

APLICAÇÃO DE IMAGENS E REDE NEURAL CONVOLUCIONAL PARA DETERMINAÇÃO DO FIM DE VIDA DE BROCAS ESCALONADAS

Henry Peterson Scharf

Universidade Federal do Paraná Av. Cel. Francisco H. dos Santos, 100 - Jardim das Américas, Curitiba - PR, 81530-000
Robert Bosch LTDA Av. Juscelino Kubitschek de Oliveira, 11800 – Cidade Industrial, Curitiba - PR 81460-900
henry.hps@hotmail.com

Heraldo Nélio Cambraia

Universidade Federal do Paraná Av. Cel. Francisco H. dos Santos, 100 - Jardim das Américas, Curitiba - PR, 81530-000
heraldo@ufpr.br

João Moraes da Silva Neto

Universidade Federal do Paraná Av. Cel. Francisco H. dos Santos, 100 - Jardim das Américas, Curitiba - PR, 81530-000
joaomsn@ufpr.br

Dalberto Dias da Costa

Universidade Federal do Paraná Av. Cel. Francisco H. dos Santos, 100 - Jardim das Américas, Curitiba - PR, 81530-000
dalberto@upfr.br

Resumo. A furação com brocas escalonadas é utilizada para a usinagem de furos complexos em peças produzidas em larga escala que, comumente, apresentam mais de uma seção transversal, rebaixos e chanfros. A deterioração dessas ferramentas é de maneira geral evidenciada através do desgaste de flanco ou cratera, lascamentos, quebras ou deformação plástica. Porém, devido às geometrias complexas de afiação necessárias na construção desse tipo de broca e a variedade de tipos de deterioração, a tomada de decisão sobre o momento certo para troca da ferramenta não é uma tarefa simples. A inspeção visual é o método normalmente utilizado, porém depende do treinamento do inspetor, sua acuidade visual e ainda se mostra contraproducente em sistemas automatizados de produção, pois se faz necessária a retirada da ferramenta da máquina para inspeção. Existem várias abordagens possíveis que estão sendo estudadas pela comunidade científica. Dentre elas, as técnicas que podem ser embarcadas na máquina têm destaque. Sejam elas através de métodos indiretos que utilizam aquisição de dados que podem ser correlacionados com o nível de deterioração da ferramenta ou métodos diretos, como sistemas de visão. Nesse contexto, o presente trabalho tem como objetivo o desenvolvimento de um sistema automático que utiliza imagens da ferramenta para a determinação do fim de vida de brocas escalonadas quando empregadas na produção de grandes lotes de peças, baseando em modelo de tomada de decisão usando redes neurais artificiais.

Palavras chave: Brocas escalonadas. Deterioração de brocas. Inspeção por imagens. Redes neurais artificiais.

1. INTRODUÇÃO

A furação é um processo largamente utilizado na produção de componentes para diversas aplicações e tem um destaque especial no processo de usinagem para a produção de furos simples ou complexos, tais como aqueles compostos por mais de uma seção transversal. No caso desses furos complexos, a usinagem pode ser realizada com o uso de uma ferramenta para cada uma de suas seções ou com uma broca escalonada (Black e Kohser, 2019). Brocas escalonadas são ferramentas que possibilitam a realização da furação em cheio (1º diâmetro) e dos rebaixos e escareamentos por meio de suas seções subsequentes. Apesar de serem ferramentas de geometria mais complexa, as brocas escalonadas são extremamente vantajosas para a usinagem de um grande lote de peças (Black e Kohser, 2019).

De modo geral, a deterioração das brocas acontece por diversas causas e se desenvolve de modos distintos em suas diferentes superfícies. Os tipos mais comuns de deterioração são os desgastes (flanco e cratera), os lascamentos, quebras e as deformações plásticas (principalmente em brocas de aço rápido) (Astakhov, 2014).

Diante dessa variedade de tipos de deterioração, a tomada de decisão sobre o momento certo de trocar a broca não é uma tarefa trivial. A inspeção visual parece ser a técnica mais eficaz, porém depende da acuidade visual do inspetor e possui sérias limitações para aplicação em sistemas de produção automatizados, aonde a retirada de ferramentas para inspeção é contraproducente.

