

Projeto e Implementação de um Classificador Autônomo Baseado no Processamento Digital de Imagens de Espiras de Fio-Máquina

Edgar Campos Furtado * Leonardo Adolpho Rodrigues da Silva *
Celso Vidal Brito Filho * Jose Antonio Toledo *

* Núcleo de Inovação, Pesquisa e Ensino em Engenharia Mecatrônica.
Universidade Federal de São João del-Rei. Ouro Branco, MG, Brasil.
(e-mails: edgar@ufsj.edu.br; leonardo@ufsj.edu.br;
celsofilho_ap@hotmail.com; jose.toledo@ufsj.edu.br).

Abstract: This work presents the design and implementation of an autonomous classifier that scores the quality of wire rod coil formation based on the irregularity of the coil formation on the roller table. Digital processing techniques were applied to grab images of the coil former/roller table. In the classifier design were considered regions of interest, in which attributes were extracted and labels were created. The scores estimated by the designed classifier are in consonance with the scores assigned by an expert in wire rod coils formation process. Thus, the classifier can be used to assist operational decision making related to changes in process parameters, such as formation speed, in order to increase the coils uniformity on the roller table, which can minimize possible material losses and increases the production and the quality of the final product.

Resumo: Este trabalho apresenta o projeto e a implementação de um classificador autônomo que pontua a qualidade da formação das espiras de fio-máquina, com base na irregularidade da formação das espiras sobre a mesa de rolos. Foram aplicadas técnicas de processamento digital em imagens capturadas do formador de espiras/mesa de rolos. Para o projeto do classificador, regiões de interesse foram definidas, atributos foram extraídos e rótulos foram criados. As notas geradas pelo classificador projetado estão de acordo com as notas designadas por um especialista na formação de fio-máquina. Assim, o classificador pode ser utilizado para auxiliar na tomada de decisão em relação a mudanças de parâmetros do processo, como a velocidade de formação, visando aumentar a uniformidade das espiras na mesa de rolos, o que minimiza possíveis perdas de material, aumentando produção e a qualidade do produto final.

Keywords: Pattern Classifier; Digital Image Processing; Wire Rod coil; Coil Alignment.

Palavras-chaves: Classificador de Padrões; Processamento Digital de Imagens; Laminação de Fio-Máquina; Alinhamento das Espiras.

1. INTRODUÇÃO

A indústria siderúrgica tem importância estratégica no desenvolvimento de um país, tanto social quanto economicamente (AISI, 2018; IAB, 2020; Viana, 2018). Os produtos siderúrgicos podem ser considerados insumos básicos em muitos contextos. Os aços planos podem ser usados, por exemplo, na indústria automotiva e marítima, enquanto os aços longos, como fios, tubos e perfis, podem ser utilizados na construção civil, óleo e gás, entre outras.

Em 2020, o Brasil foi o 12º maior exportador de produtos siderúrgicos do mundo, responsável por 29,7 milhões de toneladas produzidas. No país, o parque siderúrgico é composto por 31 usinas que empregam cerca de 103 mil pessoas, sendo responsáveis por um saldo comercial de 3,1 bilhões de dólares (IAB, 2020).

Em geral, os processos de transformação na siderurgia envolvem grandes quantidades de energia. Nesse contexto, um aumento na eficiência do processo pode gerar impacto significativo, tanto em relação ao custo quanto em relação

a outras taxas de produção (Viana, 2018). No entanto, quantificar a eficiência ou mesmo a qualidade de um processo é uma tarefa complexa. De fato, essa questão pode envolver vários fatores combinados, que podem ser baseados em características intrínsecas do processo e conhecimento de especialistas.

A síntese das informações para encontrar padrões de resposta em processos industriais é um passo importante para quantificar a eficiência. A partir do mapeamento de padrões, chamado de *clustering*, é possível prever ações e/ou prevenir situações indesejáveis na produção, ou seja, pode-se tomar decisões em relação ao processo visando maior eficiência, por exemplo.

