

ANÁLISE DE DESGASTE DE UMA SUPERFÍCIE RUGOSA UTILIZANDO TÉCNICAS DE PROCESSAMENTO DE IMAGENS

ROGÉRIO YUGO TAKIMOTO*, MARCOS DE SALES GUERRA TSUZUKI*, EDSON KENJI UEDA*,
ANDRÉ KUBAGAWA SATO*, THIAGO DE CASTRO MARTINS*,
TIAGO COUSSEAU†, AMILTON SINATORA‡

**Laboratório de Geometria Computacional
Departamento de Engenharia Mecatrônica e de Sistemas Mecânicos
Escola Politécnica da Universidade de São Paulo
Avenida Prof. Mello Moraes, 2231, CEP 05508-030 - São Paulo, SP, Brasil*

*†Laboratório de Fenômenos de Superfície, Departamento de Engenharia Mecânica
Escola Politécnica da Universidade de São Paulo
Avenida Prof. Mello Moraes, 2231, CEP 05508-030 - São Paulo, SP, Brasil*

*‡Instituto Vale de Tecnologia - Mineração (ITV)
Av. Juscelino Kubitschek, 31, CEP 35400-000 - Baurita, Ouro Preto, MG, Brasil*

Emails: takimotoyugo@gmail.com, mtsuzuki@usp.br, ueda.edson@gmail.com,
andre.kubagawa@gmail.com, thiago@usp.br, tiagoegm@gmail.com, sinatora@usp.br

Abstract— Due to the great interest of the automotive industry to quickly and systematically evaluate low wear quantities a new approach based on image processing is presented. Comparing the captured rough surface point cloud using optical interferometry before and after the wear, the proposed algorithm was able to compare both point clouds and estimate the amount of wear and the mass loss. Moreover, the main advantage of this method is the visualization of the wear geometry provided by the wear topography. The proposed algorithm was tested and the results were compared with a precision weighing balance.

Keywords— Point Cloud Registration, Image Processing, Rigid Transform, ICP, SIFT.

Resumo— Devido ao grande interesse da indústria automobilística em se avaliar rapidamente e sistematicamente baixos níveis de desgaste nova abordagem baseada em processamento de imagens é apresentada. A partir da captura da nuvem de pontos da superfície rugosa antes e depois do desgaste utilizando interferometria ótica, o algoritmo proposto pôde comparar as duas nuvens de pontos identificando a área desgastada e estimando a quantidade de massa perdida. Além disso, a grande vantagem deste método é a de permitir a visualização da geometria da área desgastada fornecendo uma comparação topográfica do desgaste. O algoritmo proposto foi testado e os resultados utilizando algumas amostras foram comparados com um balança de precisão.

Palavras-chave— Registro de Nuvem de Pontos, Processamento de Imagens, Transformação Rígida, ICP, SIFT.

1 Introdução

O conceito de tribologia como a ciência que estuda o atrito e o desgaste de corpos em contato veio da percepção dos prejuízos causados pelo desgaste de equipamentos na segunda guerra mundial conforme apontado pelo relatório de Jost et al. (1966). Desde então, sempre houve interesse em entender e quantificar o desgaste a fim de poder controlá-lo. Dentre as técnicas de medição de desgaste mais usuais e úteis citam-se aquelas associadas à mudança de peso; a análise de perfis bidimensionais e mais recentemente a análise de perfis tridimensionais (Whitenton and Blau, 1988).

O método da mudança de peso geralmente envolve a medição da massa das partículas de desgaste (debris) ou da mudança de massa do objeto. Este método não fornece nenhuma informação à respeito da morfologia do desgaste, além disso a resolução das balanças de precisão está diretamente associada à massa máxima a ser medida, limitando a sua utilização para medir desgastes pequenos (mg) à peças leves e pequenas.

