

**INSTITUTO FEDERAL DO ESPÍRITO SANTO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE CONTROLE E
AUTOMAÇÃO**

ROGÉRIO ELEOTÉRIO DE JESUS

**RECONHECIMENTO DE PASSAGEM DE ESCÓRIA NO VAZAMENTO DE AÇO
EM CONVERTEDORES DE ACIARIA**

Serra
2017

ROGÉRIO ELEOTÉRIO DE JESUS

**RECONHECIMENTO DE PASSAGEM DE ESCÓRIA NO VAZAMENTO DE AÇO
EM CONVERTEDORES DE ACIARIA**

Dissertação de Mestrado apresentada à Coordenadoria do Curso de Mestrado Profissional em Engenharia de Controle e Automação do Instituto Federal do Espírito Santo como requisito parcial para a obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientador: Prof. Dr. Daniel Cruz Cavaliere
Coorientador: Prof. Dr. Cassius Zanetti Resende

Serra
2017

Dados Internacionais de Catalogação na Publicação (CIP)

J58r
2017 Jesus, Rogério Eleotério de
Reconhecimento de passagem de escória no vazamento de aço
em convertedores de aciaria / Rogério Eleotério de Jesus. - 2017.
82 f.; il.; 30 cm

Orientador: Prof. Dr. Daniel Cruz Cavalieri.
Coorientador: Prof. Dr. Cassius Zanetti Resende.
Dissertação (mestrado) - Instituto Federal do Espírito Santo,
Programa de Pós-graduação em Engenharia de Controle de
Automação, 2017.

1. Aço - Siderurgia. 2. Processamento de imagens – Técnicas
digitais. 3. Sistema de reconhecimento de padrões. 4. Visão por
computador. I. Cavalieri, Daniel Cruz. II. Resende, Cassius Zanetti.
III. Instituto Federal do Espírito Santo. IV. Título.

CDD 006.3

Bibliotecária Rogeria Gomes Belchior - CRB6/ES 417



MINISTÉRIO DA EDUCAÇÃO
INSTITUTO FEDERAL DO ESPÍRITO SANTO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

ROGÉRIO ELEOTÉRIO DE JESUS

**RECONHECIMENTO DE PASSAGEM DE ESCÔRIA NO VAZAMENTO DE AÇO
EM CONVERTEDORES DE ACIARIA**

Dissertação de Mestrado apresentada à
Coordenadoria do Curso de Mestrado Profissional
em Engenharia de Controle e Automação do
Instituto Federal do Espírito Santo como requisito
parcial para a obtenção do título de Mestre em
Engenharia de Controle e Automação.

Aprovado em 15 de dezembro de 2017

COMISSÃO EXAMINADORA

Prof. Dr. Daniel Cruz Cavalieri
Instituto Federal do Espírito Santo
Orientador

Prof. Dr. Cassius Zanetti Resende
Instituto Federal do Espírito Santo
Orientador

Prof. Dr. Flávio Garcia Pereira
Instituto Federal do Espírito Santo
Membro Interno

Prof. Dr. Evandro Ottoni Teatini Salles
Universidade Federal do Espírito Santo
Membro externo

Dedico este trabalho primeiramente a Deus, razão maior de minha vida, autor do meu destino, à minha amada esposa Monique por todo seu apoio e carinho, ao meu pai Milton e minha mãe Martha que nunca pouparam esforços pela minha educação.

AGRADECIMENTOS

Ao Instituto Federal do Espírito Santo - Campus Serra por proporcionar um ambiente profícuo para o desenvolvimento deste trabalho incluindo todos os professores do Programa de Pós-Graduação em Engenharia de Controle e Automação (Propecaut).

À ArcelorMittal Tubarão por me permitir dedicar tempo a este trabalho e fornecer as informações necessárias ao seu desenvolvimento, em especial nas pessoas do Fernando José Martinelli e do Henrique Silva Furtado.

Ao professor Dr. Daniel Cruz Cavalieri e ao professor Dr. Cassius Zanetti Resende pelo tempo dedicado nesta orientação sempre com muita paciência e provendo o suporte acadêmico necessário.

Aos membros da banca examinadora por atenderem ao convite dispondo de seu tempo e conhecimento para analisar este trabalho.

Aos colegas de turma deste programa de pós-graduação pelo suporte e apoio mútuo em todas as atividades promovendo um ambiente saudável e descontraído.

A todos que contribuíram de alguma forma, direta ou indiretamente, para o desfecho de mais essa etapa da minha vida.

*Quanto mais aumenta nosso conhecimento, mais evidente fica
nossa ignorância.*

John F. Kennedy

RESUMO

A preocupação com a correta identificação do momento de encerrar o vazamento de aço por um convertedor de aciaria, em uma siderúrgica, é de grande importância para o processo. Sua identificação de forma eficiente representa uma redução de custo significativa, uma vez que este processo ocorre repetidas vezes ao dia. Sendo a escória um subproduto gerado dentro do convertedor durante o processo de sopro, não se deseja que ela seja levada para os processos seguintes. A partir das imagens geradas por uma câmera termográfica, serão aplicadas técnicas de processamento digital de imagens para detectar e segmentar a região do jato de aço formado durante o vazamento do convertedor para a panela de aço. Além disto, serão extraídas características das imagens do jato segmentado de 97 corridas, quadro a quadro, e aplicadas técnicas de reconhecimento de padrões para identificar e classificar a passagem de escória neste processo determinando o fim do vazamento. Os métodos SVM, kNN, RNA e CUSUM serão empregados utilizando os vetores de características gerados e tendo seus resultados comparados. Será demonstrado que as técnicas aplicadas podem alcançar resultados próximos a 100% da correta classificação da passagem de escória.

Palavras-chave: Aciaria. Escória. Processamento digital de imagens. Reconhecimento de padrões.

ABSTRACT

The concern about the correct identification of the moment to end tapping converter of steel at steelworks, in a steel plant, is of great importance for the process. Their identification efficiently represents a significant cost reduction, since these processes occurs several times a day. Since the slag is a by-product generated within the converter during the blowing process, it is not desired that it be carried to the following processes. From the images generated by a thermographic camera, digital image processing techniques will be applied to identify and segment the region of steel jet formed during the converter tapping to the ladle steel. In addition, feature vectors from segmented jet images of 97 heats will be extracted, frame by frame, and applied pattern recognition techniques to identify and classify the slag carry over in this process, determining the end of tapping. The SVM, kNN, ANN and CUSUM methods will be employed using the generated characteristic vectors, and their results will be compared. It will be demonstrated that the applied techniques can reach results close to 100% of the correct classification of the slag carry over.

Keywords: Steel Plant. Slag. Digital image processing. Pattern recognition.

LISTA DE ILUSTRAÇÕES

Figura 1 - Exemplo de processos em uma indústria siderúrgica destacando a aciaria.....	15
Figura 2 - Conversor tipo LD (Linz-Donawitz)	16
Figura 3 - Vazamento de aço do conversor para a panela.....	17
Figura 4 - Fases do processo em um conversor de aciaria.....	18
Figura 5 - Dispositivo tipo dardo.....	20
Figura 6 - Espectro visível pelo olho humano.....	24
Figura 7 - Etapas de um processo de processamento digital de imagens	24
Figura 8 - Histogramas em escala de cinza de uma imagem em diferentes contrastes.....	26
Figura 9 - Exemplo de limiarização por histograma bimodal. (a) Imagem original (b) Histograma da imagem original. (c) Imagem limiarizada pelo valor de 100	28
Figura 10 - Sistema de reconhecimento de padrão.....	32
Figura 11 - Ideia de um hiperplano ótimo para padrões linearmente separáveis	35
Figura 12 - Exemplo de classificação de dois elementos desconhecidos em um espaço bidimensional com $k=7$	37
Figura 13 - Representação funcional de um neurônio artificial.....	38
Figura 14 - Rede Neural Artificial multicamadas feedforward.....	39
Figura 15 - Quadro obtido no vazamento de aço na panela em escala de cinza	43
Figura 16 - Quadro obtido no vazamento de aço na panela com a barra de cores jet	44
Figura 17 - Histograma obtido a partir do quadro em escalas de cinza indicando a limiarização por uma linha vermelha	45
Figura 18 - Segmentação do aço na imagem	45
Figura 19 - Soma dos pixels das colunas i à esquerda e das linhas j à direita.....	46
Figura 20 - Quadro com o aço segmentado e a indicação das delimitações para o primeiro recorte vertical da região do jato.....	47
Figura 21 - Primeiro recorte vertical do quadro e segmentação do aço com a indicação das delimitações para o primeiro recorte horizontal ..	47
Figura 22 - Primeiro recorte da região de interesse (jato)	48
Figura 23 - Soma dos pixels das colunas y (a) e soma acumulada dos valores entre posições sequenciais <i>Yacum</i> (b).	50
Figura 24 - Região do jato localizado na imagem e segmentado.....	50

Figura 25 - Quadro da imagem segmentado e o respectivo histograma em escala de cinzas da região segmentada do jato de aço (região branca dentro do quadro vermelho)	51
Figura 26 - Comportamento dimensional e estatístico das variáveis analisadas, no decorrer do vídeo quadro a quadro, para uma determinada corrida. 53	
Figura 27 - Comportamento da característica área, quadro a quadro, em torno da região de início de passagem de escória.	54
Figura 28 - Separação dos dados de cada quadro em janelas alvo (início de escória) e não alvo.....	56
Figura 29 - Detecção da posição do jato em diferentes quadros de um vídeo ao longo do processo de vazamento	58
Figura 30 - Detecção da posição do jato em diferentes quadros de um vídeo ao longo do processo de vazamento	59
Figura 31 - Exemplo de vetor característica utilizando o histograma completo	63
Figura 32 - Curvas ROC para todas as características e classificadores.....	72

LISTA DE TABELAS

Tabela 1 - Composição química típica da escória.....	17
Tabela 2 - Matriz de confusão para classificação da característica área	60
Tabela 3 - Matriz de confusão para classificação da característica extensão.....	60
Tabela 4 - Matriz de confusão para classificação da característica média do eixo X.....	61
Tabela 5 - Matriz de confusão para classificação da característica média do eixo Y	61
Tabela 6 - Matriz de confusão para classificação da característica mediana	61
Tabela 7 - Matriz de confusão para classificação da característica centro de massa	61
Tabela 8 - Matriz de confusão para classificação da característica soma > lim 120	62
Tabela 9 - Matriz de confusão para classificação da característica soma > lim 140	62
Tabela 10 - Matriz de confusão para classificação da característica soma > lim 180	62
Tabela 11 - Matriz de confusão para classificação da característica soma > lim 220	62
Tabela 12 - Matriz de confusão para classificação da característica histograma 100	64
Tabela 13 - Matriz de confusão para classificação da característica histograma 60	64
Tabela 14 - Indicação convencionada para as matrizes de confusão.....	65
Tabela 15 - Sumário de sensibilidades para cada característica x método de classificação	65
Tabela 16 - Sumário das especificidades para cada característica x método de classificação.....	66
Tabela 17 - Sumário das eficiências para cada característica x método de classificação.....	67
Tabela 18 - Sumário dos Coeficientes de Correlação de Matthews (CCM) para cada característica x método de classificação	68
Tabela 19 - Sumário das exatidões para cada característica x método de classificação.....	69
Tabela 20 - Sumário das imprecisões para cada característica x método de classificação.....	70

Tabela 21 - Sumário de AUC para cada característica versus método de classificação.....	71
Tabela 22 - Matriz de confusão para classificação da característica soma > lim 180 em todas janelas das corridas teste	74
Tabela 23 - Índices gerais para a simulação de corridas-teste	74
Tabela 24 - Momento de detecção da passagem de escória	75

LISTA DE ABREVIATURAS E SIGLAS

ANN - Artificial Neural Network

BOF - Basic Oxygen Furnace

CUSUM - Cumulative Sum

ESD - Electromagnetic Slag Detection

FN - Falsos Negativos

FP - Falsos Positivos

kNN - k-Nearest Neighbors

LD - Linz-Donawitz

PCA - Principal Component Analysis

RNA - Redes Neurais Artificiais

ROC - Receiver Operating Characteristic

ROI - Region of Interest

SVM - Support Vector Machine

TSD - Thermographic Slag Detection

VN - Verdadeiros Negativos

VP - Verdadeiros Positivos

LISTA DE SÍMBOLOS

Al_2O_3 - Óxido de Alumínio (Alumina)

C - Carbono

CaF_2 - Fluoreto de Cálcio (Fluorita)

CaO - Óxido de Cálcio (Cal)

CO - Monóxido de Carbono

CO_2 - Dióxido de Carbono

Fe - Ferro

FeO - Óxido de Ferro (Hematita)

MgO - Óxido de Magnésio (Magnésia)

Mn - Manganês

MnO - Óxido de Manganês (Pirolusita)

O_2 - Oxigênio

P - Fósforo

S - Enxofre

Si - Silício

SiO_2 - Dióxido de Silício (Sílica)

SUMÁRIO

1	INTRODUÇÃO	15
1.1	MOTIVAÇÃO E CONTEXTUALIZAÇÃO.....	15
1.1.1	Fabricação de aço na aciaria	15
1.1.2	Detecção de escória durante o vazamento do convertedor	19
1.2	OBJETIVOS.....	20
1.2.1	Geral	20
1.2.2	Específicos	20
1.3	ESTRUTURA DA DISSERTAÇÃO	21
2	REVISÃO BIBLIOGRÁFICA	22
3	REVISÃO DA LITERATURA	23
3.1	PROCESSAMENTO DIGITAL DE IMAGENS.....	23
3.1.1	Aquisição de imagens	25
3.1.2	Pré-processamento	25
3.1.3	Segmentação	26
3.1.4	Pós-processamento	29
3.1.5	Extração de atributos	30
3.2	RECONHECIMENTO DE PADRÕES.....	31
3.2.1	Máquinas de vetores de suporte (SVM)	34
3.2.2	k-Vizinhos mais próximos (kNN)	36
3.2.3	Redes Neurais Artificiais (RNA)	38
3.2.4	Somas acumuladas (CUSUM)	39
4	METODOLOGIA	42
4.1	LOCALIZAÇÃO E SEGMENTAÇÃO DO JATO NA IMAGEM.....	42
4.2	RECONHECIMENTO DO PADRÃO DE PASSAGEM DE ESCÓRIA	50
5	RESULTADOS E DISCUSSÃO	58
5.1	LOCALIZAÇÃO E SEGMENTAÇÃO DO JATO NA IMAGEM.....	58
5.2	RECONHECIMENTO DO PADRÃO DE PASSAGEM DE ESCÓRIA	59
6	CONCLUSÃO E TRABALHOS FUTUROS	76
	REFERÊNCIAS	78