Contribuições no sentido de sanar o problema relacionado com a retirada da ferramenta no momento ideal, várias abordagens têm sido apresentadas, sendo que dentre elas destacam-se: a modelagem empírica, como por exemplo a equação de Taylor (Timata e Saikaew, 2019); a modelagem do desgaste por elementos finitos (Attanasio et al., 2020); a

decisão baseada na qualidade da superfície usinada (Martins et al., 2021); a aquisição automática de imagens da região desgastada (Atli A.V. et al., 2006); e o monitoramento indireto por meio de outras grandezas de processo, tais como vibração, emissão acústica, pressão sonora, corrente elétrica do motor principal e temperatura (Lauro et al., 2014). De acordo com Simon e Deivanathan (2019) a modelagem matemática é de difícil aplicação na determinação do fim de vida, tendo em vista que o desgaste se desenvolve em diferentes estágios. Segundo (Ertunc e Oysu, 2004) esses estágios seriam: desgaste inicial; desgaste leve (regular); desgaste moderado, incluindo micro quebras; desgaste severo (taxas elevadas) e, por fim, a quebra da aresta de corte.

A avaliação da qualidade dos furos, apesar de ser uma abordagem muito eficaz, pois trata-se de um critério de desempenho muito importante, é geralmente feita “off line” e, por conseguinte, possui algumas das limitações da inspeção visual. No caso de uma decisão tardia, i.e., a máquina continua produzindo enquanto a análise de qualidade é realizada, eventuais refugos de peças poderão ser gerados.

Aparentemente, existe um maior esforço por parte da comunidade científica na investigação de técnicas que possam ser embarcadas na máquina, seja por meio de sistemas de visão (Dutta et al., 2013) ou pela medição indireta de grandezas que possam ser correlacionadas à deterioração da ferramenta (Ambhore et al., 2015).

Independente da técnica embarcada na máquina, a determinação do fim de vida da ferramenta depende fortemente da qualidade dos dados obtidos, da separação de características relevantes e da capacidade de processamento rápido. A utilização de técnicas de inteligência artificial, mais precisamente as redes neurais artificiais, tem se mostrado eficaz para a modelagem e tomada de decisão neste propósito. (Serin et al., 2020).

Ao cenário descrito anteriormente, acrescenta-se que no caso de furações com brocas escalonadas, a inspeção visual como método para determinação do fim de vida é quase que impossível de ser aplicada, tornando necessária a adoção de métodos indiretos e automáticos para a decisão do momento certo de se efetuar a troca de ferramentas.

Neste contexto, o objetivo deste trabalho é apresentar o desenvolvimento de um sistema automático para a determinação do fim de vida de brocas escalonadas quando empregadas na produção de grandes lotes de peças. O sistema aqui proposto será detalhado mais adiante e é baseado na aquisição de imagens da broca e em um modelo de decisão que baseia seu funcionamento na utilização de uma rede neural convolucional.

2. MATERIAIS E MÉTODOS

A metodologia descrita a seguir faz parte de um projeto maior, em desenvolvimento em uma empresa metalúrgica de grande porte, o qual tem por objetivo a transição para o ambiente denominado Indústria 4.0. Atualmente nessa empresa, a troca de ferramentas é feita pelo operador da máquina e é baseada em dados disponíveis no plano de processos, os quais foram, previamente, calculados a partir de médias históricas. Por isso não levam em consideração as variações inerentes aos processos de fabricação.

O processo de furação com broca escalonada aqui reportado é aplicado na produção em grandes lotes de um componente para motores de combustão a diesel. Dessa forma, modificações na geometria e no material da broca, bem como nas demais condições de corte estão fora do escopo deste trabalho. Também estão fora do escopo do projeto a utilização de sistemas que tenham influência negativa na disponibilidade de máquina.

2.1. Materiais

O componente em estudo, vide desenho esquemático Fig. 1(a), é uma bomba injetora unitária, responsável pela injeção de diesel em motores de grande porte, o material é de difícil usinagem em função da forma de fornecimento (SAE 4144M forjado) da microestrutura martensítica obtida pelo processo de tratamento térmico e da dureza de 38 HRC. A microestrutura resultante do tratamento térmico é 100% martensita revenida.

As brocas utilizadas (vide fig. 1 (b)) são do tipo inteiriças fabricados em metal-duro (ISO K30/K40) pela empresa Konrad e afiação realizada pela empresa Sumitomo. As ferramentas recebem uma camada de revestimento (deposição física de vapor - PVD), comercialmente conhecido por “TiNAl” (espessura da camada de 3 μm) já executada pelo fornecedor.

Todo o processo de furação é lubri-refrigerado com uma emulsão do tipo semissintética, comercializado pela empresa Fuchs pelo nome “Ecocool durant 71”.

As condições de corte atuais são: rotação de 1800 rpm, velocidade de avanço de 216 mm/min até 11mm de profundidade e velocidade de avanço de 162mm/min até a profundidade de 17,983mm.