Os métodos que envolvem análise 2D tam-

bém não fornecem a morfologia do desgaste, mas apenas o conhecimento da seção transversal do mesmo, a qual se considera representativa da superfície, o que para muitos componentes de engenharia, como os cilindros brunidos de automóveis, é inviável e não possibilita dados credíveis de desgaste, devido ao seu acabamento superficial ser anisotrópico.

Os métodos que envolvem análise 3D apresentam majoritariamente duas abordagens: Uma baseada na quantificação do desgaste pela comparação dos parâmetros de rugosidade da superfície, em particular os parâmetros da curva de Abbot-Firestone e os parâmetros de volume (Pawlus, 1997); e outra, mais elaborada, baseada na comparação da topografia do objeto quando novo e após o desgaste. Por meio desta comparação é possível determinar o volume desgaste, bem como avaliar sua morfologia, o que permite inferir sobre o que decorreu o desgaste. O desafio deste segundo método, que é mais acurado, é o de realocar as imagens medidas antes e depois do desgaste a fim de obter o casamento perfeito destas uma vez que a referência de altura




Figura 1: Algoritmo proposto.

pode ter sido completamente perdida devido ao desgaste. A análise de vários trabalhos relevantes nesta área (Pawlus, 1997; Gara et al., 2010; Rubach et al., 2014) permite concluir que não há uma solução para o problema quando a área medida pré-desgaste se altera completamente, de modo que já não se encontre características destas na superfície pós desgaste. Deste modo, propõe-se aqui que a área medida apresente uma zona comum não desgastada de referência, visto que tal metodologia pode ser utilizada em vários componentes mecânicos como engrenagens, rolamentos, anéis de pistão, etc., visto que a área de contato destes elementos é sempre muito restrita. Tal metodologia não exclui os desafios associados a quantificar desgastes submicrométricos, e exige por tanto, a utilização de técnicas de processamento de imagens robustas e velozes dado o grande número de pontos medidos que é necessário para observar variações sub-micrométricas.

2 Método Proposto

O algoritmo proposto para a comparação de duas superfícies rugosas pode ser visualizado na Fig. 1. São fornecidas duas nuvens de pontos (uma original e outra desgastada) geradas a partir da utilização de um perfilômetro ótico 3D. Em seguida são criadas imagens 2D para realçar os pontos característicos. É determinada uma transformação 2D para registrar as duas imagens 2D. Posteriormente, o ICP (Iterative Closest Point) é utilizado para registrar as nuvens de pontos no espaço 3D.




Figura 2: (a) Nuvem de pontos da superfície rugosa, onde é impossível visualizar imperfeições. (b) Imagem 2D da nuvem de pontos, onde as imperfeições ficam realçadas.

2.1 Mapeamento da nuvem de pontos 3D numa imagem 2D

Para poder comparar as superfícies rugosas, o algoritmo realiza um processamento inicial para facilitar a visualização da rugosidade da superfície utilizando uma imagem 2D. Na imagem 2D, o eixo Z da nuvem de pontos corresponde aos níveis de cinza, enquanto os eixos X e Y da nuvem de pontos estão relacionados com o tamanho da imagem. A Fig. 2 mostra o mapeamento da nuvem de pontos para a imagem 2D. A imagem 2D apresenta detalhes indicando os locais onde a superfície apresenta imperfeições.

2.2 Identificação dos pontos característicos na imagem 2D

A utilização de imagens 2D facilitam a identificação de pontos característicos para registro das nuvens de pontos. Para essa identificação, uma das abordagens é através da identificação de certas características distintas como as bordas, os cantos ou as texturas. Dentre os métodos para se identificar características distintas em imagens, os métodos baseados em bordas e pontos característicos são bem úteis e se complementam conforme discutido em Choi and Christensen (2010); Vacchetti et al. (2004). Choi and Christensen (2010) realiza o tracking 3D utilizando os pontos característicos e as bordas. Além disso, como mencionado em Vacchetti et al. (2004), a utilização dos métodos em conjunto torna o sistema mais robusto. O algoritmo proposto utiliza a detecção das bordas com recuperação dos pontos característicos ao longo da borda detectada.