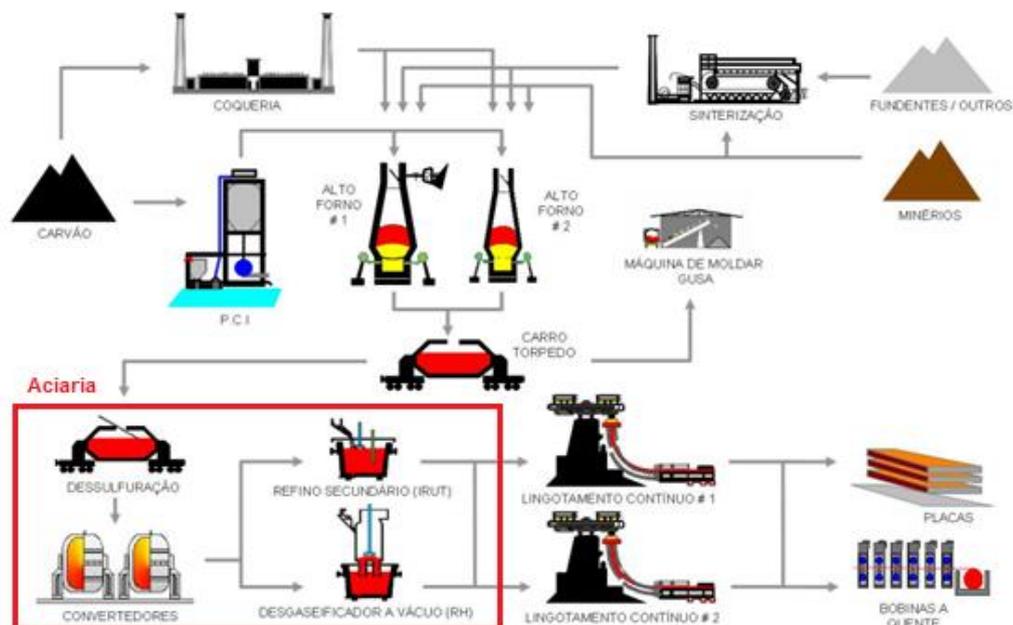
1 INTRODUÇÃO

1.1 MOTIVAÇÃO E CONTEXTUALIZAÇÃO

1.1.1 Fabricação de aço na aciaria

O aço está inserido no cotidiano das pessoas sendo um produto primordial na indústria automotiva, construção civil e sendo utilizado nas mais variadas utilidades domésticas e bens de consumo. Entretanto, antes de chegar ao produto final, em sua fabricação, ele deve passar por alguns processos dentro de uma indústria siderúrgica como pode ser visto na Figura 1. Na sinterização e na coqueria, as matérias-primas, minério de ferro e carvão, são beneficiadas produzindo o sinter e o coque respectivamente. Estes são então levados para os altos-fornos que irão transformá-los no ferro-gusa. Este último, por sua vez, será levado até um processo chamado aciaria (destacado na Figura 1), sendo responsável por transformar o ferro-gusa em aço efetivamente. O aço então segue para outros processos que irão conformá-lo, como o lingotamento contínuo por exemplo.

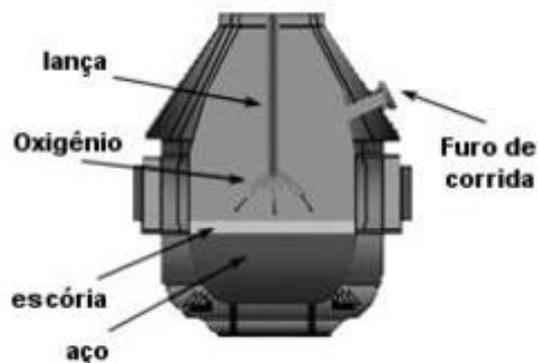
Figura 1 - Exemplo de processos em uma indústria siderúrgica destacando a aciaria



Fonte: Moreira; Lana (2007).

Na aciaria, este processo de transformação do ferro-gusa em aço, envolve basicamente a oxidação de grande parte do carbono presente no ferro-gusa que é reduzido de níveis acima de 4% para níveis inferiores a 1% na maioria dos casos. Além disso, ocorre a oxidação de impurezas para o aço como fósforo (P), enxofre (S), silício (Si) e manganês (Mn), que são eliminadas na escória formada, enquanto o excesso de carbono é eliminado sob a forma de gases (CO e CO₂). Um dos equipamentos mais utilizados para este fim chama-se convertedor BOF (do inglês, *Basic Oxygen Furnace*) conforme descrito em Frueham (1998). Este é constituído de uma carcaça cilíndrica de aço resistente ao calor, revestido internamente por materiais refratários. Nos convertedores do tipo LD (Linz-Donawitz), conforme exibido na Figura 2, o ferro-gusa é adicionado em conjunto com sucatas ocorrendo o sopro de oxigênio (O₂) por uma lança através de seu topo com temperaturas variando de 1300 a 1600°C e promovendo certa turbulência no banho.

Figura 2 - Convertedor tipo LD (Linz-Donawitz)



Fonte: Autoria própria.

Ao longo do sopro são adicionados fundentes como a cal (CaO) e a fluorita (CaF₂) que serão responsáveis pela fixação dos óxidos formados durante as reações. Análises químicas são realizadas através de amostras retiradas por uma sub-lança inserida pelo topo para confirmação da obtenção da composição química correta. Nesse tipo de convertedor, a parte superior é ocupada por gases, enquanto sua parte inferior é ocupada pelo metal líquido sobre o qual está uma camada de escória líquida que apresenta certa basicidade, temperatura e viscosidade. Quanto maior

sua superfície específica, maior será sua capacidade de proteção contra a oxidação. Cerca de 85kg de escória são gerados por tonelada de aço produzido, ou seja, em uma quantidade normal soprada contendo aproximadamente 300 toneladas de aço, gera-se aproximadamente 25 toneladas de escória com composição química típica apresentada na tabela 1.

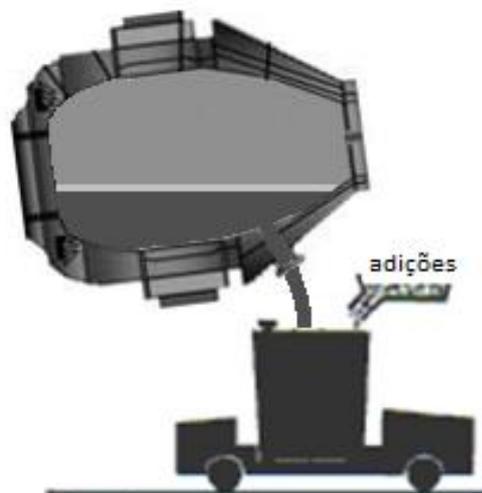
Tabela 1 - Composição química típica da escória

Elementos	CaO	MgO	MnO	Fe	FeO	SiO ₂	Al ₂ O ₃
%	23-46	5-13	2-6	14-22	18-24	11-19	0,8-4

Fonte: ArcelorMittal Tubarão (2007).

A escória é menos densa e possui, normalmente, maior temperatura que o aço, flutuando sobre o mesmo. Ao final do processo de sopro de oxigênio, o convertedor realizará um basculamento para que o produto seja vazado, em uma panela de aço, através de um furo em sua lateral como demonstrado na Figura 3. Desta panela, o aço irá prosseguir para outros processos que irão conformá-lo.

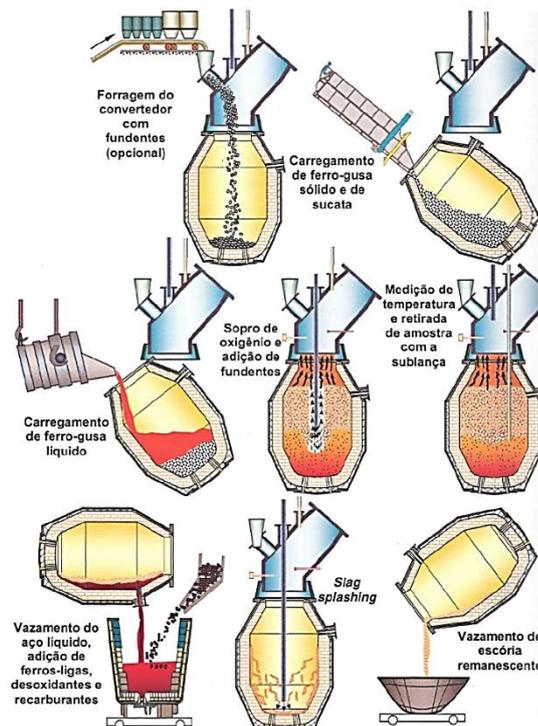
Figura 3 - Vazamento de aço do convertedor para a panela



Fonte: Autoria própria.

A escória é importante para o processo de fabricação do aço protegendo-o contra oxidação pelo ar e controlando as perdas térmicas. Além disso, capta as inclusões do aço aumentando a sua limpidez. No entanto, embora importante no processo que ocorre dentro do convertedor, uma passagem inadequada do convertedor para a panela causa alguns transtornos ao processo. A escória não é desejada nos processos seguintes, por exemplo, em um lingotamento contínuo. Além de trazer problemas ao processo de conformação, ocasionaria defeitos ao produto final. A passagem de escória para a panela de aço afeta a limpidez do produto, aumenta o desgaste dos refratários potencializando o ataque químico aos mesmos, limitando seu número de reutilizações e diminui a eficiência da desoxidação e dessulfuração do aço. Por esse motivo, não se deseja que a escória seja transmitida no vazamento do convertedor para a panela, ou seja, tão cedo quanto se detectar o início da passagem de escória pelo furo, ou mesmo antes, o convertedor deve ser basculado de volta encerrando o vazamento. Após o fim do vazamento, o convertedor é basculado para o lado oposto para que a escória seja despejada em um pote chamado pote de escória. As fases do processo ocorridas no convertedor estão demonstradas na Figura 4.

Figura 4 - Fases do processo em um convertedor de aciaria



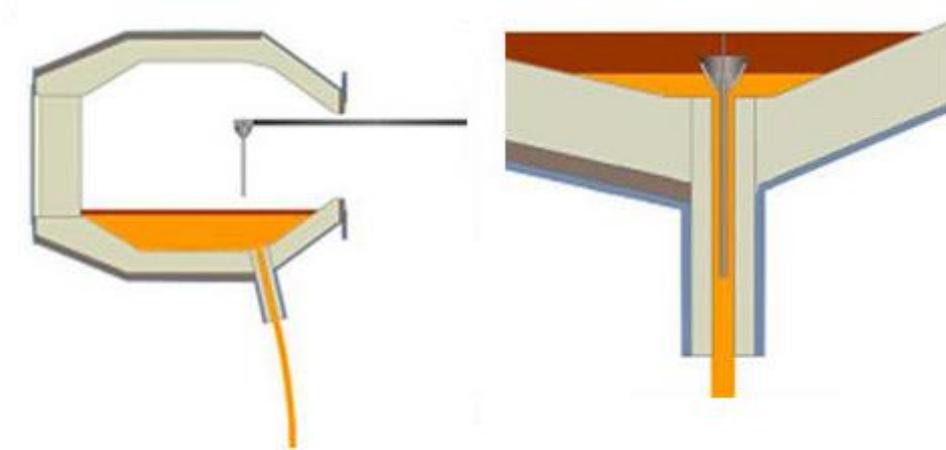
Fonte: Rizzo (2006).

1.1.2 Detecção de escória durante o vazamento do convertedor

Na grande maioria das usinas siderúrgicas, a detecção da passagem da escória durante o vazamento e o controle do basculamento do convertedor é realizada de forma manual. Operadores observam o jato de aço através do furo de corrida, e o interior do convertedor pelo seu topo, para identificar que o aço foi inteiramente vazado sobrando apenas escória em seu interior. Em alguns casos, os operadores podem ter auxílio de um sistema detector de escória TSD (do inglês, *Thermographic Slag Detection*) ou ESD (do inglês, *Electromagnetic Slag Detection*) fornecido pela AMEPA (AMEPA GmbH, Würselen, Alemanha). Esses sistemas geram um indicador de possibilidade de presença escória no jato. Esse processo de atuação manual acarreta alta variabilidade, permitindo a passagem de mais escória que o desejado em alguns casos ou, por outro lado, deixando mais aço que o devido na panela. A correta identificação do momento de encerrar o vazamento é, portanto, de grande importância para o processo. Sua identificação de forma eficiente representa uma redução de custo significativa para as siderúrgicas que realizam este processo repetidas vezes ao dia, muitas vezes possuindo múltiplos convertedores.

Outra forma de se buscar interromper a passagem de escória para a panela é com o uso de um dispositivo do tipo dardo como exibido na Figura 5. Esse elemento de tamponamento, revestido de material refratário, é projetado para flutuar entre a escória e o aço líquido possuindo uma densidade intermediária. Durante o escoamento pelo furo de corrida, o vórtice formado tende a puxar o elemento para dentro do furo provocando a interrupção do fluxo assim que seu bojo encosta na parede do convertedor. Este dispositivo não é eficaz em todos os casos, pois depende da dinâmica do escoamento entre outros fatores ocorridos durante o vazamento. Turbulências podem ocorrer levando ao não encaixe do dardo no furo, ou seja, nem sempre o alvo é atingido.

Figura 5 - Dispositivo tipo dardo



Fonte: Alibaba (2017).

Ainda não é possível afirmar que há uma técnica robusta e assertiva o suficiente capaz de detectar a passagem de escória com precisão, muito menos capaz de antever sua passagem.

1.2 OBJETIVOS

1.2.1 Geral

Utilizar uma câmera termográfica posicionada em direção ao jato de aço formado durante o vazamento, de forma a identificar de forma automática que a escória iniciou sua passagem, e avaliar a possibilidade de antever antes que ocorra.

1.2.2 Específicos

- Compilar uma base de dados, contendo vídeos do vazamento de aço do convertedor para a panela de aço, que será utilizada no desenvolvimento do trabalho;
- Utilizar técnicas de processamento de imagens para encontrar a região de interesse (região do jato durante o vazamento) ao longo de uma sequência de quadros do vídeo detectando o mesmo;
- Realizar a segmentação do jato de aço durante o vazamento;
- Extrair e identificar características da região segmentada que possam ser utilizadas para estudos de padrões de comportamento ao longo do tempo.
- Utilizar técnicas de reconhecimento de padrões para detectar o início da passagem de escória.
- Utilizar técnicas de reconhecimento de padrões para avaliar a possibilidade de antever a passagem de escória.

1.3 ESTRUTURA DA DISSERTAÇÃO

O Capítulo 1 apresenta a introdução e a motivação para o estudo do tema abordado neste trabalho, destacando sua importância nos dias de hoje. No Capítulo 2 é apresentada a revisão bibliográfica relacionando alguns trabalhos já realizados no estudo da formação e identificação da escória durante o vazamento. No Capítulo 3 é apresentada uma revisão da literatura abordando os principais conceitos empregados neste trabalho referente às técnicas de processamento digital de imagens e reconhecimento de padrões. No Capítulo 4 é detalhada a metodologia empregada na solução do problema proposto. No Capítulo 5 têm-se os resultados obtidos e no Capítulo 6 são apresentadas as considerações finais.

2 REVISÃO BIBLIOGRÁFICA

Alguns trabalhos já foram realizados visando a correta detecção da passagem de escória durante o vazamento. Em Li et al. (2007) mostram-se os resultados alcançados com o uso do sistema AMEPA TSD onde são indicados tempos de reação médios, entre identificação da escória e a primeira ação, executada por operadores, para encerramento do vazamento. Os resultados variam entre 2,3 e 3,3 segundos após o início do evento, com sucesso na detecção de escória em 88,7% dos casos. Sem o uso do equipamento, os tempos se elevam para entre 3,9 e 4,8 segundos. Em Graham et al. (2008) também é apresentado um trabalho de detecção utilizando o AMEPA TSD combinado com um sensor de nível no convertedor. Com o auxílio de um modelo de densidade de escória desenvolvido, busca-se estimar a presença de escória no jato. Resultados mensuráveis não são demonstrados sendo apresentado como um trabalho em andamento.