A furação ocorre em um centro de usinagem marca Grob, modelo BZ 500 equipado com comando marca Siemens, modelo sinumerik 840D. O referido comando possibilita o controle de movimentos em três eixos (X,Y,Z) além da movimentação do magazine de ferramentas (eixo Q) de forma simultânea.

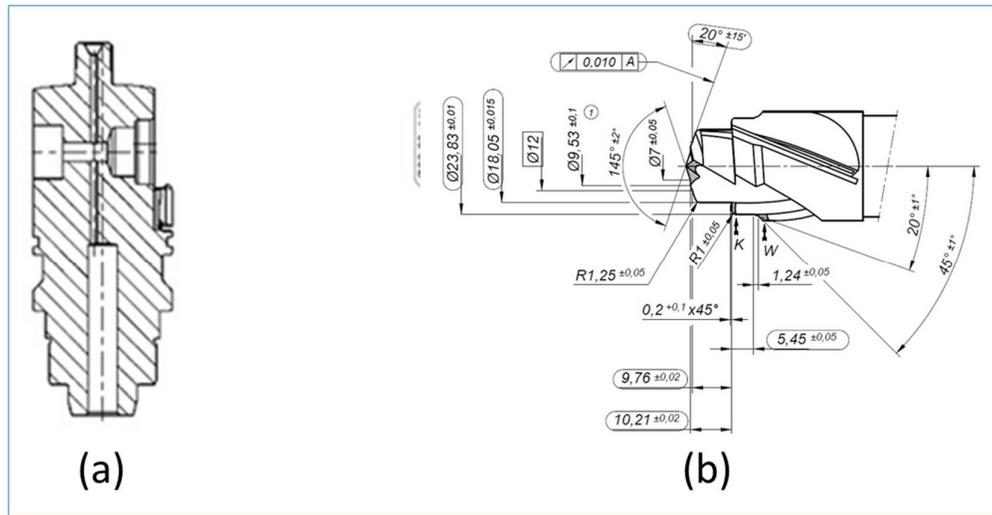


Figura 1. Peça (a) e broca (b) utilizadas neste estudo.

2.2. Métodos

A metodologia aqui proposta pode ser dividida, de maneira geral, nas seguintes etapas: aquisição, rotulagem automática, armazenamento, classificação manual, treinamento da rede neural artificial (RNA) e validação do processo de decisão sobre o fim da vida da ferramenta. A Fig. 2 contém uma representação da metodologia adotada neste trabalho.

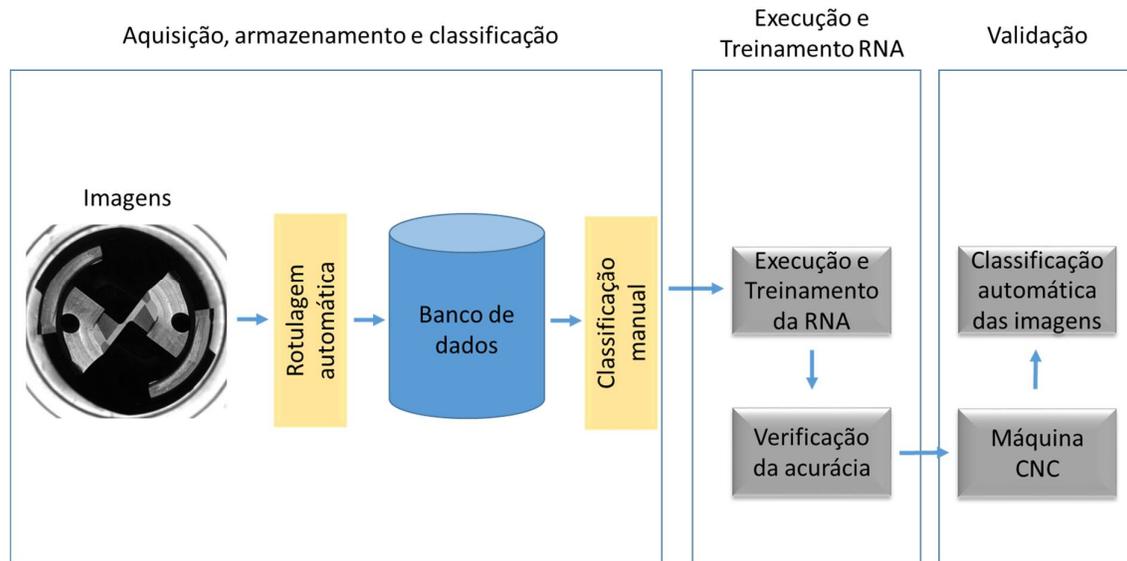


Figura 2. Etapas da metodologia do projeto.