2.2.1 Detectores de Borda

Como uma borda ou aresta corresponde a uma descontinuidade na intensidade dos tons de cinza dos pixels que formam a imagem, os detectores de bordas Sobel (Sobel and Feldman, 1968) e Canny (Canny, 1986) serão utilizados para identificar mudanças abruptas na intensidade dos brilhos. O Sobel tem como objetivo destacar bordas de uma imagem no sentido horizontal e vertical, retornando a borda onde o gradiente é máximo.




Figura 3: Extração de bordas da superfície rugosa mapeada. (a) Imagem original. (b) Sobel. (c) Canny.

No Canny, a imagem é suavizada com as derivadas de primeira ordem do filtro Gaussiano na direção do gradiente local seguido pela detecção de bordas por dois limiares. As bordas fracas são incluídas apenas se estiverem conectadas às bordas fortes. Desta forma, este processo é menos suscetível a ruídos e mais coerente com as bordas fracas além de fragmentar menos tais bordas. O Canny trabalha com base em três critérios ótimos para localização de contornos: mínima probabilidade de detecção de múltiplas bordas; boa localização, isto é, mínima possibilidade de erro na detecção dos pontos pertencentes à borda verdadeira; e, detecção de uma única borda, ou seja, se houverem duas respostas uma delas é considerada falsa. A Fig. 3 mostra as imagens obtidas com Sobel e Canny para a superfície rugosa mapeada.

2.2.2 SIFT

Após a identificação das bordas, os pontos característicos são obtidos pelo SIFT (*Scale Invariant Feature Transform*) (Lowe, 1999). Este método é robusto para extrair e descrever pontos chaves de uma imagem, e realiza também a extração de vetores característicos ao redor dos pontos chaves. O SIFT permite que um mapeamento confiável entre diferentes vistas de um objeto ou cena seja feito. A seguir, são descritas suas etapas.

(1) Construção do espaço-escala: O algoritmo procura por características estáveis ao longo de diferentes escalas. O espaço-escala é construído pela função Gaussiana a partir da diferença de gaussianas, $D(x, y, \sigma)$ no espaço x , y e escala σ (Lindeberg, 1994). (2) Localização dos pontos característicos: os máximos e mínimos locais são detectados pela comparação de cada pixel com os seus 8 vizinhos na imagem corrente e 9 vizinhos nas escalas superior e inferior. O candidato é preservado se ele for maior ou menor que todos os seus 26 vizinhos. (3) Atribuição de orientação: Para cada imagem amostrada $L(x, y)$, numa escala particular, calcula-se o gradiente de magnitude $m(x, y) = \sqrt{L_x^2 + L_y^2}$ e a orientação $\theta(x, y) = \arctan\left(\frac{L_y}{L_x}\right)$ onde $L_x = L(x+1, y) - L(x-1, y)$ e $L_y = L(x, y+1) - L(x, y-1)$. Um histograma de orientação é formado a partir do gradiente dos

pontos amostrados ao redor do ponto característico. Picos no histograma de orientação correspondem à direção dominante do gradiente local. (4) Descrição dos pontos característicos: o próximo passo é calcular um descritor para a região da imagem local que é distinta e invariante a variações adicionais, tais como mudanças na iluminação ou visão perspectiva. Para alcançar a invariância de orientação, as coordenadas do descritor e as orientações do gradiente são rotacionadas em relação à orientação do ponto característico. (5) Mapeamento dos pontos característicos: uma vez que o SIFT foi aplicado às imagens, o mapeamento inicial entre os pontos característicos será realizado através do método do vizinho mais próximo, conforme proposto por Lowe (1999).