Já Sato et al. (2009) busca uma abordagem diferente modelando fisicamente o comportamento do aço e da escória durante o esgotamento do convertedor através de simulações realizadas em laboratório com água (como aço) e óleo (como escória) em um recipiente de vidro. O estudo mostra que a simulação física do esvaziamento da panela é eficaz em identificar alguns parâmetros para avaliar o vórtice e minimizar o arraste e emulsificação do ar ou óleo de silicone com a água para a válvula de saída. Nenhuma implementação real foi realizada. Esta modelagem em laboratório precisa realizar muitas considerações para que seja efetivada na indústria.

Uma série de outros trabalhos foram realizados buscando abordar a modelagem física do processo como os que podem ser encontrados em Hammerschmid et al. (1984); Sankaranarayanan (1994); Andrzejewski et al. (1987); Koria e Kanth (1994); Pimenta, Valadares e Belligoli (1997); Steffen (1987). Mas o método de modelagem sempre recai em fatores de imprecisão que dependem de variáveis do processo de difícil mensuração na prática.

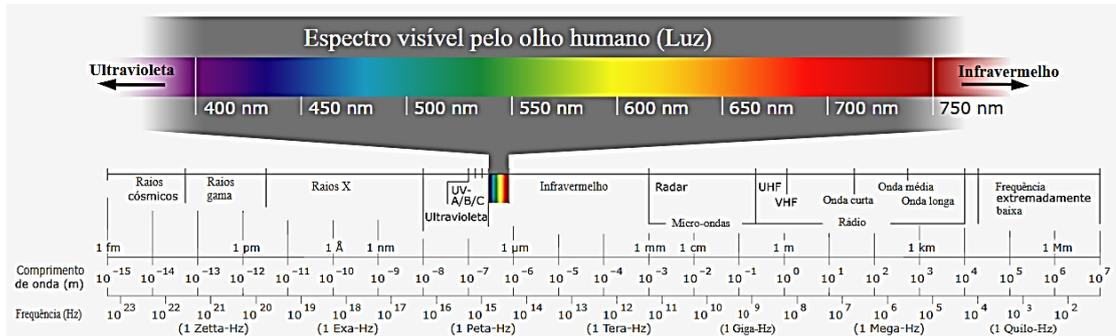
3 REVISÃO DA LITERATURA

3.1 PROCESSAMENTO DIGITAL DE IMAGENS

Atualmente, diversos campos da atividade humana têm recorrido a imagens para armazenar, exibir e fornecer informações sobre o mundo que nos rodeia. O desafio que fica para os pesquisadores, engenheiros e empresários, é extrair rapidamente informações valiosas a partir de dados brutos de imagens (SALDANHA; FREITAS, 2010). Este é o objetivo primário do processamento de imagens, ou seja, converter imagens em informação (RSI, 2005).

Uma imagem pode ser definida como uma função bidimensional $f(x,y)$, onde x e y são coordenadas espaciais e a amplitude de f em qualquer par de coordenadas (x,y) é a intensidade ou nível de cinza da imagem naquele ponto. A imagem será definida como digital quando x , y e $f(x,y)$ são grandezas finitas e discretas (GONZALES; WOODS, 2000). Assim, uma imagem digital é uma matriz cujos índices de linhas e de colunas identificam um ponto na imagem, o valor do elemento da matriz identifica o nível de cinza naquele ponto também chamado de pixel. As imagens desempenham um papel importante na percepção humana através da visão. No entanto, os humanos se limitam a faixa visual do espectro eletromagnético entre 400THz e 750THz (STARR, 2005) como pode ser observado na Figura 6. Já determinados equipamentos podem cobrir praticamente todo espectro de raios gama até ondas de rádio operando sobre imagens onde humanos não estão acostumados a associar como tal. Portanto, o processamento digital de imagens cobre um amplo e variado campo de aplicações.

Figura 6 - Espectro visível pelo olho humano

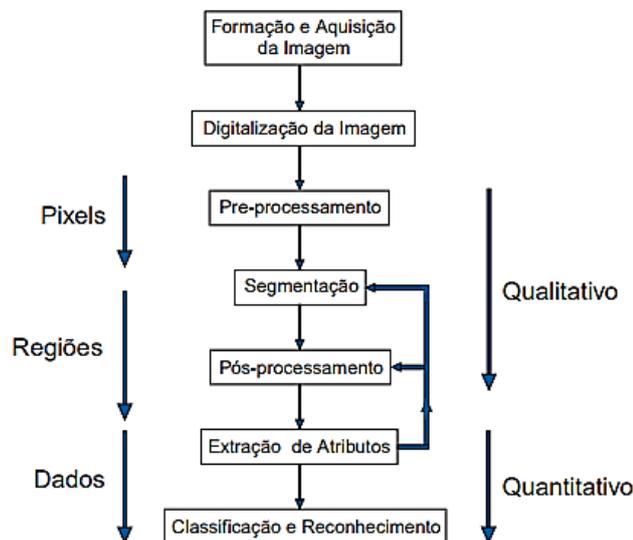


Fonte: Wikipedia (2017).

Não existe um consenso entre os autores onde é o limite entre o processamento de imagem e outras áreas correlatas como análise de imagens e visão computacional. Em geral, se tanto a entrada como a saída do processo são imagens, trata-se como processamento digital de imagens. Ao incluir análise e interpretação de características destas imagens caminha-se para o campo da visão computacional.

Uma aplicação envolvendo processamento de imagens passa por diversas etapas, tais como aquisição da imagem, digitalização, pré-processamento, segmentação, pós-processamento, extração de atributos, classificação e reconhecimento, como ilustrado na Figura 7.

Figura 7 - Etapas de um processo de processamento digital de imagens



Fonte: Albuquerque et al (2011).

3.1.1 Aquisição de imagens

Na etapa de aquisição de imagens, dois elementos são necessários, um dispositivo transdutor e um digitalizador. O primeiro é um dispositivo físico sensível ao espectro de energia eletromagnético, como ao espectro de raio-x, luz ultravioleta, infravermelha ou visível que deve produzir em sua saída um sinal elétrico proporcional ao nível de energia percebido. O segundo é responsável por converter o sinal elétrico analógico produzido na saída do sensor em um sinal digital.

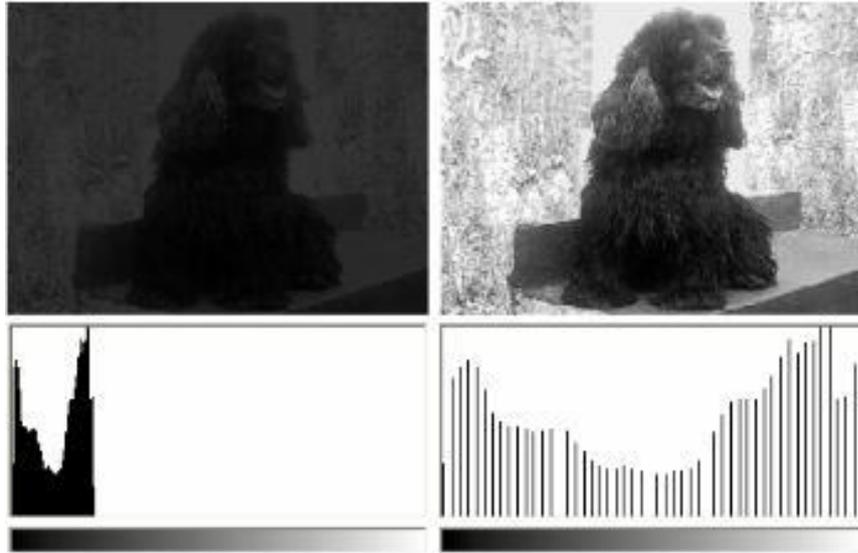
3.1.2 Pré-processamento

O pré-processamento envolve a aplicação de técnicas com o objetivo de melhorar a qualidade da imagem como, por exemplo, eliminando ruídos com a aplicação de filtros. As técnicas podem ser divididas em duas categorias principais: métodos que operam no domínio espacial manipulando o plano da imagem e métodos que operam no domínio da frequência manipulando seu espectro. Nesta etapa, um histograma de luminância é frequentemente utilizado dentro do processo. O histograma de uma imagem digital com k níveis de cinza é definido por uma função discreta apresentada na Equação 1:

$$p(k) = \frac{n_k}{n}, \text{ com } \sum_1^k p(k) = 1, \quad (1)$$

onde k representa os níveis de luminância discretos, n_k representa o número de pixels na imagem com intensidade k e n é o número total de pixels da imagem. Esta representação pode ser entendida como uma distribuição de probabilidades dos pixels dentro da imagem. Na Figura 8 pode-se ver exemplos de distribuição em escala de cinza através de seus histogramas. O menor valor 0 (zero) representa o preto e o maior valor 255 representa o branco.

Figura 8 - Histogramas em escala de cinza de uma imagem em diferentes contrastes



Fonte: Cardoso; Gomes (2005).

3.1.3 Segmentação

A etapa de segmentação busca uma redução das informações da imagem em áreas mais ou menos homogêneas com a finalidade de permitir uma análise mais apropriada. Os dois principais objetivos buscados são: decompor a imagem em partes para posterior análise e realizar uma mudança de representação (SHAPIRO; STOCKMAN, 2001). O resultado esperado dessa etapa é um número finito de regiões homogêneas, que individualizam as diferentes regiões contidas numa imagem. Dessa forma, a imagem seria formada por um conjunto de regiões, conectadas pelas suas bordas e que não se sobrepõem, de tal forma que cada pixel da imagem pertence unicamente a uma determinada região (ACHARYA; RAY, 2005).

A elaboração de algoritmos visando à automatização de processos de segmentação é uma das tarefas mais difíceis dentro da área de processamento de imagens (GONZALES; WOODS, 2000). Esta etapa é basicamente um problema de percepção psicofísica, e, portanto, não suscetível de uma solução puramente analítica (NIKHIL e SANKAR, 1993). Dessa forma, para obter um resultado

satisfatório, qualquer algoritmo de segmentação, não importando modelo matemático adotado, deve ser complementado por heurísticas que envolvam tanto a informação semântica como o conhecimento a priori sobre as imagens que estão sendo processadas (YONG; FENG; RONGCHUN, 2004).

Duas características básicas dos pixels são levadas em consideração no desenvolvimento destes algoritmos envolvendo os conceitos de descontinuidade e similaridade. Por meio do uso desses conceitos, conforme estruturado por Gonzalez e Woods (2000), a segmentação é realizada utilizando-se detecção de bordas e detecção de similaridades.

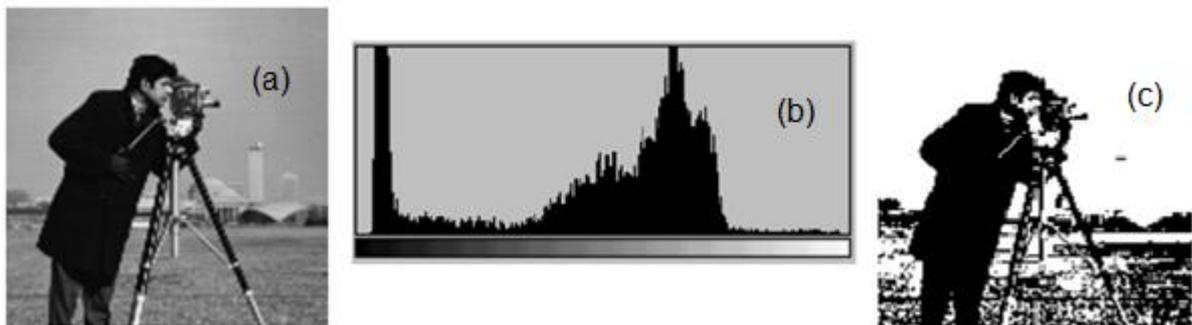
Os métodos de segmentação baseados na detecção de descontinuidades pontuais, linhas ou as bordas de um objeto partem do princípio que estas características sobressaem em uma imagem, sejam por tons de cinza distintos da região onde estão inseridas ou por assinalarem mudanças bruscas de tons de cinza entre regiões. Normalmente esses métodos usam a convolução através do uso de máscaras. Esses métodos, em geral, apresentam falhas necessitando de um pós-processamento visando corrigi-las.

Os métodos de segmentação baseados na detecção de similaridades têm como fundamento a observação do interior dos objetos e não suas fronteiras. Para tanto, parte da idealização que os pixels que compõem um objeto têm propriedades similares enquanto pixels de objetos distintos têm propriedades distintas (FU; MUI, 1981). Entre estes métodos, destacam-se: 1) O crescimento de regiões que visa agrupar pixels ou sub-regiões em regiões maiores partindo de um conjunto de pixels “sementes”. O crescimento se dá por meio da inclusão de vizinhos com características similares tais como intensidade, textura, cor, etc. Esse método apresenta algumas dificuldades como determinar a região de início do processo, ou seja, a escolha das sementes, a escolha do critério de similaridade a ser aplicado e a determinação do critério de parada; 2) Pirâmides onde ocorre a subdivisão da imagem em quadrantes usando uma estrutura denominada *quadtree* (abreviatura da expressão em inglês *quadratic picture tree*). Nessa estrutura a imagem é representada por um nó pai (nível $n=0$), enquanto que os quatro quadrantes são representados por quatro nós filhos (nível $n=1$), e assim por diante em uma ordem

pré-determinada. A partir desses, realiza-se a junção ou divisão das regiões; 3) A detecção de bacias que pode ser visto como uma combinação entre detecção de bordas e junção de regiões. Essa técnica baseia-se no princípio de “inundação de relevos topográficos” (RUSS, 1998) de que uma imagem em níveis de cinza pode ser vista como um relevo topográfico, formado por vales, que representam as regiões mais escuras da imagem, e por montanhas, que representam as porções mais claras (ROERDINK; MEIJSTER, 2000) sendo tomadas por “água”. O resultado da inundação é a separação das regiões que compõem a imagem delimitada pelas linhas divisórias da bacia.

Dentre os métodos de segmentação no espaço de atributos tem-se: a limiarização e o agrupamento. A limiarização como sendo uma das formas mais simples a serem utilizadas e uma das abordagens mais importantes para a segmentação (GONZALES; WOODS, 2000). O processo todo se baseia na análise do histograma de frequências da imagem, onde as faixas de intensidade correspondem às bandas do histograma. Um caso simples de ser entendido é o de um histograma bimodal. Nessa situação, o histograma apresenta dois picos separados por um vale entre eles, sendo assim, esses picos podem representar duas regiões distintas, como por exemplo, um fundo e um objeto, como apresentado na Figura 9.

Figura 9 - Exemplo de limiarização por histograma bimodal. (a) Imagem original. (b) Histograma da imagem original. (c) Imagem limiarizada pelo valor de 100



Fonte: Fonseca (2017).