A aquisição das imagens foi realizada automaticamente após cada ciclo de usinagem, que era composto por 8 pçs, com o auxílio de uma câmera com sensor CMOS marca Allied, modelo Manta G1236 integrada no magazine de ferramentas da máquina. O centro de usinagem permite que o magazine de ferramentas se movimente simultaneamente nos eixos X, Y e Z, excluindo assim o tempo necessário para obtenção das fotos, no interior do magazine, após o ciclo de usinagem. A lente utilizada é adequada para uma resolução de 12Mp, tem 16 mm de distância focal e regulagem de abertura da íris, F 2 a 22. O controle da aquisição de imagens é feito pelo software Vimba, desenvolvido pelo fornecedor da câmera. O sistema de iluminação é do tipo domo, proporcionando uma iluminação difusa, portanto toda a ferramenta recebe uma quantidade de luz igual, fazendo com que a foto tenha um bom contraste e não tenha áreas esbranquiçadas devido a iluminação excessiva. O esquema de montagem da câmera e do sistema de limpeza no magazine de ferramentas pode ser observado na Figura 3.

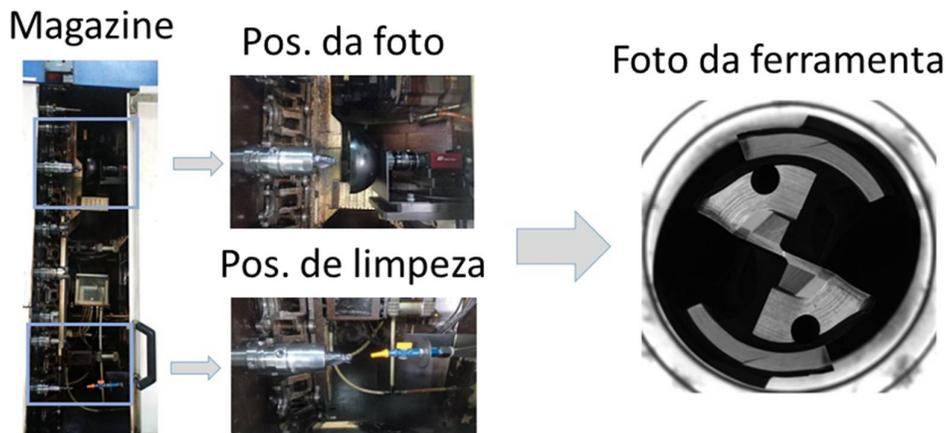


Figura 3. Esquema de montagem do sistema de coleta de imagem no magazine da máquina.

A câmera digital, bem como o condicionador de sinais foram integrados e ligados a um computador industrial, marca Beckhoff, modelo CX5140-0155. Esse, por sua vez, se comunica com o CLP e o CNC da máquina de usinagem, bem como o servidor da rede, assim coletando dados, como a vida da ferramenta e o horário do início do ciclo de usinagem para rotulagem de dados, após isso salvando os dados e as imagens em um diretório pré-definido no servidor. Todos as fotos receberam nomes automaticamente, com informações provenientes da comunicação com a máquina CNC, para que pudessem ser correlacionados com as ferramentas. Esses nomes contêm a norma da ferramenta, vida útil, inventário da máquina, dia, mês, ano, hora, minuto e segundo. Assim cada foto recebe um nome único, possibilitando a rastreabilidade dos dados.

Foi utilizada uma rede neural convolucional (RNC) para classificar as imagens em ok e não ok, baseando-se na condição da ferramenta. Para isso, quando o banco de dados de imagens atingiu 5000 fotos classificadas, foram utilizadas 4000 fotos (80%) para o treinamento da rede neural e 1000 fotos (20%) para validação do modelo de decisão baseado na RNC. Dentre as 5000 fotos classificadas existiam apenas 8% de fotos classificadas como ferramentas quebradas. Isto constitui-se em um fator limitante da acuracidade atingida durante a validação do treinamento da rede neural. A estrutura da RNC utilizada pode ser vista na Fig. 4.