2.3 RANSAC

Devido ao deloscamento que pode haver entre as nuvens de pontos capturadas, pontos característicos presentes nas bordas de uma imagem podem não possuir uma correspondência na outra imagem e vice-versa. Para eventuais problemas e erros com relação à correspondência entre os pontos característicos existe a necessidade de se utilizar um método de estimação para se considerar somente os pontos corretamente mapeados. Estimadores de parâmetros clássicos, como mínimos quadrados, se baseiam em todos os dados disponíveis. Desse modo, se grande parte dos dados vier de uma fonte em que existam erros inerentes, ou ruídos, (isto é, algum tipo de *outlier*) o modelo final estimado será prejudicado. O RANSAC (RANdom SAMple Consensus) (Fischler and Bolles, 1981) foi desenvolvido com o intuito de evitar que *outliers* atrapalhem a determinação do modelo final. O RANSAC inicia com a seleção aleatória de uma amostra mínima de dados. Essa amostra, é o número mínimo de dados necessário para inicializar o modelo. O modelo adotado no sistema desenvolvido corresponde a determinar a correspondência de retas, a amostra mínima é constituída por apenas dois pontos mapeados. Em cada uma das imagens uma reta é estimada e a transformação para realizar o registro das duas retas, é determinada. O restante dos dados é utilizado para determinar retas adicionais e verificar se elas estão razoavelmente registradas segundo a transformação já determinada. Para tal, é definido um valor de limiar, que é a distância máxima do modelo que um dado pode estar para ainda ser considerado um *inlier*. Os *inlier* associados a um modelo representam o conjunto de consenso do modelo e são os dados que se aproximam do modelo, por outro lado os *outliers* são os dados que não se aproximam do modelo. Com isso, o RANSAC pode estimar um modelo utilizando os melhores pontos no mapeamento de pontos característicos a partir de um conjunto de dados. A Fig. 4 mos-




Figura 4: Mapeamento de pontos característicos, onde linhas determinadas nas duas imagens estão registradas. (a) Antes do RANSAC. (b) Depois do RANSAC.

tra as imagens com os pontos característicos mais próximos mapeados antes e depois da aplicação do RANSAC.

2.4 Utilização e Aprimoramento do ICP

Após o processamento inicial para identificar os pontos de interesse nas imagens 2D, as coordenadas 3D dos pontos identificados são recuperadas para que o registro entre as nuvens de pontos seja feita. O ICP (Iterative Closest Point) foi introduzido originalmente para registrar conjuntos de dados 3D por Besl and McKay (1992). Dados P e Q , duas nuvens de pontos contendo N_P e N_Q pontos característicos respectivamente, tem-se, $P = \{p_i\}$, $1 \leq i \leq N_P$ e $Q = \{q_i\}$, $1 \leq i \leq N_Q$. A partir do mapeamento dos pontos mais próximos, o objetivo é calcular os parâmetros da transformação rígida $\mathbf{T}$ que melhor alinha os pontos $r_i = \mathbf{T} \cdot p_i$, $1 \leq i \leq N_P$ para o conjunto de pontos Q . Para uma transformação Euclidiana 2D os parâmetros de $\mathbf{T}$ são o ângulo de rotação θ e o vetor de translação (t_x, t_y) . O registro ocorre quando um número máximo de iterações é atingido ou quando a mudança no estimador quadrático médio cair para um valor abaixo de um determinado limiar $\tau > 0$.

2.4.1 ICP Modificado

Embora o ICP seja largamente utilizado para alinhar nuvens de pontos 3D, algumas limitações devem ser destacadas. O algoritmo tem um mínimo local muito próximo ao mínimo global e pode ficar preso a um dos mínimos locais conforme abordado em Cuchet et al. (1995). Além disso, como o algoritmo descrito por Besl and McKay (1992) utiliza uma métrica de erro ponto a ponto no qual a soma da distância quadrada entre os pontos correspondentes é minimizada, cada ponto de um conjunto é alinhado com o ponto mais próximo no outro conjunto para formar um par correspondente. No entanto, no problema em estudo, a correspondência não pode ser um-para-um, pois existem *outliers* devido à oclusão, assim um subconjunto de pontos deve ser considerado, ao invés do conjunto completo. Será utilizado um método estatístico para gerar um limiar de distância dinâmico que permite o alinhamento exclusivo dos pontos mais próximos. O limiar de distância dinâmico é usado para