O presente trabalho aborda a aplicação industrial de produção de bobinas de fio-máquina. O processo produtivo, ilustrado na Fig. 1, é baseado em cadeiras de laminação a quente, que transformam um tarugo de aço de seção transversal retangular em um fio longo de seção transversal circular. Os fios são contorcidos em espiras que irão compor bobinas.



Figura 1. Bobinas de fio-máquina sendo transportadas. Retirado de Jatlas (2022).

A velocidade do aço durante o processo de conformação pode chegar a 130 m/s, nas últimas etapas de laminação (Taurino et al., 2016), e a temperatura do fio-máquina no momento da formação da espira é cerca de 900 °C (Mukhopadhyay e Bhattacharyya, 2013), o que torna a tarefa de sensoriamento complexa.

Um dos desafios deste processo é obter uma formação de espiras, na mesa de rolos, o mais uniforme e com o menor tempo possível. A uniformidade da formação das voltas das espiras pode minimizar possíveis perdas na etapa de bobinamento. Essa formação é dependente de vários fatores, contudo o mais significativo é a velocidade do processo de formação.

Desta forma, este trabalho tem como objetivo apresentar o projeto de um classificador de padrões autônomo para quantificar a eficiência de formação por meio de uma pontuação de zero a dez, a partir de características mensuradas pelo processamento digital das imagens de formação de espiras do fio-máquina. Essa pontuação pode auxiliar na tomada de decisão em relação a mudanças de parâmetros do processo, como a velocidade de formação, visando aumentar a uniformidade das espiras na mesa de rolos, o que minimiza possíveis perdas de material e aumenta a qualidade do produto final.

O texto é organizado da seguinte forma: a Seção 2 apresenta o processo de produção de bobinas de fio-máquina e introduz a questão principal desse trabalho, que é o nível de alinhamento das espiras na mesa de rolos. A Seção 3 detalha as etapas de aquisição das imagens, definição das regiões de interesse e extração dos atributos. Com base nos atributos, a Seção 4 mostra a transformação dos mesmos em rótulos e detalha o projeto do classificador autônomo. A Seção 5 aborda o treinamento desse classificador e a Seção 6 mostra a aplicação do mesmo em uma formação completa de fio-máquina, gerando notas de zero a dez condizentes com aquelas avaliadas por especialistas no processo. Por fim, conclusões são apresentadas na Seção 7.

2. PROCESSO DE PRODUÇÃO DE FIO-MÁQUINA COM FOCO NO FORMADOR DE ESPIRAS

Uma planta de fio-máquina é constituída por um conjunto de cadeiras de laminação, conforme ilustrado na Fig. 2, que são usadas para reduzir a área e o formato da seção transversal de um bloco de metálico, geralmente denominado de tarugo (Bastos et al., 2020).



Figura 2. Planta típica de produção de fio-máquina. Retirado de Bastos et al. (2020).

De acordo com a utilização final do fio-máquina, escolhe-se a bitola final da seção transversal, sendo tipicamente de 5,5 a 22,0 mm de diâmetro (Bastos et al., 2020). Independentemente da bitola, após a última cadeira, o fio-máquina é convertido de uma geometria reta para uma geometria espirada por meio do formador de espiras, mostrado na Fig. 3(a). Esse procedimento é necessário para formação, compactação e transporte das bobinas que são produzidas com essas espiras.




Figura 3. (a) Fotografia do formador de espiras, retirado de Taurino et al. (2016), e (b) desenho do tubo formador, modificado de Mukhopadhyay e Bhattacharyya (2013).

O formador de espiras é implementado por um tubo de metal que é dobrado em uma geometria espiral de Arquimedes, conforme representado na Fig. 3(b). Este tubo é acionado por um motor elétrico que desenvolve torque na direção longitudinal do eixo do tubo.

A qualidade da formação pode ser associada ao nível de alinhamento das espiras na mesa de rolos, conforme apresentado na Fig. 4. Este alinhamento é impactado pela vibração do formador de espiras. Se o desalinhamento for excessivo, a etapa final do bobinamento pode não ser possível, acarretando em prejuízos pela perda de todo o material (tarugo).