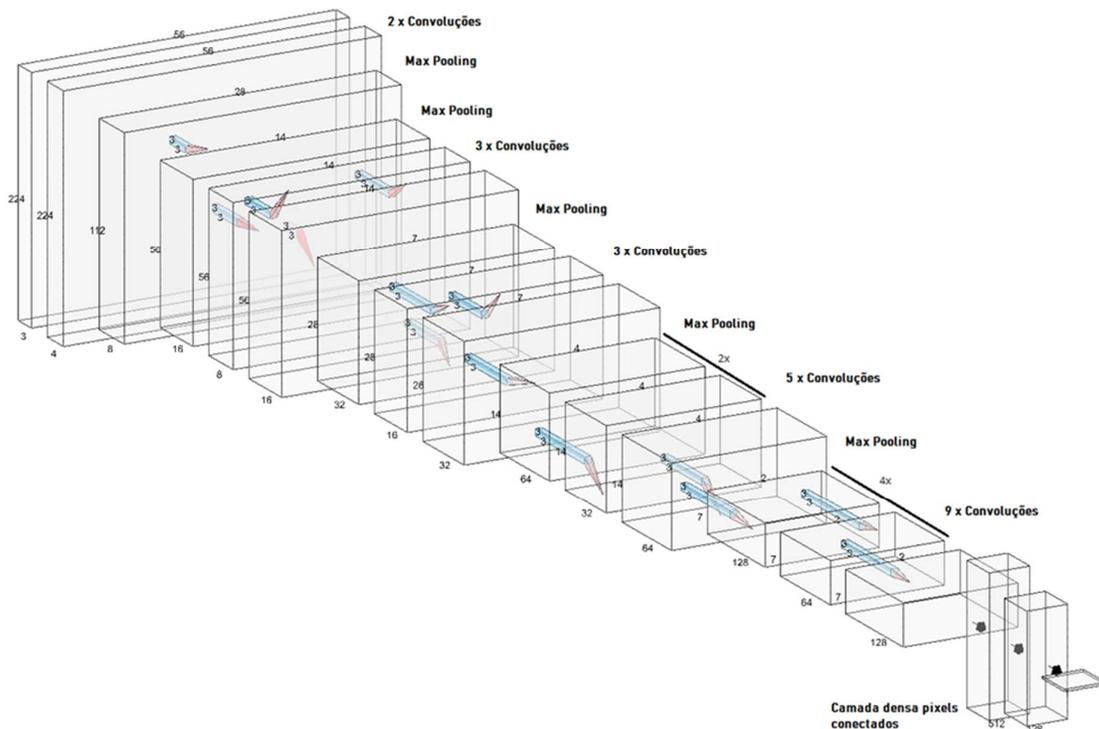


Figura 4. Estrutura da RNC utilizada.

Uma RNC pode ser dividida basicamente em duas partes. A primeira parte possui camadas alternadas de convolução e ativação, responsáveis por extrair características da imagem por meio de filtros e *pooling*, responsáveis por reduzir a escala da imagem e para acelerar o tempo de aprendizagem. A segunda parte de uma RNC é uma camada de neurônios densa e completamente conectada, consistindo-se em uma rede neural tradicional, responsável pela classificação da imagem de entrada com base nas informações filtradas que os neurônios da camada densa receberam. Mais detalhes sobre RNCs podem ser vistos em Vargas et al. (2016).

A camada de convolução é uma camada composta por vários neurônios, que tem a tarefa de aprender quais filtros devem ser utilizados em cada pedaço específico da imagem de entrada e o peso de cada filtro é aprendido durante as rodadas de treinamento da RNC. Cada neurônio é conectado a diversos pixels da imagem na camada anterior e cada filtro aprendido é um extrator de características. O tamanho do filtro define a quantidade de pixels que serão processados por cada neurônio. Esse processo é utilizado para que as imagens filtradas evidenciem a característica que determina a classe procurada na imagem, tal como proposto por Martínez-Arellano et al. (2019).

Logo após a camada convolucional, normalmente é aplicada uma camada de ativação na qual são adicionadas funções de ativação aos neurônios, assim fazendo com que eles apliquem transformações não lineares nos dados. (Vargas et al., 2016).

A camada de *Pooling*, também chamada de camada de agrupamento, é responsável pela redução da dimensão da matriz dos dados de entrada, agrupando-os em uma nova matriz de tamanho reduzido. Considerando que uma imagem hipotética possa ser representada por uma matriz com 4 colunas e 4 linhas (vide Fig. 5), a função *pooling* subdivide-a em janelas de tamanho definido pelo programador da RNC, por exemplo 2 x 2. Desse modo, cada janela terá apenas um valor que representará os valores contidos no intervalo da matriz 2 x 2 escolhido, conforme ilustrado na Fig. 5. Essa redução no tamanho da matriz é importante para agilizar o tempo de processamento durante o treinamento da RNC. O tipo mais comum de *pooling* é a função de máximo, tal como utilizado por Martínez-Arellano et al. (2019).