Um levantamento realizado por Queiroz; Pinto (2014) mostra as técnicas de agrupamento (do inglês *clustering*) encontradas na literatura. Essas técnicas

possuem objetivos similares e, sendo assim, segundo Jain (1989), podem ser aplicadas para a segmentação de imagens. Intuitivamente, padrões pertencentes a um dado grupo devem ser mais similares entre si do que em relação a padrões pertencentes a outros grupos (ZUBEN; MOSCATO, 2002). Nesse tipo de segmentação um conjunto de dados é substituído por grupos ou clusters. Para Everitt et al. (2011), a definição de clusters, parte da ideia que valores de atributos são vistos como pontos no espaço I-dimensional, ou seja, clusters são regiões contínuas deste espaço e que contém uma alta densidade de pontos, separadas de outras regiões densas, por regiões com baixa densidade de pontos. Partindo deste ponto, duas abordagens para fundamentação dos algoritmos podem ser obtidas. A primeira leva em consideração o conceito de agrupamento rígido (do inglês, *hard, crisp*) no qual cada ponto pertence a um único grupo. A segunda considera o conceito de agrupamento nebuloso (do inglês, *fuzzy*) onde cada ponto pertence a todos os grupos até um certo grau. Para fins de aplicação na segmentação de imagens, a abordagem mais adequada é a primeira, pois não fere os princípios de segmentação por regiões estipulados por Fu e Mui (1981). O algoritmo mais conhecido e comumente usado é o k-médias.

Os diferentes métodos de segmentação encontram aplicabilidade em função da imagem e objeto de segmentação proposto cabendo uma análise de qual técnica trará o resultado esperado com o menor esforço computacional necessário.

3.1.4 Pós-processamento

O pós-processamento é a etapa seguinte à segmentação onde os principais defeitos e imperfeições da segmentação são corrigidos normalmente através de técnicas de morfologia matemática, com utilização de filtros morfológicos que realizam uma análise qualitativa dos pixels da imagem. As operações são realizadas sempre entre a imagem e o elemento estruturante. A forma do elemento estruturante é função do tratamento desejado, como por exemplo, erosão ou dilatação, e do tipo de conectividade adotada.

3.1.5 Extração de atributos

Quando o objetivo do processamento é obter informações numéricas reduzindo a dimensionalidade dos dados eliminando informações redundantes, realiza-se a extração de atributos (ou características) da imagem (DUDA; HART; STORK, 2001). Nessa fase, geralmente procura-se por propriedades invariantes onde o processo de extração não varia de acordo com condições específicas ou definidas (NIXON; AGUADO, 2008). Descritores da imagem são obtidos através dos vetores de características com propriedades como cor, textura, forma ou relacionamento entre objetos adicionados a uma métrica de comparação (GONZALES; WOODS, 2000). Os descritores de características podem ser agrupados nas seguintes classes: 1) Características dimensionais que são aquelas que podem ser medidas diretamente no objeto, ou seja, são informações de dimensões do objeto, por exemplo, área e perímetro; 2) Características inerciais sendo aquelas relacionadas às propriedades dos corpos rígidos, contemplando informações como o centro geométrico da imagem, a orientação e seus momentos; 3) Características topológicas carregam informações como a quantidade de furos, de vértices e seus componentes conectados; 4) Características de aspecto são relacionadas à textura, cor, acabamento, rugosidade, etc.

As características dimensionais do objeto utilizam como descritores a área e o perímetro. A área é obtida pela contagem de todos os pixels do objeto sendo uma propriedade geométrica. Características como área do retângulo são úteis para obtenção de reconhecimento, porém somente são válidas para imagens que não variam. O perímetro, diâmetro, raio, retangularidade e alongamento são atributos que também podem ser utilizados para facilitar a obtenção de características para identificação de um objeto em uma imagem.

Baseada na teoria de momentos, as características inerciais podem ser aplicadas na identificação de objetos e são utilizadas especificamente para caracterizar funções com densidade de probabilidade. Quando se tem o objetivo de reconstruir uma imagem a partir de seus momentos, os ortogonais e os de Legendre são muito utilizados nas engenharias. Adicionalmente, esses momentos podem ser

combinados para formarem um conjunto de características que permitem a identificação de um objeto sem depender da orientação em relação à sua posição.

Os principais descritores das características topológicas são: 1) números de componentes conectados, isto é, quaisquer pontos que estiverem conectados a um conjunto podem ser interligados por uma linha pertencente ao mesmo subgrupo; 2) número de furos, que é a quantidade de furos encontrados no interior do objeto e; 3) número de Euler, classificado como o número de componentes conectados acrescido do número de furos.

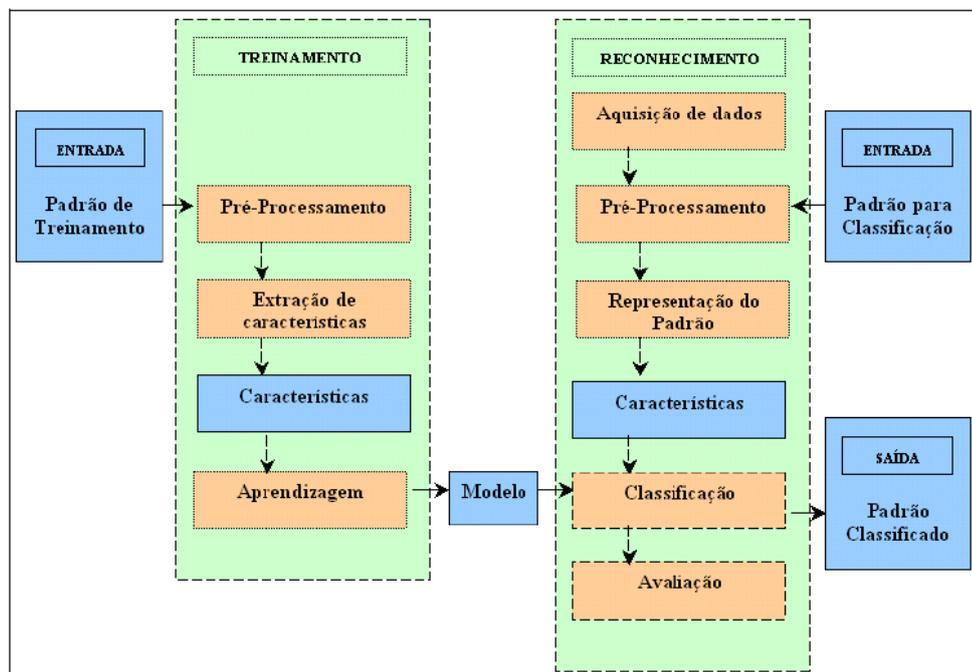
O aspecto consiste por caracterizar objetos a partir da extração de sua cor ou de sua textura. Algumas extrações com uso de características de aspecto são complexas por possuírem limitações com a identificação de materiais semelhantes como os ferrosos. Por outro lado, caso a imagem utilizada possua peças com materiais metálicos pode ser facilitado. Em muitos casos, a textura contribui consideravelmente para uma melhor exatidão no processo de reconhecimento e classificação do objeto ou imagem, pois é um aspecto que frequentemente se encontra em imagens naturais e é muito bem reconhecido pela visão humana, salvo quando a análise da imagem é realizada intuitivamente. A caracterização por meio da textura é dependente da comparação e percepção de padrões de superfície.

Com o objetivo de reduzir a dimensionalidade das informações extraídas da imagem, em muitos casos pode ser empregado a análise de componentes principais (PCA, do inglês *Principal Component Analysis*). É um procedimento matemático que utiliza uma transformação ortogonal (ortogonalização de vetores) para converter um conjunto de observações de variáveis possivelmente correlacionadas num conjunto de valores de variáveis linearmente não correlacionadas chamadas de componentes principais.

3.2 RECONHECIMENTO DE PADRÕES

O ser humano possui uma capacidade singular para reconhecer padrões. Ao enxergar algo, coleta informações para identificar, isolar, associar e reconhecer formas, sons ou conceitos (LIMA; PINHEIRO; SANTOS, 2014). Denomina-se reconhecimento ou classificação o processo de atribuição de um rótulo a um objeto, baseado nas características extraídas do objeto que são representadas por descritores. Existem duas fases em um ambiente de reconhecimento: aprendizado (ou treinamento), onde o conhecimento dos conjuntos de objetos que podem estar presentes na imagem e as informações relevantes estão em um banco de dados; e interpretação (ou reconhecimento), que pressupõe a análise de novas imagens e não possui informações no banco de dados. A Figura 10 apresenta um digrama representativo de um sistema de reconhecimento de padrões.

Figura 10 - Sistema de reconhecimento de padrão



Fonte: Stange; J. Neto (2010).

A importância atual do reconhecimento de padrões está ligada à procura por métodos informatizados e automatizados para tarefas humanas repetitivas, exaustivas e muito sujeitas a falhas. Inúmeras aplicações de reconhecimento de padrões em imagens digitais têm sido desenvolvidas nas mais diversas áreas ao

longo dos anos (ERPEN, 2004). Entre elas pode-se citar sensoriamento remoto, medicina, radar, sonar, robótica, inspeção automática de componentes industriais, entre outros (JAIN et al., 2000) (PICOLLI et al., 2015).

As técnicas de classificação podem ser do tipo supervisionadas e do tipo não supervisionadas. Na classificação supervisionada, um conjunto-padrão de objetos conhecidos pertencentes a diferentes classes é analisado, escolhendo-se os parâmetros ideais para a separação das classes. Já na classificação não supervisionada é usada nas aplicações em que informações de classificação não estão disponíveis.

Para o processo de reconhecimento de padrões usam-se métodos de abordagem que podem ser: estatística (ou teoria da decisão), sintática (ou estrutural), neuronal ou nebulosa.

A maioria dos classificadores estatísticos tem como base a regra de decisão de Bayes assumindo uma distribuição normal da população (ERPEN, 2004). Neste caso, a probabilidade a priori não é conhecida em muitos dos casos devendo ser estimada a partir das amostras. Apesar disso, nada impede que sejam empregadas técnicas determinísticas. Já com os classificadores neurais não há necessidade de considerações das funções de densidade de probabilidade, no entanto, existe o problema em se definir a arquitetura da rede neural artificial (RNA). A abordagem nebulosa, não-determinística, baseada em lógica difusa (ou *fuzzy*, do inglês), diferentemente das demais abordagens onde se tem limites bruscos entre elementos pertencentes e não pertencentes ao conjunto, a transição está em uma faixa gradual entre o membro e não membro.

O método sintático é utilizado em problemas onde os padrões são considerados complexos e o número de características é alto. Cada padrão é classificado em sub padrões e cada um destes em suas partes, chegando até padrões mais simples conhecidos como primitivas. Da mesma forma que a gramática de uma linguagem forma frases e sentenças pela concatenação de palavras e estas por letras, este método estrutura os padrões na forma de várias composições de sub padrões.

Em Stange e J. Neto (2010) é realizada uma comparação entre as diferentes técnicas de reconhecimento de padrões. Os métodos estatísticos são predominantes na literatura, porém, cada abordagem tem seu domínio, sendo uma técnica mais apropriada que outra em função da aplicação (DUDA; HART; STORK, 2001). Os métodos estatísticos são apropriados quando o foco é evidenciar tendências no espaço amostral e quando suas particularidades são irrelevantes, tendendo a obter resultados rapidamente. Entretanto, alguns problemas de classificação incluem atributos nominais ou categóricos, sem noções naturais de semelhança ou de ordem. Nestes casos, a distribuição de probabilidade não é adequada necessitando de métodos mais apropriados como os determinísticos (árvores de decisão e aprendizagem baseada em regras, por exemplo).

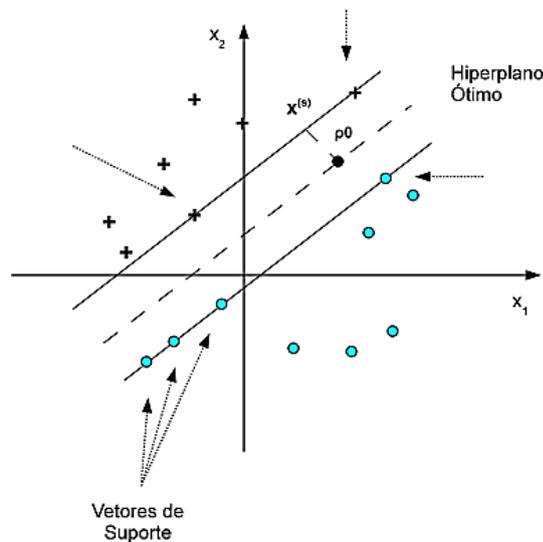
Os sistemas baseados em Redes Neurais Artificiais (RNA's) são muito utilizados principalmente devido à sua estrutura paralela e distribuída e à sua habilidade para aprender, e, portanto, generalizar o conhecimento adquirido (HAYKIN, 1999). O seu uso também se destaca pelas propriedades de aprendizagem de conjuntos linearmente inseparáveis, mapeamento de entrada-saída, adaptação, tolerância à falhas e uniformidade de análise e projeto. É importante destacar que as RNA's são baseadas na minimização do risco empírico, ou seja, minimização do erro de treinamento. Entretanto, essa técnica apresenta problemas como: algoritmos de aprendizagem envolvendo geralmente um grande número de exemplos de treinamento, longos períodos de treinamento, ocorrência de mínimos locais e arquitetura definida a partir de experimentos.

3.2.1 Máquinas de vetores de suporte (SVM)

As Máquinas de Vetores de Suporte (SVM, do inglês *Support Vector Machines*) é uma técnica estatística de aprendizagem de máquina propostos por Vapnik (1999) a partir de estudos iniciados em Vapnik e Chervonenkis (1971). A ideia principal de uma SVM é construir um hiperplano como superfície de decisão de tal forma que a margem de separação entre exemplos positivos e negativos seja máxima. Desta

forma, a SVM consiste em um mapeamento não-linear de um vetor de entrada para um espaço de características de alta dimensionalidade, que é oculto da entrada e da saída. O hiperplano ótimo separa as características descobertas após o mapeamento, como ilustrado na Figura 11.

Figura 11 - Ideia de um hiperplano ótimo para padrões linearmente separáveis



Fonte: Rocha (2013).

A SVM representa uma implementação do método de minimização estrutural de risco, que é um princípio estatístico indutivo baseado no fato de que a taxa de erro de uma máquina de aprendizagem sobre dados de teste (taxa de erro de generalização) é limitada pela soma da taxa de erro de treinamento e por um termo que depende da dimensão de Vapnik-Chervonenkis (V-C) (VAPNIK; CHERVONENKIS, 1971). No caso de padrões separáveis, uma SVM produz um valor de zero para o primeiro termo e minimiza o segundo termo.

Algumas características justificam a utilização do método SVM na classificação, tais como: boa capacidade de generalização, robustez em alta dimensionalidade, capacidade de lidar com dados ruidosos e uma base teórica matemática e estatística solidamente fundamentada (BURGES, 1998), apesar do fato de que ele não incorpora conhecimento do domínio do problema. Este atributo é único das SVM's.

Conforme citado por Lorena e Carvalho (2007), os resultados da aplicação dessa técnica são comparáveis, e muitas vezes superiores, aos obtidos por outros algoritmos de aprendizado, como as Redes Neurais Artificiais (RNA's) (BRAGA, CARVALHO; LUDERMIR, 2000). Exemplos de aplicações de sucesso podem ser encontrados em diversos domínios, como na categorização de textos (JOACHIMS, 2002), na análise de imagens (KIM et al., 2002) (PONTIL; VERRI, 1998) e em Bioinformática (NOBLE, 2004).

Apesar de possuir uma performance eficaz para a maioria dos problemas de classificação e regressão, a SVM é sensível a escolha dos parâmetros, permitindo a aplicação de muitas estratégias para seleção e otimização do processo, sendo realizado normalmente empiricamente ou através de experimentos por tentativa e erro.

Um maior aprofundamento matemático desta técnica pode ser encontrado em Haykin (1999) e em Burges (1998).