Figura 4. Diferentes níveis de alinhamento na formação de espiras, sendo: (a) formação pouco adequada, candidata a receber nota 1 (um), enquanto (b) formação adequada, candidata a receber nota 9 (nove).

Para dar suporte às ações de manutenção e gerenciamento, os níveis de desalinhamento são avaliados por engenheiros metalúrgicos especialistas, por meio de uma escala de notas que varia de zero a dez. A nota é aplicada por inspeção visual, sendo zero para a formação não conforme (nível máximo de irregularidade), enquanto dez representa uma formação com máxima adequação.

Vale ressaltar que a nota da formação deve ser baseada na percepção e experiência dos operadores do processo, em geral, engenheiros metalúrgicos.

3. PROCESSAMENTO DIGITAL DE IMAGEM

O processamento digital de imagens é um conjunto de técnicas que visa extrair informações e/ou características de imagens, sendo dividido em: captura ou aquisição de imagens e processamento de complexidade baixa, média e alta (Annadurai e Shanmugalakshmi, 2007), conforme mostra o diagrama de blocos da Fig. 5.

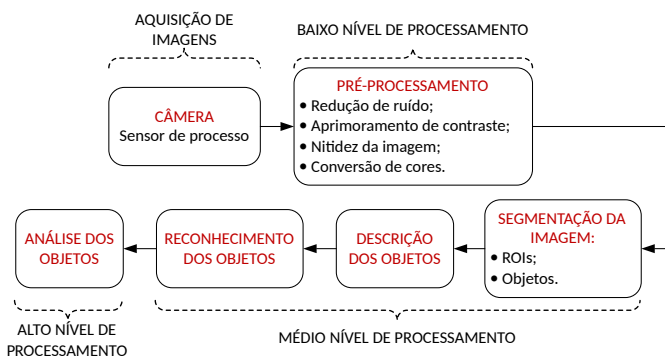


Figura 5. Diagrama de blocos de um processamento digital de imagens.

O processamento digital da imagem inicia-se com um comando enviado ao sensor de processo (câmera), pela interface Ethernet, solicitando uma nova imagem. Alguns parâmetros de configuração são necessários na instrução de comando. Como resultado, a interface da câmera processa o comando que retorna a nova imagem capturada. O sensor de processo é detalhado na Seção 3.1.

A partir da imagem capturada, o processamento de nível baixo é feito. Nesse estágio, a redução de ruído, o aprimoramento de contraste, a nitidez da imagem, a conversão de cores e outras técnicas podem ser usadas para enfatizar alguns recursos da imagem.

O primeiro passo no processamento de nível médio é a definição das regiões de interesse (do inglês, *region of interest* ou ROI), que são partes de uma imagem que contém os objetos de interesse. Esta etapa é detalhada na Seção 3.2. A partir de tais regiões é possível reduzir o tempo de processamento, pois os algoritmos são aplicados em uma parte da imagem, em vez da imagem completa. Em seguida, atributos podem ser extraídos das ROIs, como bordas, contornos e identidade dos objetos individuais.

Por fim, no processamento de nível alto são analisadas as informações ou objetos extraídos na etapa anterior. Neste trabalho, tais informações tornam-se rótulos, que são utilizados pelo classificador autônomo para pontuar a formação retratada pela imagem em análise.

3.1 Sensor de Processo

Como mencionado anteriormente, o sensoriamento na etapa de formação da espira é uma tarefa complexa, pois a temperatura pode atingir 900 °C. Além disso, algumas informações são difíceis de extrair com sensores convencionais como, por exemplo, a borda da formação na mesa de rolos. Tais desafios podem ser superados pelo uso de uma câmera como sensor. As imagens capturadas, como aquelas mostradas na Fig. 4, podem ser processadas para extrair informações diferentes do processo.

A câmera selecionada é da fabricante Baumer, modelo LXG-20.P, tecnologia VisualApplets, sistema GigE Vision, sensor CMOS, monocromática, capacidade de 140/56 FPS (do inglês, *frames per second* ou FPS) e resolução de imagem de 2048 × 1088 pixels. Esse dispositivo obtém e transmite imagens em escala de cinza para reduzir o tempo de processamento e de transmissão. A rede de conexão entre a câmera e o *hardware* de processamento é feita por *Jumbo Frames*, que são quadros Ethernet com mais de 1500 bytes de carga.