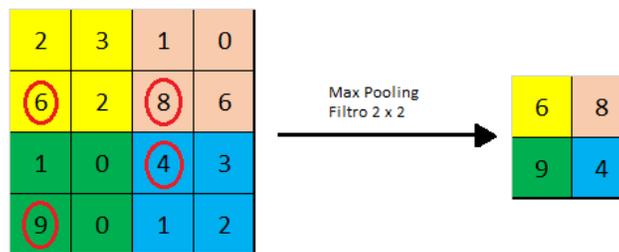


Figura 5. Funcionamento do *Max Pooling*.

No trabalho aqui reportado, a validação foi feita em duas etapas, primeiramente a RNA classificava as imagens e os dados de máquina colocando o resultado da classificação no nome da imagem. Na segunda etapa, com base nos nomes das fotos classificadas pela RNA e armazenadas no banco de dados, validou-se o modelo comparando-se os resultados da RNA com aqueles obtidos pela inspeção visual das brocas.

O software utilizado para escrita de todo o código para a concepção da rede neural aqui proposta foi o PyCharm versão Community 2019.1, o qual tem como base a linguagem Python versão 3.

3. RESULTADOS

3.1. Formação do data-set

Uma das principais atividades da primeira etapa foi constituída pela coleta de dados. Para aumentar a confiabilidade dos resultados foram utilizadas 65 ferramentas e mais de 45000 furos foram executados para análise e estudo dos dados coletados. As imagens foram coletadas e classificadas manualmente em quatro classes, são elas: ferramenta nova, ferramenta ok, ferramenta quebrada, ferramenta com cavaco. Para simplificação do treinamento da rede neural as classes ferramenta nova e ferramenta ok foram agrupadas e a classe ferramenta com cavaco foi excluída do treinamento, por se tratar de uma exceção no *data set*. As classificações atribuídas podem ser vistas na Fig. 6.



Figura 6. Classificações atribuídas as ferramentas.

3.2. Dados de entrada na Rede Neural Convolutacional

Um dos fatores primordiais para o atingimento de uma alta acuracidade pela RNC é a qualidade dos dados de entrada na rede durante a fase de treinamento. O primeiro treinamento da RNC foi feito com a imagem inteira da ferramenta, porém de tamanho reduzida, aproximadamente 1 megapixel. Nesse treinamento a rede neural se mostrou instável e a acuracidade na validação dos dados teve uma tendência de diminuição. Os melhores resultados foram de apenas 50% de acuracidade. Isso aconteceu devido à falta de resolução da imagem, pois o desgaste das arestas de corte se desenvolve em uma região muito pequena, isto é, aonde ocorre o corte propriamente dito. O valor desse desgaste varia entre 0,01 mm até 0,06 mm para a ferramenta e condições aqui estudadas. A utilização da foto completa também não gerou bons resultados devido às perturbações causadas pela luminosidade, cor, brilho e etc durante a vida da ferramenta.

A Figura 7 mostra um exemplo dessa redução de acuracidade, cuja avaliação foi efetuada pela aplicação de um recurso denominado *Class Activation Map* (CAM), por meio do qual a rede neural executa um mapa de calor que mostra as regiões de maior ativação. Pode-se observar que as regiões de maior ativação, cor vermelha na foto, coincidem com os canais para passagem do cavaco, os quais são de pouca importância para a avaliação do fim de vida.

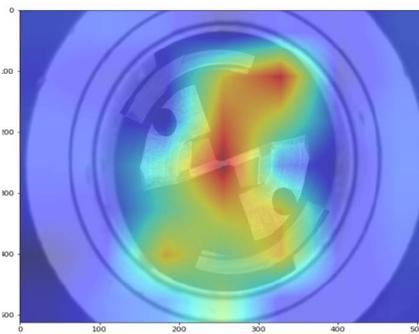


Figura 7. Análise CAM para confirmação das regiões de maior ativação da rede neural.

No segundo teste do treinamento da RNC as imagens foram cortadas, de forma que nas regiões de interesse, as arestas de corte fossem localizadas e concatenadas, com o auxílio de uma rede neural adicional, gerando uma nova imagem, conforme ilustrado na Fig. 8.