Figura 5: Comparação das nuvens de pontos adquiridas de uma única superfície sem desgaste (nuvem de pontos da primeira aquisição em vermelho e nuvem de pontos da segunda aquisição em verde).

relaxar as correspondências de modo que um subconjunto seja alinhado a um subconjunto do outro, suportando alinhamentos parciais. O algoritmo utiliza uma distância máxima $D_{\max}^1$ para determinar o subconjunto que será utilizado, com isso cada ponto $\{p_i\}$ no primeiro conjunto cuja distância ao seu ponto mais próximo é menor que $D_{\max}^1$ é mantido juntamente com seu ponto mais próximo $\{q_i\}$ e sua distância $\{d_i\}$. A média μ é dada por $\mu = \frac{1}{N} \sum_{i=1}^N d_i$. A distância tolerável máxima $D_{\max}^1$ é adaptativamente fixada estatisticamente nos valores de distâncias calculados. A média μ é utilizada para atualizar $D_{\max}^1$ (Takimoto et al., 2016). A iteração termina quando a mudança na translação e na rotação for menor que 1%.

3 Resultados

Foram feitos dois tipos de testes. Em um primeiro teste, foram obtidas duas nuvens de pontos a partir da mesma superfície com coincidência parcial da superfície amostrada. Em um segundo teste, foram obtidas nuvens de pontos de uma superfície pré e pós teste de desgaste.

3.1 Testes com a superfície rugosa deslocada

A validação do algoritmo proposto envolveu a aquisição da nuvens de pontos da superfície rugosa sem desgaste. Após uma primeira aquisição, a peça foi deslocada e uma outra aquisição foi realizada. Desse modo, têm-se que a comparação entre as duas aquisições apresenta apenas uma região em comum. A Fig. 5 mostra o par de nuvem de pontos utilizado nos testes. Após a aquisição, imagens 2D foram criadas para identificar e mapear os pontos característicos. A Fig. 6 mostra as imagens 2D juntamente com os pontos característicos mapeados após a aplicação do RANSAC.

A etapa final envolvendo o registro da nuvem de pontos utiliza as coordenadas 3D dos pontos característicos para a recuperação da transformação rígida para registro das nuvens. Aplicando-se a transformação rígida para todos os pontos da nuvem de pontos é possível verificar a correspondência na região comum de imperfeições da superfície




Figura 6: Pontos característicos mapeados após a aplicação do RANSAC, superfície sem desgaste.




Figura 7: Comparação da nuvem de pontos após o mapeamento dos pontos (a escala em Z foi aumentada para uma melhor visualização).

(vide Fig. 7). Considerando somente a região de correspondência, o registro pôde ser verificado numericamente pela subtração dos valores absolutos das coordenadas z de cada ponto correspondente da nuvem de pontos. $D = \frac{1}{N} \sum_{i=1}^N z_i - z'_i$ onde z and z' correspondem à altura z de cada ponto da nuvem de pontos e N é o número de pontos. A diferença é menor que $0.0047\mu m$.