3.2 Segmentação da Imagem

Neste trabalho foram definidas três ROIs, conforme ilustra as Figs. 6 e 7, sendo extraídos atributos diferentes em cada uma delas. Na primeira ROI, apresentada na Fig. 6, o atributo extraído é a intensidade dos pixels, sendo transformado em um rótulo utilizado para inicializar ou finalizar o classificador autônomo.




Figura 6. Região de interesse 1, utilizada para identificar quando o código responsável pelo processamento de imagens está (a) parado ou (b) em funcionamento.

Na Fig. 7 estão ilustradas outras duas ROIs, nas quais são extraídos outros atributos que serão transformados em rótulos para o classificador autônomo, conforme detalhado na Seção 3.3.




Figura 7. Regiões de interesse 2 (lado esquerdo) e 3 (lado direito), utilizadas para extração de alguns atributos.

3.3 Extração dos Atributos

Inicialmente, para cada coluna de pixels da ROI 1 gera-se um histograma da intensidade luminosa, ou seja, o quão branco é aquela coluna em uma faixa de 0 a 255. Cada histograma retorna um valor, que será utilizado para definir se o processamento da imagem continua ou não.

Se o histograma com maior valor retornado não atingir pelo menos a quantidade de 3750, significa que a mesa de rolos está vazia ou que há pequenas quantidades de espiras provenientes da calda da última formação. Logo, essas imagens devem ser descartadas e o processamento interrompido. O valor de 3750 foi escolhido empiricamente.

Se o processamento não for interrompido pela ROI 1, então as ROIs 2 e 3 são analisadas para a extração dos contornos. A biblioteca utilizada para esse fim considera um contorno como uma região do espaço bem definida e sem extremidades, ou seja, o ponto inicial condiz com o ponto final.

Nessa parte do processamento, primeiro encontra-se o maior contorno existente (borda externa), que representa a separação entre a mesa de rolos e as espiras. Após essa etapa, encontra-se os demais contornos dentro da região das espiras, denominados buracos. De posse da quantidade de buracos e da área dos mesmos, pode-se projetar o classificador autônomo.

4. PROJETO DO CLASSIFICADOR

O projeto de classificadores autônomos tem recebido atenção especial nos últimos anos. Diferentes metodologias têm sido apresentadas na literatura, a maioria delas baseadas em métodos estatísticos, como Decomposição de Valor Singular e Inferência Bayesiana. Embora esses classificadores tenham se demonstrado eficientes, existem aplicações que podem ser suportadas por classificadores de menor esforço computacional, que se baseiam em propriedades físicas do material classificado ou ainda de sensores específicos, como o caso da câmera digital utilizada na presente aplicação.

Após o processamento digital da imagem, os quatro atributos obtidos das ROIs 2 e 3 de cada imagem capturada estão prontos para serem transformados em rótulos que serão processados pelo classificador autônomo, conforme ilustra a Fig. 8.

O objetivo é criar uma relação para pontuar a qualidade da formação de espiras. Contudo, compor esses rótulos



Figura 8. Atributos de entrada para o classificador autônomo.

não é uma tarefa simples. Para combinar a quantidade de buracos e áreas das duas ROIs da Fig. 7, o primeiro passo foi utilizar média simples destes valores em cada região para compor a área média A_m e quantidade média B_m dos buracos da imagem em análise.

Em geral, foram observadas experimentalmente duas situações:

- poucos buracos com maiores áreas, quando se tem uma formação não adequada (menor regularidade);
- muitos buracos com menores áreas, quando se tem uma formação mais adequada (maior regularidade).

Percebe-se que a área média dos buracos é um parâmetro importante, mas que precisa ser ponderado, uma vez que podem ocorrer situações em que as áreas médias dos buracos de duas imagens tem valor semelhante, mas a formação pode ser considerada não adequada em alguma delas, em função da irregularidade.

