **Concreto: Microestrutura, Propriedades e Materiais**. 3.ed. São Paulo: IBRACON, 2008.

MONTEIRO, A. C. N. **Concreto Poroso: dosagem e desempenho**. Monografia de Graduação em Engenharia Civil. Universidade Federal de Goiás (UFGO). Goiania, 2010.

PEDRINI, H.; SCHWARTZ, W.R. **Análise de Imagens Digitais: princípios, algoritmos e aplicações**. São Paulo: Thomson Learning, 2008.

PHAM, D. T.; ALCOCK, R. J. Automated visual inspection of birch wood boards. In **IEE Colloquium on Artificial Intelligence in Manufacturing**, p. 1-4, 1997.

PREFEITURA de SP interdita ponte que leva à Dutra pela Marginal Tietê. **G1 SP**, São Paulo - SP, 23 de jan. de 2019. Disponível em: <https://g1.globo.com/sp/sao-paulo/noticia/2019/01/23/prefeitura-de-sp-interdita-ponte-que-leva-a-dutra-pela-marginal-tiete.ghtml>. Acesso em: 20 de jun. de 2019.

RADOVAN, S.; GEORGE, P.; PANAGIOTIS, M.; MANOS, G.; ROBERT, A.; IGOR, D. An approach for automated inspection of wood boards. In **International Conference on Image Processing**, 1, p. 798-801, 2001.

SCHVAICKARDT, C. M.; MATTOS, J. R. G. Estudo de traço para peças prêmoldadas de concreto para pavimentos intertravados. In **Revista Nacional de Gerenciamento de Cidades**, v. 6, n. 39. 2018.

VEDALDI, A.; FULKERSON, B. **VLFeat**: An Open and Portable Library of Computer Vision Algorithms. 2008. URL: <http://www.vlfeat.org/>.

VIADUTO da Galeria dos Estados desaba e abre cratera no Eixão Sul. **Correio Braziliense**, Brasília - DF, 06 de fev. de 2018. Disponível em: https://www.correiobraziliense.com.br/app/noticia/cidades/2018/02/06/interna_cidadesdf,658118/parte-do-viaduto-da-galeria-dos-estados-desaba-no-centro-de-brasilia.shtml. Acesso em: 20 de jun. de 2019.

YANG, Y.; e NEWSAM, S. Comparing SIFT descriptors and Gabor texture features for classification of remote sensed imagery. In **15th IEEE International Conference on Image Processing**, p. 1852-1855, 2008.

ZHU, J.; HOI, S. C.H.; LYU, M. R.; e YAN, S. Near-duplicate keyframe retrieval by nonrigid image matching. In **16th ACM international conference on Multimedia**, p. 41–50, New York, NY, USA, 2008.