3.2 Testes com a superfície rugosa desgastada

Nos testes de comparação da superfície rugosa desgastada, realiza-se uma aquisição antes do desgaste e uma após o desgaste. Nesta etapa foram utilizadas 10 amostras de uma placa de alumínio de $15 \times 15mm$ com diferentes níveis de desgaste utilizando uma solução de 10% de hidróxido de sódio (NaOH). Durante o processamento das imagens 2D geradas a partir das nuvens de pontos, detectaram-se problemas de mapeamento para os casos de maior desgaste e para as regiões em que a superfície rugosa sem desgaste apresenta um perfil com baixa variação de intensidade. As Figs. 8(a)-(b) apresentam duas amostras onde esses casos estão presentes. Devido ao elevado desgaste presente na superfície e da amplitude limitada dos níveis de cinza verificou-se que a região não desgastada da imagem da superfície com desgaste apresentou baixo contraste, dificultando, com isso, a identificação dos pontos característicos dessa região. Para resolver o problema, foi utilizada a binarização da imagem pela análise do histograma. Desse modo, definiu-se uma altura limiar Z para poder fixar a cor da área desgastada. Com isso, para valores com altura menor que Z , correspondente a área desgastada, a cor foi fixada em preto e para valores maiores que Z a amplitude dos níveis de cinza foi utilizada para melhorar o contraste da área não desgastada. As Figs. 8(c)-(d) mostram




Figura 8: Amostras com problemas no mapeamento dos pontos característicos. (a) Amostra 2. (b) Amostra 8. Amostras em que a região desgastada foi fixada numa determinada cor. (c) Amostra 2. (d) Amostra 8. Superfície original à esquerda, e superfície desgastada à direita.

Tabela 1: Volumes e massas utilizando o método proposto e massas utilizando a balança (A - Amostra, V - Volume, M - Massa, B - Balança)

A	V (mm^3)	M (g)	B (g)
1	$1.09 * 10^{-3}$	$2.93 * 10^{-6}$	$-2.80 * 10^{-5}$
2	$1.85 * 10^{-1}$	$5.00 * 10^{-4}$	$7.73 * 10^{-4}$
3	$1.34 * 10^{-2}$	$3.62 * 10^{-5}$	$1.24 * 10^{-4}$
4	$6.00 * 10^{-2}$	$1.62 * 10^{-4}$	$2.38 * 10^{-4}$
5	$8.14 * 10^{-2}$	$2.20 * 10^{-4}$	$2.78 * 10^{-4}$
6	$8.78 * 10^{-4}$	$2.37 * 10^{-6}$	$8.20 * 10^{-5}$
7	$1.09 * 10^{-2}$	$2.94 * 10^{-5}$	$5.40 * 10^{-5}$
8	$1.68 * 10^{-1}$	$4.54 * 10^{-4}$	$5.04 * 10^{-4}$
9	$9.22 * 10^{-3}$	$2.49 * 10^{-5}$	$4.80 * 10^{-5}$
10	$3.53 * 10^{-3}$	$9.54 * 10^{-6}$	$2.60 * 10^{-5}$

os resultados obtidos por este processo juntamente com o mapeamento dos pontos correspondentes.

A Fig. 9 mostra os resultados finais obtidos após o alinhamento das nuvens de pontos com e sem desgaste. A análise das nuvens de pontos com e sem desgaste permitiu a comparação entre as superfícies e a determinação do volume desgastado e da massa perdida. Para as superfícies analisadas considerando-se que $dx = dy = 6.55\mu m$ e que $\rho = 2.7g/cm^3$, tem-se que o volume e a massa da parte desgastada pode ser recuperada calculando-se a diferença da altura entre a superfície desgastada e não desgastada. A Tabela 1 mostra os valores de volume e massa obtidos pela análise das superfícies juntamente com os valores medidos utilizando uma balança de precisão. Analisando-se as medições obtidas com a balança de precisão verificou-se um ganho de massa para a amostra 1. Como a precisão da balança utilizada é de 10^{-5} , entende-se que o valor obtido para essa amostra apresenta uma baixa confiabilidade. Além disso, a partir da comparação dos resultados obtidos com a balança e com o processamento da nuvem de pontos foi possível verificar uma correlação na variação de massa entre as amostras.




Figura 9: Nuvem de pontos antes e depois do desgaste combinadas. (a) Amostra 2. (b) Amostra 9. (c) Amostra 10.