3.2.2 k-Vizinhos mais próximos (kNN)

O algoritmo k-Vizinhos Mais Próximos (kNN, do inglês *k-Nearest Neighbor*) foi proposto por Fukunaga e Narendra (1975) sendo um dos classificadores de mais simples implementação, mas ainda com bons resultados dependendo da aplicação. O kNN é um classificador onde o aprendizado é baseado na analogia. Um conjunto de treinamento é formado por vetores n-dimensionais e cada elemento deste conjunto representa um ponto no espaço n-dimensional. Segundo Webb (2002) "O kNN é um método simples de estimação de densidade". O kNN recebe essa denominação pelo ao fato dele estimar a densidade local de padrões de treinamento na vizinhança de um padrão desconhecido durante a classificação.

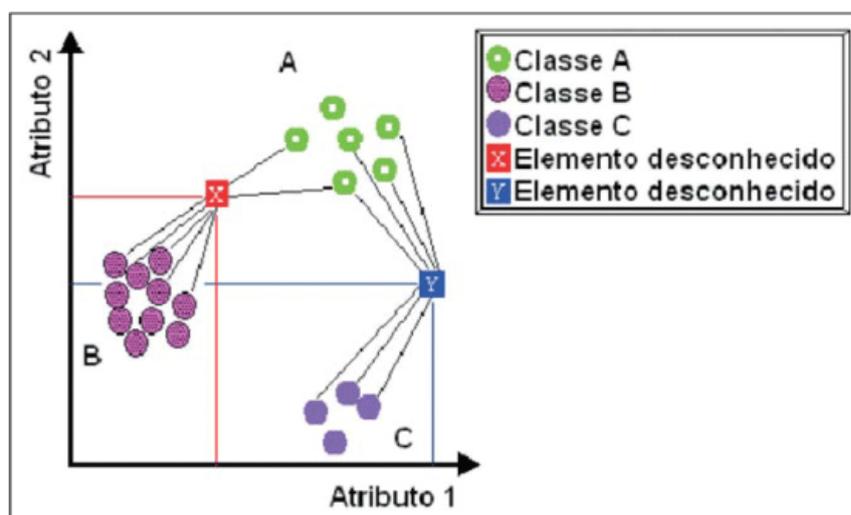
Para determinar a classe de um elemento que não pertença ao conjunto de treinamento, o classificador kNN procura k elementos do conjunto de treinamento que estejam mais próximos deste elemento desconhecido, ou seja, que tenham a

menor distância ou maior similaridade. Estes k elementos são chamados de k -vizinhos mais próximos. Verificam-se quais são as classes desses k -vizinhos e a classe mais frequente será atribuída à classe do elemento desconhecido. Algumas métricas diferentes podem ser utilizadas no cálculo de distância entre pontos, sendo as mais comumente utilizadas a Euclidiana, Manhattan e Minkowski. Pesos podem ainda ser aplicados atribuindo determinada importância a cada variável. O critério de similaridade é um aspecto que possui grande influência no desempenho do método KNN (SHAKHNAROVICH; DARRELL; INDYK, 2005).

O kNN é um classificador que possui apenas um parâmetro livre (o número de k -vizinhos) que é controlado pelo usuário com o objetivo de obter uma melhor classificação. Em um grande número de dados o método pode ser computacionalmente exaustivo, mas bem aceito em aplicações com um número menor de dados.

Na Figura 12, apresenta-se em forma de exemplo uma representação com dois atributos (espaço bidimensional) onde dois elementos desconhecidos devem ser classificados entre três possíveis classes utilizando os 7 vizinhos mais próximos ($k=7$).

Figura 12 - Exemplo de classificação de dois elementos desconhecidos em um espaço bidimensional com $k=7$



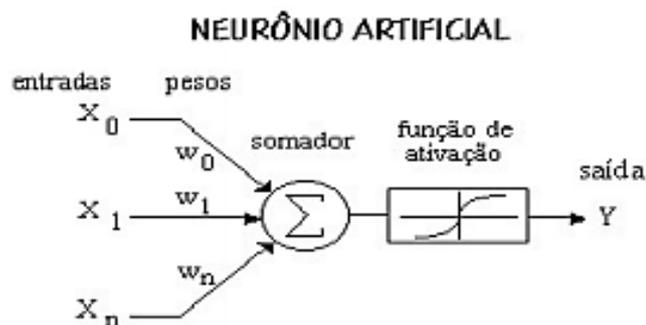
Fonte: Martins et al. (2005).

3.2.3 Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais (RNA) vêm originalmente da tentativa de modelar o comportamento da rede de neurônios do cérebro humano e compreender seu funcionamento. Além da motivação de se conseguir realizar atividades como reconhecimento de padrões e controle motor através de simulações do funcionamento do cérebro. Para Haykin (1999), uma rede neural artificial é um sistema de processamento maciçamente paralelo, composto por unidades simples com capacidade natural de armazenar conhecimento e disponibilizá-lo para uso futuro. A natureza das RNA's faz com que seu estudo seja multidisciplinar, envolvendo as áreas da neurofisiologia, psicologia, física, computação, engenharia, estatística, entre outras.

A estrutura que é conhecida como a unidade básica de uma rede neural foi projetada por McCulloch e Pitts (1943). Um modelo de neurônio com uma unidade de processamento binária capaz de executar diversas operações lógicas como demonstrado na Figura 13.

Figura 13 - Representação funcional de um neurônio artificial

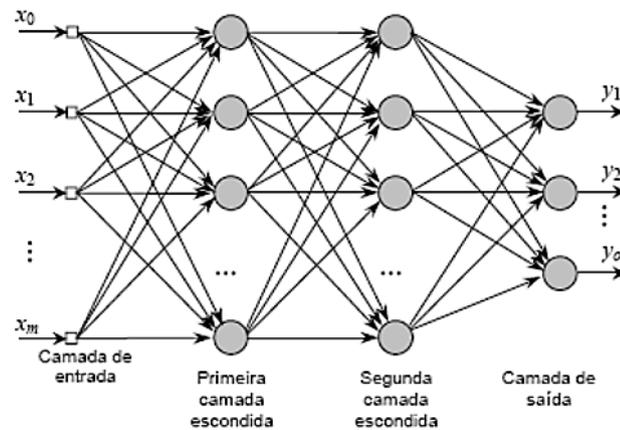


Fonte: Christo (2005).

As redes são formadas por conjuntos de neurônios. No caso mais simples das redes em camadas, têm-se uma camada de entrada com neurônios cujas saídas alimentam a última camada da rede. A rede é chamada de *feedforward* se a

propagação do sinal e unidirecional. Caso existam mais camadas intermediárias, estas são chamadas de camadas ocultas. Adicionando-se uma ou mais camadas intermediárias, aumenta-se o poder computacional de processamento não-linear e armazenagem da rede. Um exemplo de uma rede multicamadas pode ser vista na Figura 14.

Figura 14 - Rede Neural Artificial multicamadas *feedforward*.



Fonte: Oliveira et al. (2010).

A capacidade de aprendizagem é uma das características marcantes das RNA's. Uma rede neural aprende, basicamente, através de um processo iterativo de ajuste de pesos e limiares (bias).

Existem diferentes arquiteturas, tipos de neurônios e métodos de treinamento, cada um deles apresentando uma gama de vantagens e desvantagens. Um estudo mais aprofundado pode ser encontrado em Haykin (1999).

3.2.4 Somas acumuladas (CUSUM)

As Somas Acumuladas (CUSUM, do inglês *Cumulative Sum*) foram introduzidas pela primeira vez por Page (1954), tendo como finalidade o monitoramento da variabilidade de um processo. Essa ferramenta estatística tem como principal vantagem o fato de que esta acumula informações das amostras de um processo ponderando-as igualmente, fazendo com que as amostras tenham o mesmo peso. Por este motivo, estes gráficos são capazes de detectar pequenas e persistentes mudanças na média de um processo.

O método da Soma Acumulada pode ser representado pelo CUSUM tabular e pela máscara V. De acordo com Montgomery (2004), o CUSUM tabular trabalha acumulando desvios da média (μ_0) que estão acima do valor alvo, com uma estatística C^+ , e acumulando desvios de μ_0 que estão abaixo do valor alvo, com outra estatística C^- . As estatísticas C^+ e C^- são chamadas CUSUMs unilaterais superior e inferior, respectivamente. Elas são calculadas através das Equações 2 e 3:

$$C_i^+ = \max[0, x_i - (\mu_0 + K) + C_{i-1}^+] \quad (2)$$

e

$$C_i^- = \max[0, (\mu_0 + K) - x_i + C_{i-1}^-], \quad (3)$$

onde os valores iniciais são $C^+ = C^- = 0$.

Quando o processo está sob controle, supõe-se, como premissa básica, que tem uma distribuição normal com média μ_0 e desvio padrão σ (FACCIO; WERNER, 2010). Nas equações 2 e 3, K é um valor de referência (também denominado valor de tolerância ou de folga), e é aproximadamente a metade do valor que se tem interesse em detectar rapidamente, determinando valores entre o valor pretendido μ_0 e o valor da média fora de controle μ_1 . Assim, se a mudança é expressa em unidades de desvio padrão como $\mu_1 = \mu_0 + \delta * \sigma$, então K é a metade da magnitude dessa mudança, ou seja, conforme Equação 4:

$$K = \frac{\delta}{2} * \sigma = \frac{|\mu_1 - \mu_0|}{2}, \quad (4)$$

onde δ é o valor da mudança que se deseja detectar em unidades de desvios padrão, σ o desvio padrão, μ_0 o valor pretendido e μ_1 o valor da média fora de controle. Quanto menor o valor obtido da equação acima, menor será a faixa de variação que o gráfico será capaz de detectar e maior será a sensibilidade do gráfico.

É importante ressaltar que C_i^+ e C_i^- acumulam desvios a partir do valor alvo μ_0 que são maiores do que K , com ambas as quantidades recolocadas em zero ao se tornarem negativas.

Um estudo mais aprofundado desta técnica pode ser encontrado em Basseville e Nikiforov (1996).

4 METODOLOGIA

Este capítulo apresenta a metodologia utilizada para a solução do problema proposto neste trabalho. Na Seção 4.1, descrevem-se as técnicas de processamento digital de imagens empregadas cujo resultado é uma imagem binária, com as bordas da cena, que é essencial para o processo de identificação da região do jato na imagem. Na Seção 4.2, descreve-se a etapa de extração de características e reconhecimento de padrões. A solução do problema proposto neste trabalho foi desenvolvida utilizando o *software* Matlab proprietário da MathWorks.

4.1 LOCALIZAÇÃO E SEGMENTAÇÃO DO JATO NA IMAGEM

A etapa de localização, em conjunto com a segmentação da região de interesse, tem por objetivo reproduzir, no meio digital e guardadas as devidas proporções, o processo cognitivo sofisticado realizado pelo sistema visão e o cérebro humano, de identificar padrões em imagens capturadas pelo sistema de visão humano (JESUS; ALMONFREY, 2014). Atualmente, na literatura, encontra-se um grande número de trabalhos existentes que descrevem ou fazem uso de técnicas de segmentação em imagens, como os encontrados em Cheng et al. (2001); Jesus e Almonfrey (2014); Severino e Gonzaga (2013), por exemplo. Entretanto, não se encontram estudos aplicados, especificamente, ao caso de segmentação abordado neste trabalho. Utilizar imagens em um ambiente como a aciaria, constitui um desafio pelas diversas interferências relacionadas ao pó, fumaça, luminosidade não controlada, entre outras. Em algumas aplicações, onde a temperatura do objeto em questão sobressai-se no ambiente, a utilização de uma câmera que capta níveis de radiações infravermelhas, como neste caso, pode eliminar muitas dessas interferências.

Na abordagem proposta, por meio das imagens geradas por uma câmera termográfica fixa (AMEPA) apontada para a região de vazamento da panela de aço,

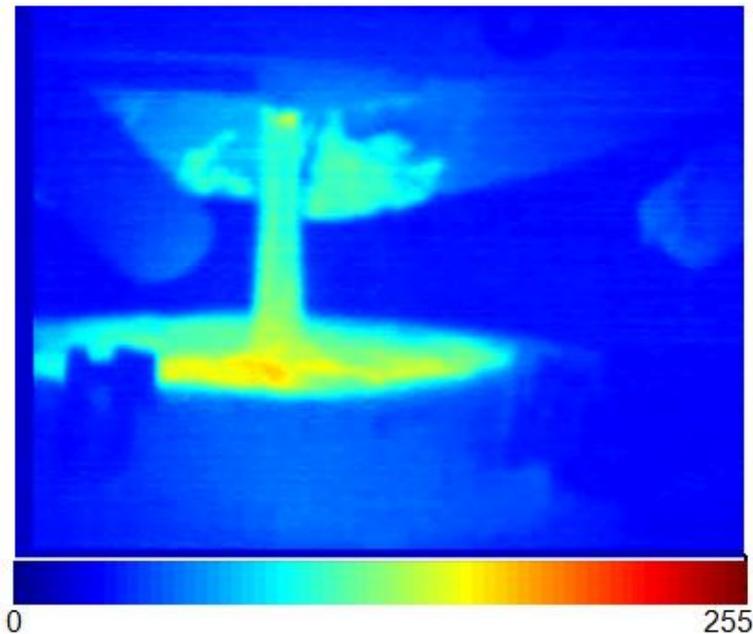
monitora-se o processo de vazamento do início ao fim. Este tipo de equipamento percebe imagens na faixa de radiações infravermelhas do espectro eletromagnético e as convertem para uma faixa visível do espectro, normalmente, para uma escala de intensidade de cinzas, onde 0 (preto) representa o valor mais baixo da escala do equipamento com a menor temperatura e 255 (branco) representa o maior valor da escala deste com a maior temperatura. Um quadro do vídeo gerado pelo sinal infravermelho, convertido para escala de cinza, é mostrado na Figura 15. Além disso, a imagem pode ser colorida por software, através de uma barra de cores em escala unidimensional. Esta coloração permite destacar as diferentes intensidades, ou temperaturas, ao olho humano como mostrado na Figura 16 com o mapa de cores padrão *jet* indicado na parte de baixo da figura.

Figura 15 - Quadro obtido no vazamento de aço na panela em escala de cinza



Fonte: Autoria própria.

Figura 16 - Quadro obtido no vazamento de aço na panela com a barra de cores *jet*

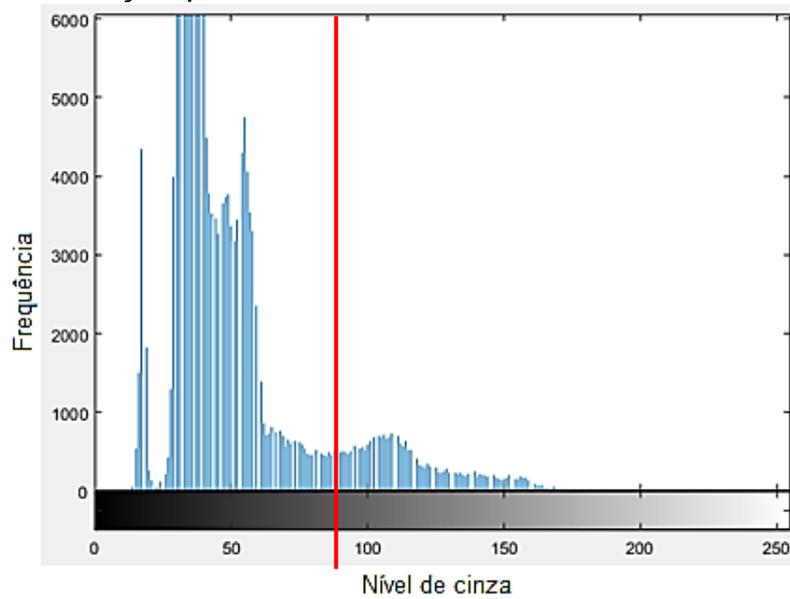


Fonte: Autoria própria.