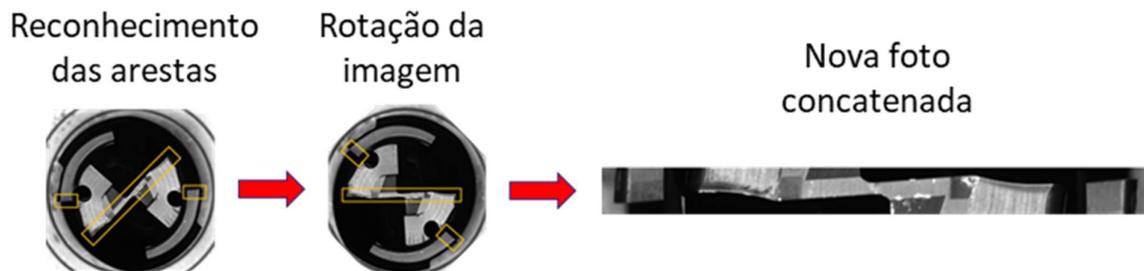


Figura 8. Nova foto concatenada, mostrando apenas as regiões de interesse (arestas de corte).

Com essa abordagem adotada neste segundo treinamento, os resultados da avaliação da validação dos dados para verificação da acurácia foram mais estáveis, atingindo o valor de aproximadamente 75%.

Na terceira e última tentativa de treinamento da RNC a imagem concatenada foi subdividida em 11 partes, conforme Fig. 9, cada divisão da imagem foi classificada separadamente. Esse procedimento foi necessário pois, mesmo avaliando apenas a região de interesse da foto, arestas de corte, ainda existem mesmo para uma broca classificada como não ok regiões as quais a ferramenta ainda estava em condições de uso. Com isso a acurácia atingida durante a validação do treinamento executada com os 20% dos *data-set* foi de aproximadamente 92%. Valor este que se aproxima daquele reportado por Martínez-Arellano et al (2019).



Figura 9. Imagem da região de interesse dividida em 11 partes e classificada individualmente.

5. CONCLUSÕES

Com base nos dados apresentados acima, pode-se concluir que a utilização de RNAs no auxílio da determinação do momento ótimo para troca de brocas helicoidais escalonadas foi validada com o atingimento de uma acurácia de aproximadamente 92%, conforme Figura 10.

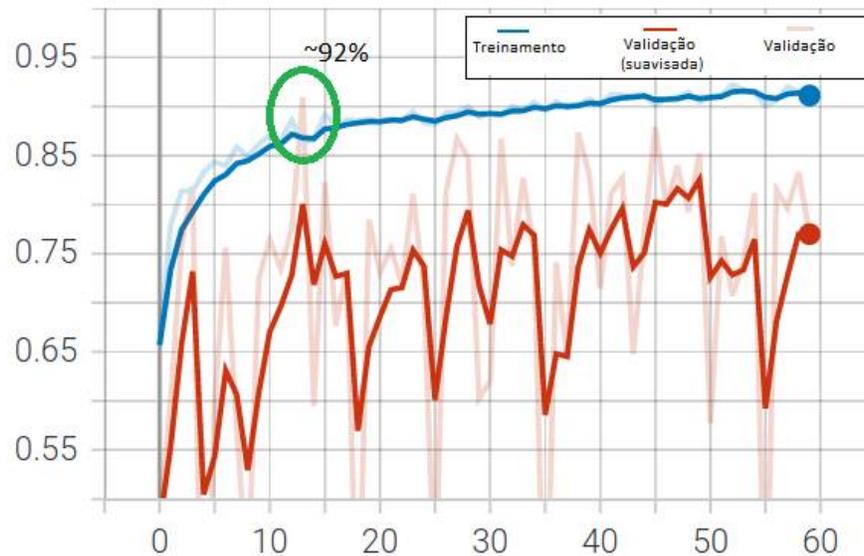


Figura 10. Acurácia atingida após o treinamento da RNC

Durante o treinamento da rede neural convolucional os principais fatores para o atingimento de uma alta acurácia foram: a quantidade de fotos coletadas no banco de dados; a qualidade da foto, considerando a nitidez, iluminação, brilho, foco; e a resolução das imagens. também são. A definição das regiões de interesse, as quais continham apenas as arestas de corte, e ainda a subdivisão e subsequente reclassificação das imagens influenciaram de forma positiva no resultado atingido.