4 Conclusões e Trabalhos Futuro

As medições realizadas permitiram a comparação da superfície rugosa antes e depois do desgaste. Esta análise foi possível pelo correto registro da área comum de suas respectivas nuvens de pontos. Além de permitir a determinação do volume desgastado e da massa perdida, o sistema proposto possibilitou a visualização da superfície desgastada e a comparação com a superfície não desgastada através do registro da área comum das nuvens de pontos. Apesar disso, para garantir a qualidade, a precisão e a coerência dos dados obtidos, os mesmos precisam ser validados pela comparação com outros métodos e pela avaliação das imprecisões do equipamento de medição.

Agradecimentos

MSG Tsuzuki, TC Martins, RY Takimoto e EK Ueda possuem suporte do CNPq (processos 310.663/2013-0, 306.415/2012-7, 150508/2015-8 e 140518/2015-0). AK Sato e T Cousseau possuem suporte da CAPES (PNPD e projeto A014/2013).

Referências

Besl, P. J. and McKay, N. D. (1992). A method for registration of 3-d shapes., *IEEE Transactions on Pattern Analysis and Machine Intelligence* **14**: 239–256.

Canny, J. (1986). A computational approach to edge detection, *IEEE Trans. Pattern Anal. Mach. Intell.* **8**(6): 679–698.

Choi, C. and Christensen, H. I. (2010). Real-time 3d model-based tracking using edge and keypoint features for robotic manipulation, *IEEE International Conference on Robotics and Automation, ICRA 2010, Anchorage, Alaska, USA, 3-7 May 2010*, pp. 4048–4055.

Cuchet, E., Knoploch, J., Dormont, D. and Marsault, C. (1995). Registration in neurosurgery

and neuroradiotherapy applications, *Journal of Image Guided Surgery* **1**(4): 198 – 207.

Fischler, M. A. and Bolles, R. C. (1981). Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography, *Communications of the Association for Computing Machinery* **24**: 381–395.

Gara, L., Zou, Q., Sangeorzan, B., Barber, G., McCormick, H. and Mekari, M. (2010). Wear measurement of the cylinder liner of a single cylinder diesel engine using a replication method, *Wear* **268**(3-4): 558 – 564.

Jost, H. P., of Education, G. B. D. and Science (1966). *Lubrication (tribology) : education and research : a report on the present position and industry's needs.*, London : HMSO 1966.

Lindeberg, T. (1994). Scale-space theory: A basic tool for analysing structures at different scales, *Journal of Applied Statistics* **21**: 224–270.

Lowe, D. G. (1999). Object recognition from local scale-invariant features, *Proc. of the International Conference on Computer Vision*, Corfu, Greece, pp. 1150–1157.

Pawlus, P. (1997). Change of cylinder surface topography in the initial stage of engine life, *Wear* **209**(1): 69 – 83.

Rubach, S., Riemer, T., Valentin, J. and Delto, C. (2014). Wear detection on cylinder liners with optical 3d measuring technology, *MTZ worldwide* **75**(3): 38–43.

Sobel, I. and Feldman, G. (1968). A 3x3 Isotropic Gradient Operator for Image Processing. Never published but presented at a talk at the Stanford Artificial Project.

Takimoto, R. Y., de Sales Guerra Tsuzuki, M., Vogelaar, R., de Castro Martins, T., Sato, A. K., Iwao, Y., Gotoh, T. and Kagei, S. (2016). 3d reconstruction and multiple point cloud registration using a low precision rgb-d sensor, *Mechatronics* **35**: 11 – 22.

Vacchetti, L., Lepetit, V. and Fua, P. (2004). Combining Edge and Texture Information for Real-Time Accurate 3D Camera Tracking, *Proceedings of the 3rd IEEE/ACM International Symposium on Mixed and Augmented Reality, ISMAR '04, IEEE Computer Society, Washington, DC, USA*, pp. 48–57.

Whitenton, E. P. and Blau, P. J. (1988). A comparison of methods for determining wear volumes and surface parameters of spherically tipped sliders, *Wear* **124**(3): 291 – 309.