Com tais imagens, objetiva-se identificar a localização do jato, quadro a quadro, de forma a segmentá-lo das demais informações e extrair características que possam ser utilizadas para encontrar um padrão que identifique o início da passagem de escória. Cabe ressaltar, que ao longo do vazamento, o convertedor tem sua inclinação alterada e a panela movimenta-se no intuito de manter a queda no local correto. Com isso, a imagem do jato posiciona-se em diferentes regiões do quadro ao longo do processo. Além disso, suas dimensões não se mantêm fixas e o tempo de vazamento varia entre 4 e 11 minutos.

Ao trabalhar-se com imagens em escala de cinza, não há preocupações em avaliações relativas ao melhor espaço de cores (RGB, HSV, $L^*a^*b^*$, por exemplo) a ser utilizado como ocorre com imagens coloridas (JESUS et al., 2016). Uma limiarização a partir do histograma de níveis de cinza (Figura 17) permite encontrar a região que contém aço na imagem. Para isso, encontra-se a posição que contém o maior número de ocorrências ou intensidades, subtrai-se de um valor delta igual a 80 definido através de inspeção e testes, garantindo que haja um valor mínimo de ocorrências. Com isso, define-se a posição da linha vermelha exibida na Figura 17, separando em duas regiões distintas.

Figura 17 - Histograma obtido a partir do quadro em escalas de cinza indicando a limiarização por uma linha vermelha



Fonte: Autoria própria.

Com a limiarização aplicada, obtém-se a imagem exibida na Figura 18.

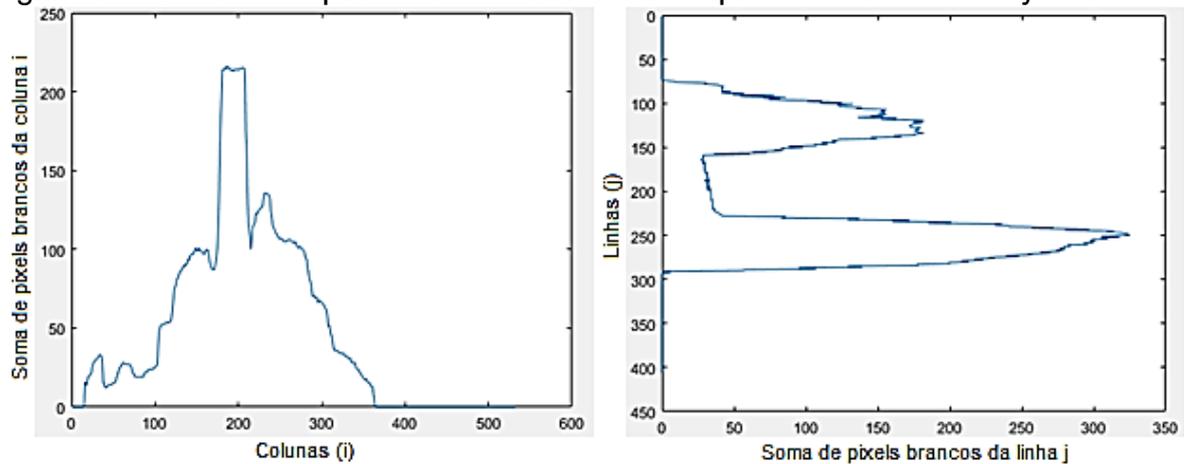
A partir desta imagem deve-se adotar uma estratégia para identificar a região do jato. Com a soma de pixels ao longo de cada linha e coluna da imagem, obtêm-se os gráficos exibidos na Figura 19.

Figura 18 - Segmentação do aço na imagem



Fonte: Autoria própria.

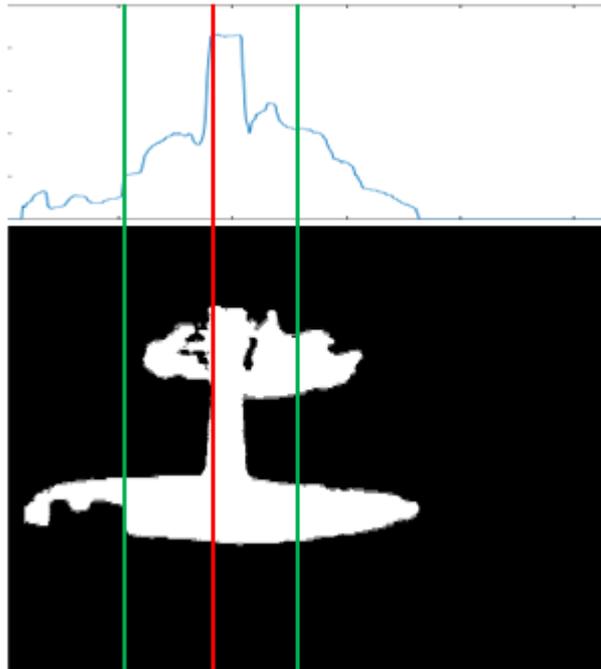
Figura 19 - Soma dos pixels das colunas i à esquerda e das linhas j à direita



Fonte: Autoria própria.

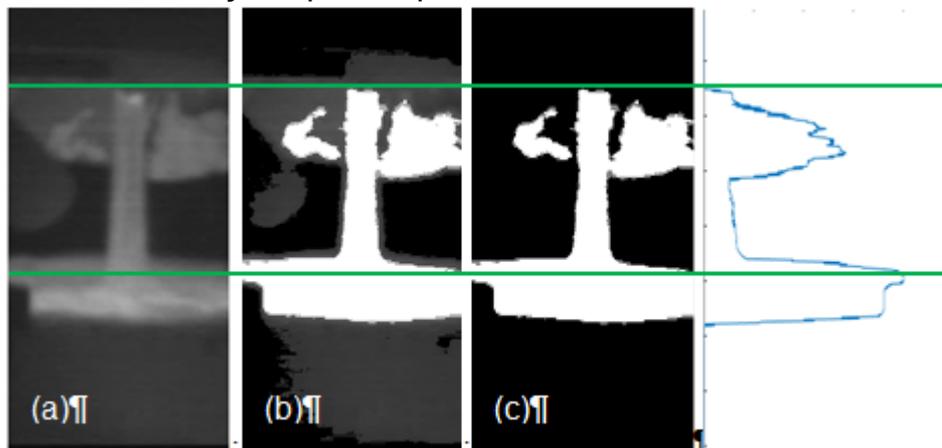
Com base nos gráficos da Figura 19, busca-se realizar um primeiro recorte em torno da região do jato através dos vetores obtidos pela soma dos pixels. Inicia-se por um primeiro recorte vertical. Para isso, utiliza-se a posição do maior valor encontrado na soma das colunas (linha vermelha da Figura 20, a partir da qual obtém-se o limite esquerdo subtraindo-se o valor de 100 e o limite direito adicionando-se o valor de 100 indicados pelas linhas verdes na Figura 20). Estes valores foram obtidos através de inspeção visual em diferentes quadros de variadas corridas. O resultado do recorte vertical pode ser observado na Figura 21 (a). Uma pré-filtragem através do histograma em escala de cinzas é realizada novamente, com a intensidade inferior de 50 e superior de 90 obtidas por variações destes valores e observando-se os resultados, chegando-se as imagens da Figura 21 (b) e Figura 21 (c) (após uma binarização).

Figura 20 - Quadro com o aço segmentado e a indicação das delimitações para o primeiro recorte vertical da região do jato



Fonte: Autoria própria

Figura 21 - Primeiro recorte vertical do quadro e segmentação do aço com a indicação das delimitações para o primeiro recorte horizontal

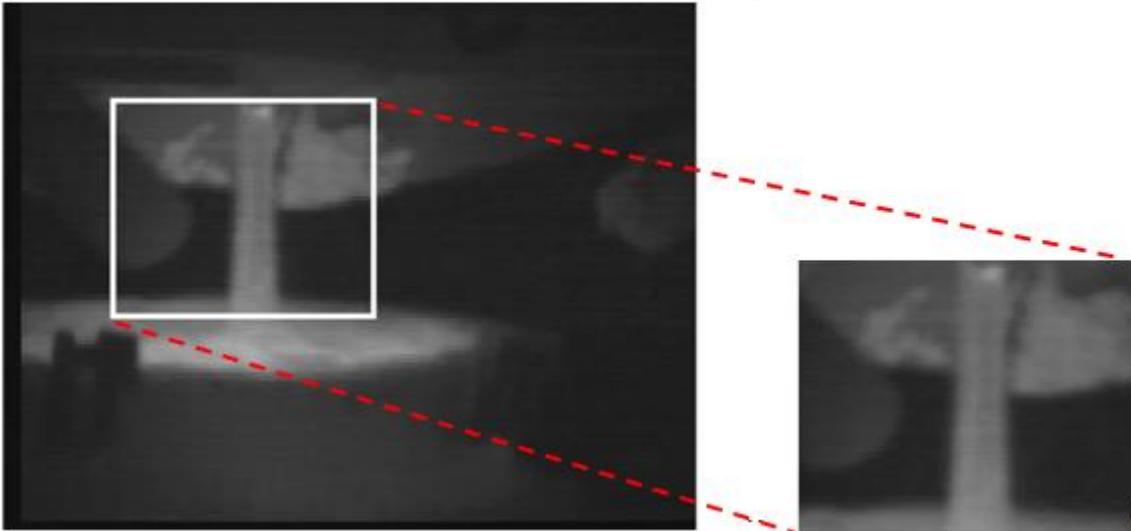


Fonte: Autoria própria

Já para o recorte horizontal, repete-se o processo de obtenção da soma dos pixels para as linhas, a partir do recorte vertical realizado (Figura 21). Para identificação do limite superior, utiliza-se a primeira posição encontrada varrendo-se o vetor de cima para baixo (linha verde superior na Figura 21). Para o limite inferior, utiliza-se a

posição do maior valor encontrado no mesmo gráfico desde que sejam atendidas condições mínimas posicionais (linha verde inferior na Figura 21). A região definida, pelos recortes verticais e horizontais, é exibida na Figura 22.

Figura 22 - Primeiro recorte da região de interesse (jato)



Fonte: Autoria própria

Segue-se um processo semelhante ao realizado anteriormente com a segmentação do aço na imagem a partir da região apresentada na Figura 22. As alturas iniciais e finais do jato já estão definidas restando identificar a posição de suas laterais. O aço é novamente segmentado e o gráfico da soma dos pixels das colunas é obtida. Ao se analisar o resultado na Figura 23 (a), pode-se pensar na utilização da derivada discreta como um bom caminho. No entanto, nem sempre a maior diferença entre valores sequenciais está na região de interesse, eliminando a hipótese de seu uso. Deve-se adotar uma estratégia diferente.

A estratégia de definição das posições laterais do jato de aço inicia-se encontrando a posição do maior valor do de soma de pixels das colunas $\text{máximo}(y)$ na Figura 23 (a). Essa posição, indicada pela linha tracejada vermelha, separa o gráfico em duas regiões, uma a sua esquerda e outra à sua direita. Na primeira região (à esquerda), do início até o ponto encontrado, para cada posição i , contabiliza-se a diferença em relação ao valor da posição anterior, ou seja, $y_i - y_{i-1}$. O valor encontrado é

acumulado enquanto esta diferença se mantiver positiva. O fato da diferença se tornar negativa indica que houve uma mudança de tendência mesmo que localizada. As delimitações das laterais do jato de aço tendem a se comportar com uma maior sequência de diferenças positivas que as demais regiões. A Equação 5 descreve este método aplicado à parte esquerda do gráfico.

$$Y_{acum_esq}(j) = \sum_{j=1}^{j_{\max(y)}} \sum_{i=j}^{i \mid (y_i - y_{i-1}) > 0} (y_i - y_{i-1}). \quad (5)$$

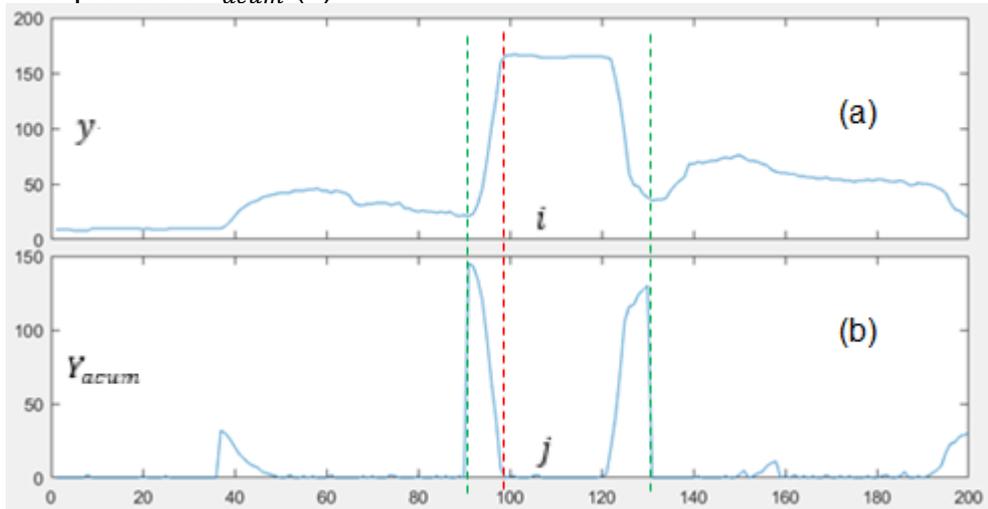
O comportamento de Y_{acum_esq} para a função obtida da Figura 23 (a) está demonstrado na Figura 23 (b). A posição que obtiver a maior sequência com diferenças positivas dos valores acumulados, até alcançar o ponto de máximo da função y , determina o início do jato ou sua lateral esquerda, ou seja, a posição de máximo(Y_{acum_esq}) na região esquerda do gráfico.

De forma análoga, realiza-se um processo semelhante para a segunda parte do gráfico (à direita da linha vermelha) varrendo-se a função y no sentido inverso da última posição até a posição de máximo(y). A Equação 6 descreve este método para a parte direita do gráfico. Dessa forma, obtém-se a lateral direita do jato, ou seja, a posição de máximo(Y_{acum_dir}).

$$Y_{acum_dir}(j) = \sum_{j=\max(i)}^{j_{\max(y)}} \sum_{i=j}^{i \mid (y_{i-1} - y_i) > 0} (y_{i-1} - y_i). \quad (6)$$

As duas posições encontradas pelo método estão representadas pelas linhas tracejadas em verde na Figura 23.