Desta forma, uma maneira de ponderar a área média é utilizar a quantidade média de buracos, por meio de uma relação exponencial, ou seja:

$$F_c = A_m \epsilon^{-\left(\frac{B_m}{F_a}\right)}, \quad (1)$$

em que F_c representa o rótulo combinado, A_m e B_m são as respectivas áreas e quantidades médias dos buracos nas ROIs 2 e 3, bem como F_a é um fator de atenuação, escolhido empiricamente como $F_a = 90$.

A escolha da relação exponencial é baseada no fato da quantidade média de buracos de uma formação adequada ser elevada e, por outro lado, em uma formação pouco adequada essa quantidade ser muito menor. Ou seja, a disparidade entre os extremos é melhor representada por uma relação exponencial que uma linear.

5. TREINAMENTO DO CLASSIFICADOR

Para o treinamento do classificador, as seis imagens da Fig. 9 foram previamente analisadas por um especialista no processo de fio-máquina, a fim de quantificar a *expertise* e conhecimento da formação. As seis imagens foram processadas para extrair os atributos e os resultados estão resumidos na Tab. 1.

Tabela 1. Atributos extraídos das imagens da Fig. 9.

Imagem	Número de buracos		Área dos buracos	
	ROI 2	ROI 3	ROI 2	ROI 3
(a)	45	63	20872,0	24332,0
(b)	11	13	7677,0	12197,0
(c)	20	15	12906,0	5352,0
(d)	71	93	9204,5	13568,5
(e)	26	17	5848,0	4017,5
(f)	4	7	684,5	547,0




Figura 9. Pontuação das formações por um operador especializado no processo de fio-máquina: (a) nota 1 (um), (b) nota 4 (quatro), (c) nota 5 (cinco), (d) nota 6 (seis), (e) nota 6 (seis) e (f) nota 9 (nove).

A Tab. 2 mostra que o rótulo combinado, modelado pela Eq. 1, forneceu resultados em consonância com as pontuações do especialista. Percebe-se que menores valores de F_c indicam melhores notas dadas pelo especialista. Além disso, os efeitos da alta quantidade de buracos com pequenas áreas, Fig. 9(d), também conduz a uma pontuação semelhante a baixa quantidade de buracos com grandes áreas, Fig. 9(e). Nesses casos, ambas as imagens foram pontuadas como seis pelo especialista.

Tabela 2. Combinação dos rótulos para pontuar as imagens da Fig. 9.

Imagem	B_m	A_m	F_c [Eq. (1)]	S_f [Eq. (2)]	Nota do Especialista
(a)	54,0	22602,0	12404,2	0,3766	1
(b)	12,0	9937,0	8696,6	3,8060	4
(c)	17,5	9129,0	7515,8	4,3905	5
(d)	21,5	11387,0	4578,3	5,6445	6
(e)	82,0	4932,8	3884,6	6,0095	6
(f)	5,5	615,8	579,2	8,9464	9

Para traduzir o rótulo combinado, F_c , em uma pontuação, S_f , na mesma escala da adotada pelo especialista, estimou-se a seguinte aproximação polinomial:

$$S_f = -(9,122 \times 10^{-12})F_c^3 + (1,731 \times 10^{-7})F_c^2 - (1,5 \times 10^{-3})F_c + 9,759. \quad (2)$$

A Fig. 10 ilustra a relação entre a pontuação dada pelo especialista e aquela atribuída pela Eq. (2) para o classificador autônomo em função do rótulo combinado. As imagens de treinamento da Fig. 9 têm ambas pontuações apresentadas na Tab. 2.




Figura 10. Pontuações de formação em função do rótulo combinado para imagens da Fig. 9.

6. PONTUAÇÃO DE UMA FORMAÇÃO COMPLETA

A Fig. 11 ilustra a série temporal de evolução da pontuação de um processo de formação completa, com fio-máquina de 5,6 mm de diâmetro e que com tempo de formação de cerca de 90 segundos para ser concluído. Durante a formação em questão foram coletadas e processadas 384 imagens.