6. REFERÊNCIAS

- Ambhore, N. et al. 2015. "Tool condition monitoring system: A review". *Materials Today: Proceedings*. Vol. 2, n. 4-5, p. 3419-3428.
- Astakhov, V. P., 2014. *Drills: Science and Technology of Advanced Operations*. CRC Press - Taylor & Francis Group, New York.
- Atli A.V. et al., 2006. "A computer vision-based fast approach to drilling tool condition monitoring" *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*. Vol. 220(9), p.1409-1415.
- Attanasio, A. et al. 2020 "Numerical simulation of tool wear in drilling Inconel 718 under flood and cryogenic cooling conditions" *Wear*, Vol. 458-459. .
- Black, J.T., Kohser, R.A., 2019. *Degarmo's Materials and Processes in Manufacturing*. Wiley, Hoboken, 13ª edição.
- Dutta, S. et al., 2013. "Application of digital image processing in tool condition monitoring: A review". *CIRP Journal of Manufacturing Science and Technology*. Vol.6 (3), p. 212-232
- Ertunc, H. M., and Oysu, C., 2004, "Drill Wear Monitoring Using Cutting Force Signals," *Mechatronics*. Vol. 14, N. 5, p. 533-548.
- Lauro, C.H. et al., 2014. "Monitoring and processing signal applied in machining processes – A review". *Measurement*, Vol. 58, P. 73-86.
- Martínez-Arellano, G.; Terrazas, G.; Ratchev, S. 2019. "Tool wear classification using time series imaging and deep learning". *International Journal of Advanced Manufacturing Technology*. Vol. 104, n. 9-12, p. 3647-3662.
- Martins, P.S, et al., 2021 "Study on roughness and form errors linked with tool wear in the drilling process of an Al-Si alloy under high cutting speed using coated diamond-like carbon high-speed steel drill bits" *Journal of Manufacturing Processes*, Vol. 62, p. 711-719.
- Serin, G. et al. 2020. "Review of tool condition monitoring in machining and opportunities for deep learning". *Int J Adv Manuf Technol*. Vol. 109, p. 953-974.

- Simon, G.D. e Deivanathan, R. 2019. "Early detection of drilling tool wear by vibration data acquisition and classification". *Manufacturing Letters*, Vol. 21, p. 60-65
- Timata, M. e Saikaew, C., 2019." Experimental and Simulation Study on Tool Life Models in Drilling of Forging Brass Using Uncoated-WC and AlCrN Coated-WC Tools" *Coatings*, Vol 9, N 12, p. 1-14
- Vargas, A. C. G.; Paes, A. e Vasconcelos, C. N. 2016. "Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres". In *Proceedings of the XXIX Conference on Graphics, Patterns and Images*, p. 1–4, 2016

IMAGE APPLICATION AND CONVOLUCIONAL NEURAL NETWORK FOR DETERMINING THE END OF TOOL LIFE OF STEP DRILLS

Henry Peterson Scharf

Universidade Federal do Paraná Av. Cel. Francisco H. dos Santos, 100 - Jardim das Américas, Curitiba - PR, 81530-000
Robert Bosch LTDA () Av. Juscelino Kubitschek de Oliveira, 11800 – Cidade Industrial, Curitiba - PR 81460-900
henry.hps@hotmail.com

Heraldo Nélio Cambraia

Universidade Federal do Paraná Av. Cel. Francisco H. dos Santos, 100 - Jardim das Américas, Curitiba - PR, 81530-000
heraldo@ufpr.br

João Morais da Silva Neto

Universidade Federal do Paraná Av. Cel. Francisco H. dos Santos, 100 - Jardim das Américas, Curitiba - PR, 81530-000
joaomsn@ufpr.br

Dalberto Dias da Costa

Universidade Federal do Paraná Av. Cel. Francisco H. dos Santos, 100 - Jardim das Américas, Curitiba - PR, 81530-000
dalberto@upfr.br

Abstract. *Drilling with stepped drills for machining complex holes in parts produced on a large scale, which commonly have more than one cross-section, recesses and chamfers. The deterioration of these tools is generally evidenced through the flank wear or crater, chipping, breaks or plastic deformation. However, due to the complex sharpening geometries required in the construction of this type of drill and the variety of types of deterioration, deciding on the right time to change the tool is not a simple task. Visual inspection is the method normally used, though it depends on the inspector's training, his visual acuity and is still counterproductive in automated production systems, as it is necessary to remove the tool from the machine for inspection. There are several possible approaches, which are being studied by the scientific community; among them, the techniques that can be loaded on the machine are highlighted. Whether through indirect methods that use data acquisition that can be correlated with the level of deterioration of the tool or direct methods, such as vision systems. In this context, the present work aims to develop an automatic system that uses images of the tool to determine the end of life of stepped drills when used in the production of large batches of parts, basing the decision-making model on the use of an artificial neural network.*

Key words: *Stepped drills. Tool deterioration. Image inspection. Artificial neural networks.*