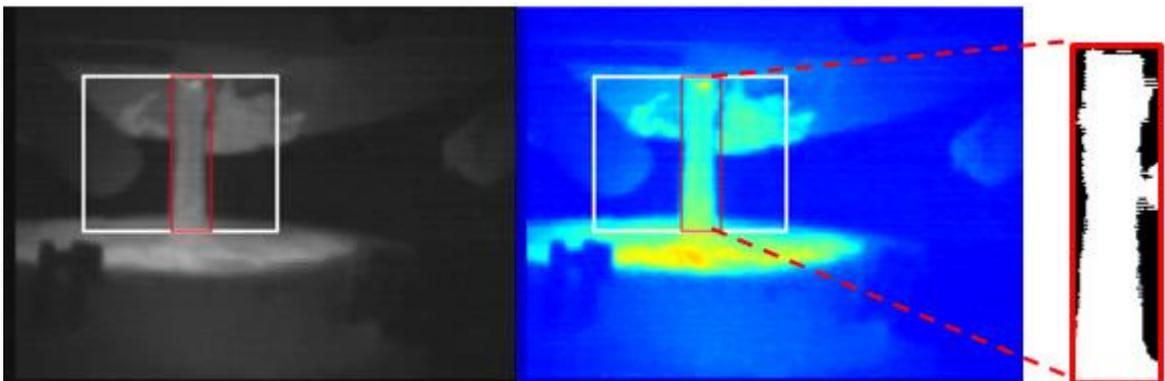
Figura 23 - Soma dos pixels das colunas y (a) e soma acumulada dos valores entre posições sequenciais Y_{acum} (b)



Fonte: Autoria própria

Na Figura 24 é mostrada a região do jato identificada pelo método proposto delimitado pelo retângulo vermelho. Uma filtragem semelhante a aplicada anteriormente é realizada segmentando a região do jato de aço do resto da cena.

Figura 24 - Região do jato localizado na imagem e segmentado



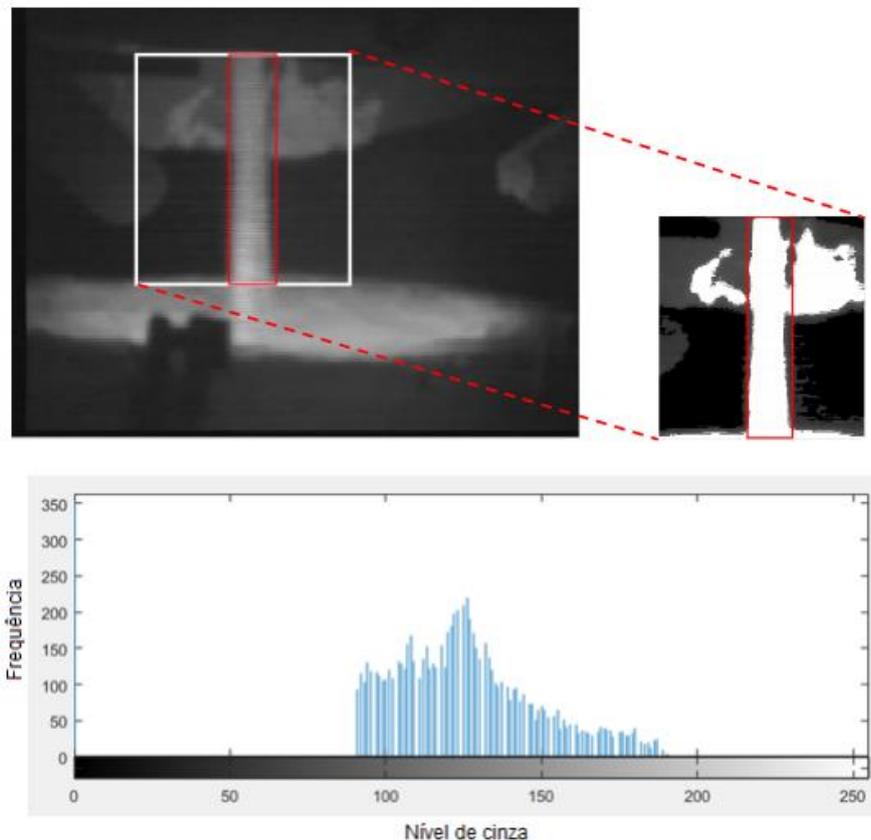
Fonte: Autoria própria

4.2 RECONHECIMENTO DO PADRÃO DE PASSAGEM DE ESCÓRIA

Após a etapa de localização e segmentação do jato de aço, segue-se a etapa de extração de características e classificação através de técnicas de reconhecimento de padrões para identificar a passagem de escória a partir do jato de aço segmentado na imagem. Informações dimensionais e estatísticas são levantadas com o intuito de avaliar as características mais relevantes. Para cada quadro em sequência ao longo do vídeo, extraem-se estas informações e observa-se, através de inspeção, o comportamento ao longo do processo de vazamento de forma temporal.

A partir da região segmentada do jato, são observadas área do jato, área do jato em sub-regiões, histograma de em escala de cinzas (Figura 25), temperaturas, entre outras. Do histograma, outras características são obtidas como média, mediana, moda, desvio padrão e quantidade de ocorrências acima de limites pré-estabelecidos.

Figura 25 - Quadro da imagem segmentado e o respectivo histograma em escala de cinzas da região segmentada do jato de aço (região branca dentro do quadro vermelho)



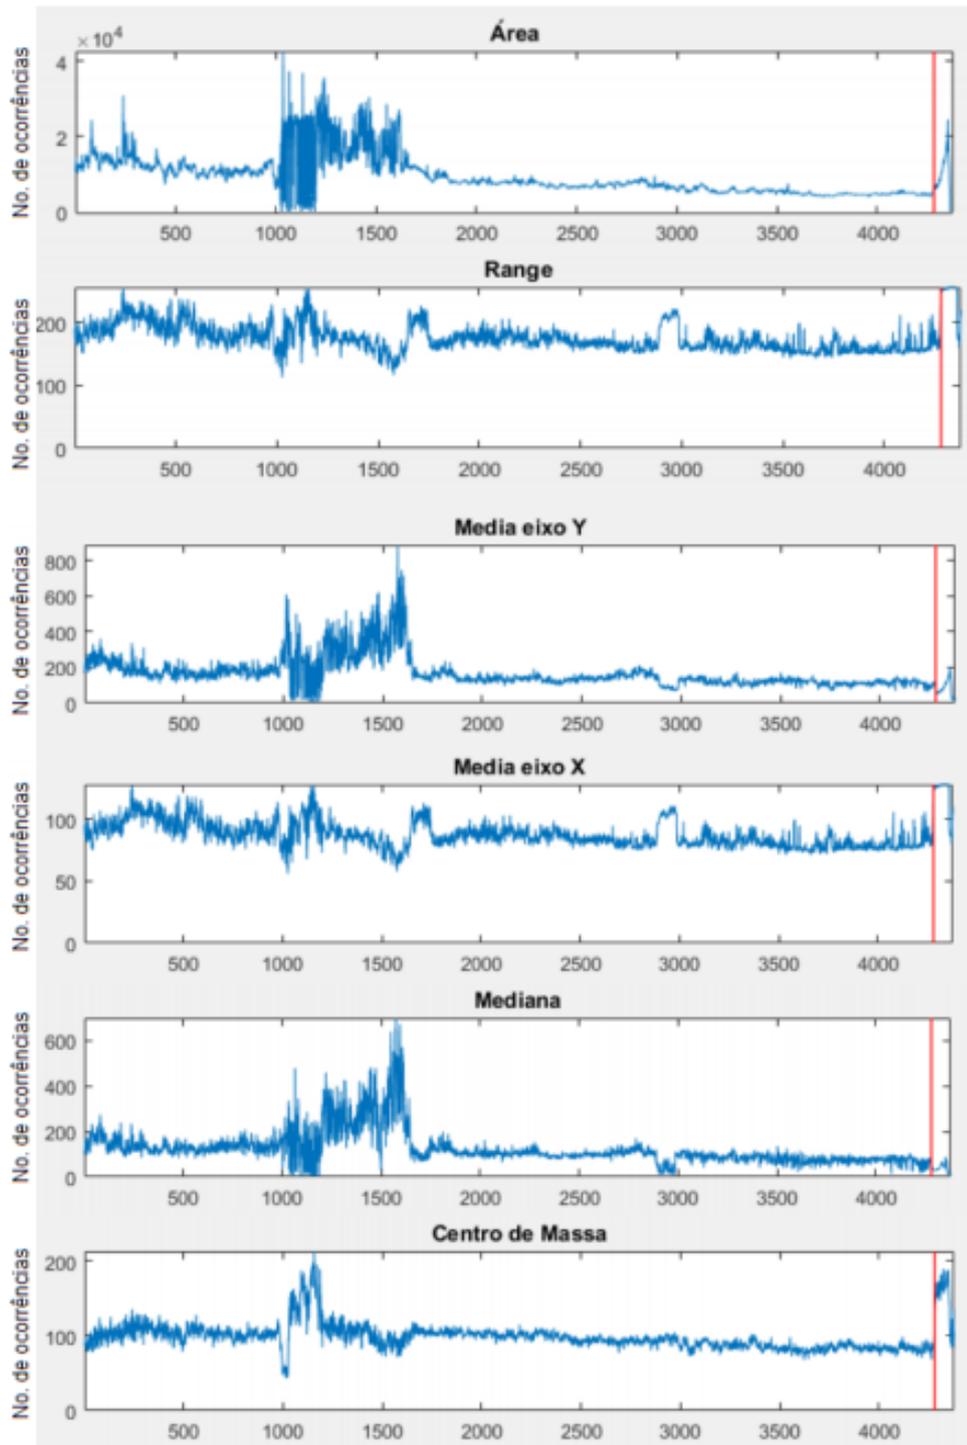
Fonte: Autoria própria

Na Figura 26 pode ser observado o comportamento dimensional e estatístico destas variáveis, no decorrer do vídeo quadro a quadro (eixo horizontal), para uma determinada corrida. A linha vertical vermelha demarca o momento em que se inicia a passagem de escória do convertedor para a panela, ou seja, o momento a ser detectado ou previsto. Este momento foi identificado previamente por inspeção visual avaliando quadro a quadro do vídeo. Aproximadamente entre os quadros 1000 e 1700, observa-se um comportamento instável dos dados. Esta instabilidade coincide com a adição de fundentes na panela levando a reações que provocam distúrbios na imagem. Estas adições de fundentes ocorrem em momentos pré-determinados e conhecidos, normalmente na metade do processo de vazamento, não interferindo no objetivo de se identificar a passagem de escória.

As variáveis são:

- **Área:** Quantidade de pixels iguais a 1 da imagem binária segmentada (jato);
- **Extensão (Range):** Diferença entre a maior e a menor intensidade observada no histograma;
- **Media Eixo Y:** Valor médio das ocorrências no eixo Y do histograma;
- **Média Eixo X:** Valor médio das ocorrências no eixo X do histograma;
- **Mediana:** Valor da mediana das ocorrências no eixo X do histograma;
- **Centro de Massa:** Valor do centro de massa do histograma;
- **Soma > lim x:** Soma das ocorrências acima do limite x no histograma. Onde $x=120, 140, 180$ e 220 .

Figura 26 - Comportamento dimensional e estatístico das variáveis analisadas, no decorrer do vídeo quadro a quadro, para uma determinada corrida

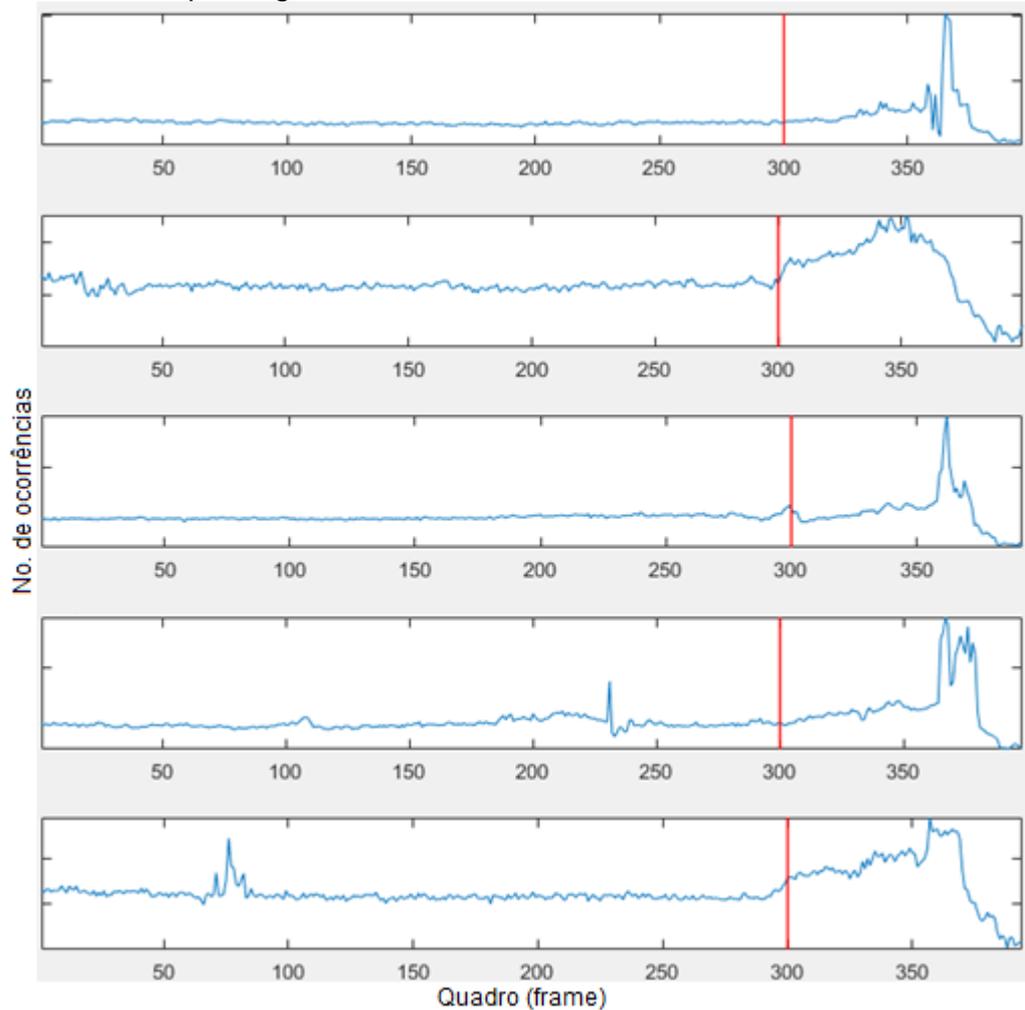


Fonte: Autoria própria

Apesar de grande parte destas variáveis aparentarem mudar de comportamento exatamente no momento da passagem de escória, ao se observar em torno da

região de interesse e por várias corridas, este comportamento não é confirmado. Isto pode ser observado na Figura 27 para, por exemplo, a variável área em cinco corridas distintas.

Figura 27 - Comportamento da característica área, quadro a quadro, em torno da região de início de passagem de escória.



Fonte: Autoria própria

Avalia-se também a possibilidade de se utilizar um simples limiar em escala de cinza para determinar se houve ou não passagem de escória. Na escala de 0 a 255, limiares conservadores acima de 220 garantem detecção de escória, mas de forma tardia, normalmente acima de 3 segundos após o início de sua passagem. A medida que se reduz o valor do limiar, o número de detecções incorretas (indicação de

escória antes do fim do vazamento) se torna elevada e aleatória ocorrendo em qualquer momento do vazamento, inviabilizando o seu uso. A dinâmica do escoamento indica que a escória inicia sua passagem pelo interior do jato não se tornando visível de imediato através da câmera.