Figura 11. Série temporal das pontuações dadas pelo classificador autônomo para uma formação completa da bobina de fio-máquina.

A formação completa foi avaliada pelo especialista da área com média 6 (seis), enquanto a nota dada pelo classificador autônomo é de 6,37, mostrando coerência entre as pontuações para a presente formação.

7. CONCLUSÃO

O projeto e a implementação de um classificador de padrões autônomo foi viabilizado pela utilização de uma câmera como sensor, tornando possível a extração de atributos por meio de técnicas de processamento de imagens. A intensidade de brilho de uma região de interesse foi utilizada para identificar o início ou término do processo de formação de espiras.

A identificação de bordas externas de outras duas regiões de interesse, bem como a contagem do número de buracos e a área desses buracos, dentro da região espacial envolvida pelas bordas, foram utilizadas para construir rótulos que permitem ao classificador pontuar a formação.

Os resultados obtidos pelo classificador projetado foram adequados, pois estão coerentes com as pontuações dadas por um especialista no processo de formação de fio-máquina. As notas obtidas ficaram próximas, tanto durante o treinamento do classificador com as seis imagens de pontuação entre um e nove, quanto durante a série temporal de pontuação de uma formação completa.

Isso pode permitir que empresas siderúrgicas que produzem esse tipo de produto façam um mapeamento da qualidade da formação em função de um parâmetro específico, como a velocidade de formação. Dessa forma, as

indústrias podem definir parâmetros na linha de produção para atingir o ponto ótimo de alinhamento das espiras na mesa de rolos e elevar, assim, a média das formações completas no tempo.

Fica proposto como trabalhos futuros a implementação de outros tipos de classificadores, como o classificador de Análise das Componentes Principais (do inglês *Principal Component Analysis* ou PCA), que pode ser usado para encontrar um sistema alternativo de coordenadas ortogonais com dimensão reduzida, ao longo do qual o conjunto de dados tem as maiores variâncias. Além disso, pode-se utilizar das bordas externas das ROIs 2 e 3 para realizar uma análise espectral e, assim, determinar a nota da formação. Os dois classificadores propostos e o implementado neste trabalho podem ser comparados para definir os pontos fortes e fracos da utilização de cada um deles para a presente aplicação.

REFERÊNCIAS

- AISI (2018). The economic impact of the american iron and steel industry. American Iron and Steel Institute. Disponível em: <steel.org/economicimpact/>. Acesso em: 22 fev. 2022.
- Annadurai, S. e Shanmugalakshmi, R. (2007). *Fundamental of Digital Image Processing*. Pearson Education, 1 edition.
- Bastos, R.R., de Souza, T.S., de Carvalho, M.M., Silva, L.A.R., e Cardoso Filho, B.J. (2020). Assessment of a nine-phase induction motor drive for metal industry applications. *IEEE Transactions on Industry Applications*, 56(6), 7217–7226. doi:10.1109/TIA.2020.3023061.
- IAB (2020). Dados consolidados do setor siderúrgico referentes ao ano de 2020. Instituto Aço Brasil. Disponível em: <acobrasil.org.br/site/dados-do-setor/>. Acesso em: 22 fev. 2022.
- Jatlas (2022). Wire rods. Disponível em: <jatlas.com.tr/product/wire-rods/>. Acesso em: 11 mar. 2022.
- Mukhopadhyay, G. e Bhattacharyya, S. (2013). Wear of laying head pipes in a wire rod mill. *Journal of Failure Analysis and Prevention*, 13(4), 474–482. doi:10.1007/s11668-013-9701-6.
- Taurino, A., Vasi, M., Mestroni, A., e De Luca, A. (2016). The most advanced systems for perfect coil production: The loop laying head (LLH) is a cost-effective solution for the latest generation of H3 high-speed wire rod mills. *53rd Rolling Seminar*, 136–145. doi:10.5151/1983-4764-27629.
- Viana, F.L.E. (2018). Indústria siderúrgica: investir em eficiência. *Caderno Setorial ETENE*, Ano 3(39), 1–14. URL bnb.gov.br/s482-dspace/handle/123456789/1026.