Não sendo observado um padrão visível que identifique ou que possibilite prever a passagem de escória, este trabalho propõe um método para este fim. Busca-se aliar a intensidade em escala de cinza a possíveis alterações na dinâmica do escoamento do jato, quadro a quadro, de forma a antecipar sua detecção. Os momentos do vazamento de aço (quadros) serão agrupados em janelas que serão classificadas como (alvo) com presença de escória ou (não alvo) sem presença de escória como mostrado na Figura 28. Os métodos de classificação kNN, SVM, RNA e CUSUM são utilizados em função das características descritas na seção 3.2.

O classificador SVM será treinado, para cada característica, utilizando a opção de otimização da função *fitcsvm* do Matlab. Essa por sua vez busca encontrar o hiperplano que minimiza o erro variando parâmetros como o kernel (gaussiano, linear ou polinomial), escala do kernel, C e ordem dos polinômios.

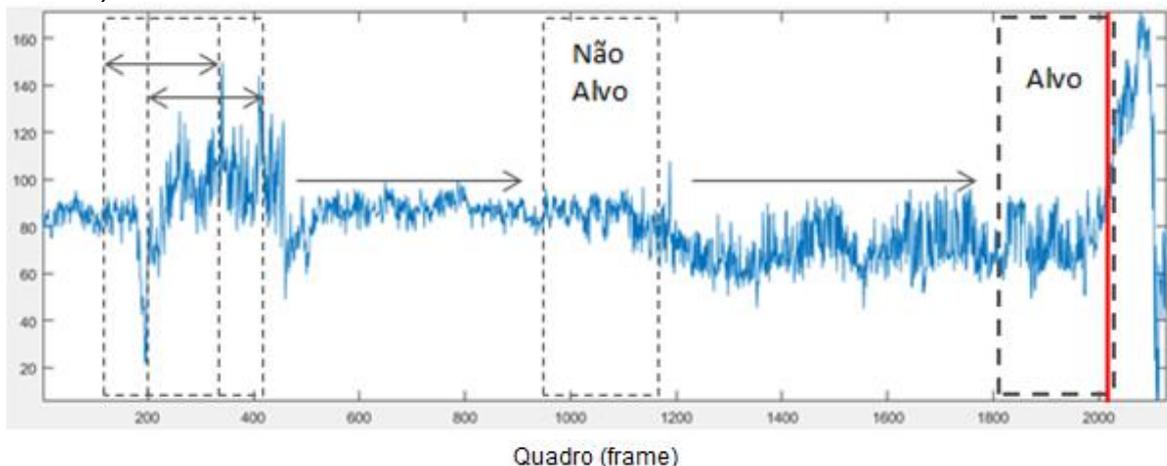
De forma semelhante, o classificador kNN será treinado, para cada característica, utilizando a opção de otimização da função *fitcknn* do Matlab. Esta por sua vez busca obter os parâmetros que minimizam o erro variando parâmetros como o método de cálculo de distância (manhattan, chebychev, euclidiana entre outras) e o número de vizinhos k.

Para o caso da RNA, a escolha da arquitetura não é trivial. Opta-se por trabalhar com uma arquitetura simples com uma rede *feedforward* com uma camada oculta com função de ativação tansig e na camada de saída, logsig. O número de neurônios da camada oculta é variado de 2 a 10. Um método supervisionado será aplicado.

O método CUSUM será avaliado alterando-se os parâmetros de desvio padrão a partir da média e o deslocamento médio mínimo detectável.

Para o treinamento e validação destes classificadores, amostras para os dois tipos de regiões, alvo e não alvo, são obtidas de 97 vazamentos distintos, ou 97 corridas. A estratégia de particionamento *holdout* é adotada, sendo utilizado 70% dos dados para o treinamento e 30% para testes. A região de alvo foi determinada como uma janela de tamanho igual a 100 quadros, obtida a partir do momento em que ocorre a escória. Mais especificamente, o padrão de alvo é obtido utilizando-se uma janela com 15 quadros a partir do primeiro momento da ocorrência da escória e 85 quadros antes da mesma. Como os vídeos estão com cadência determinada de 10fps (frames por segundo), as janelas contêm 10 segundos de informação. Estes valores foram escolhidos após testes variando-se o tamanho das janelas entre 50 e 120. Para a região não alvo, as amostras são obtidas a partir de posições obtidas aleatoriamente excluindo os momentos posteriores a região alvo. É importante destacar ainda, que no treinamento o número de dados da região não alvo utilizado é três vezes maior que o da região alvo. Este desbalanceamento proposital é devido, principalmente, ao fato do maior número de ocorrências da região não alvo. As janelas que finalizam entre 3 e 0 (zero) segundos antes do início da passagem de escória não são utilizadas no treinamento deixando que o método generalize o resultado e determine a classificação como alvo ou não alvo.

Figura 28 - Separação dos dados de cada quadro em janelas alvo (início de escória) e não alvo.



Fonte: Autoria própria.

Após o treinamento dos classificadores, aplica-se o modelo obtido com as corridas de treinamento nas corridas teste. Varre-se o gráfico, como mostrado na Figura 28, deslocando as janelas a cada 5 quadros (ou 0,5 segundos), utilizando-se também janelas com tamanho de 100 quadros.

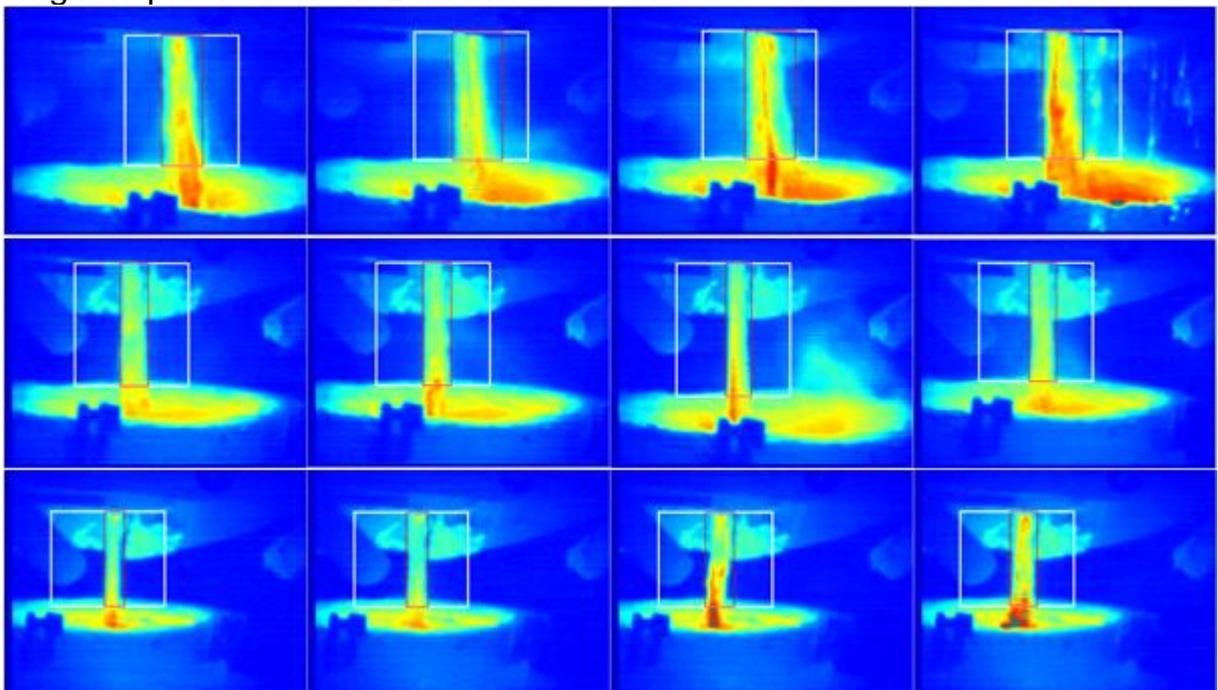
O método deve então realizar a classificação do instante de vazamento, através da janela obtida, a cada 0,5 segundos indicando se estaria passando escória ou não.

5 RESULTADOS E DISCUSSÃO

5.1 LOCALIZAÇÃO E SEGMENTAÇÃO DO JATO NA IMAGEM

O método de identificação da região do jato utilizando técnicas de processamento digital de imagens apresentou resultado consistente ao longo dos quadros do vídeo sendo observado para as 97 corridas avaliadas. O método de localização e segmentação é aplicado em cada quadro da sequência de um vídeo obtendo-se uma detecção da região do jato como representado na Figura 29. Como pode ser observado nesta figura, ao longo do tempo, tanto a panela quanto o convertedor estão em movimento levando a diferentes tamanhos e posições do jato na imagem. Com base nisso, pode ser observado que o método consegue identificar com precisão a região de interesse (ROI, do inglês *Region of Interest*) que delimite o jato de aço em cada quadro do vídeo.

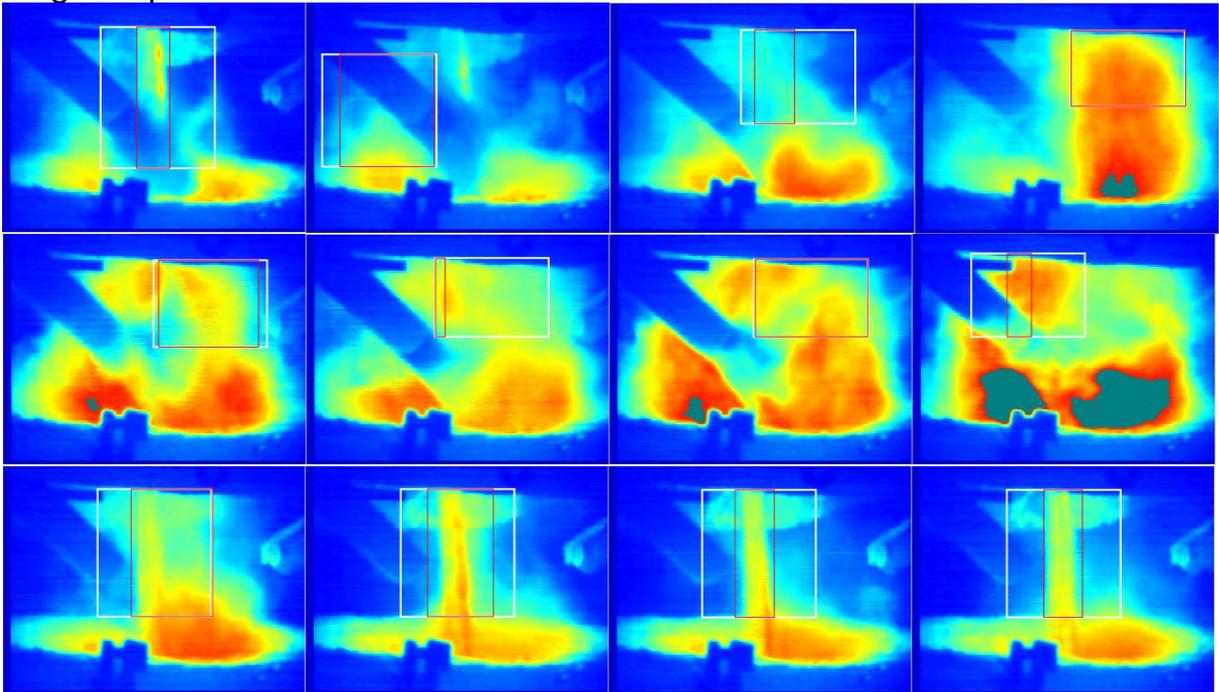
Figura 29 - Detecção da posição do jato em diferentes quadros de um vídeo ao longo do processo de vazamento



Fonte: Autoria própria.

Nos momentos em que ocorre a adição de fundentes na panela levando a reações que provocam distúrbios na imagem, como previamente mencionado, pode ocorrer a perda momentânea da detecção da região como pode ser visto na Figura 30. Isso pode interferir no objetivo de se identificar a passagem de escória que ocorrerá no final do processo com amostras instáveis apresentadas ao processo de treinamento do classificador. Por esse motivo, esta região deverá ser expurgada da amostragem. Nessa figura pode ser observado também que à medida que o processo de adição de fundentes vai se encerrando, com a estabilização do processo a identificação correta da ROI é retomada.

Figura 30 - Detecção da posição do jato em diferentes quadros de um vídeo ao longo do processo de vazamento



Fonte: Autoria própria.

5.2 RECONHECIMENTO DO PADRÃO DE PASSAGEM DE ESCÓRIA

Uma vez que a escória somente ocorrerá bem próximo do final do processo, optou-se por testar os classificadores a partir de 1 minuto antes da ocorrência do início da

passagem de escória. Este tipo de consideração é comum em problemas de detecção de mudanças abruptas descritas em Basseville e Nikiforov (1996).

O método deve ser avaliado para as diferentes características extraídas na etapa anterior. A primeira avaliação a ser realizada apresenta as matrizes de confusão para cada característica e método como pode ser observado nas Tabelas 2 a 11. O número total de alvos são 29, ou seja, uma janela (amostra) extraída de cada corrida teste. Já o número total de não alvos são 87, ou seja, 3 janelas extraídas de cada corrida-teste. Para cada característica, os conjuntos de treinamento e testes foram gerados aleatoriamente 5 vezes de forma a permitir uma melhor avaliação da capacidade de generalização. Uma média dos valores obtidos é apresentada.

Tabela 2- Matriz de confusão para classificação da característica *área*

		Área							
		SVM		kNN		RNA		CUSUM	
Verdadeiro	Preditos								
	não alvo	alvo							
não alvo	72	15	73	14	80	7	87	0	
alvo	8	21	12	17	16	13	29	0	

Fonte: Autoria própria.

Tabela 3 - Matriz de confusão para classificação da característica *extensão*

		Extensão							
		SVM		kNN		RNA		CUSUM	
Verdadeiro	Preditos								
	não alvo	alvo	não alvo	alvo	não alvo	alvo	não alvo	alvo	
não alvo	87	0	86	1	85	2	87	0	
alvo	2	27	2	27	2	27	29	0	

Fonte: Autoria própria.

Tabela 4 - Matriz de confusão para classificação da característica *média do eixo X*

		Média Eixo X							
		SVM		kNN		RNA		CUSUM	
Verdadeiro	Preditos								
	não alvo	alvo	não alvo	alvo	não alvo	alvo	não alvo	alvo	
não alvo	87	0	83	4	86	1	87	0	
alvo	3	26	1	28	1	28	29	0	

Fonte: Autoria própria.

Tabela 5 - Matriz de confusão para classificação da característica *média do eixo Y*

		Média Eixo Y							
		SVM		kNN		RNA		CUSUM	
Verdadeiro	Preditos								
	não alvo	alvo	não alvo	alvo	não alvo	alvo	não alvo	alvo	
não alvo	79	8	79	8	78	9	87	0	
alvo	2	27	5	24	3	26	29	0	

Fonte: Autoria própria.

Tabela 6 - Matriz de confusão para classificação da característica *mediana*

		Mediana							
		SVM		kNN		RNA		CUSUM	
Verdadeiro	Preditos								
	não alvo	alvo	não alvo	alvo	não alvo	alvo	não alvo	alvo	
não alvo	77	10	79	8	79	8	87	0	
alvo	6	23	5	24	6	23	29	0	

Fonte: Autoria própria.

Tabela 7 - Matriz de confusão para classificação da característica *centro de massa*

		Centro de Massa							
		SVM		kNN		RNA		CUSUM	
Verdadeiro	Preditos								
	não alvo	alvo	não alvo	alvo	não alvo	alvo	não alvo	alvo	
não alvo	83	4	86	1	84	3	87	0	
alvo	1	28	5	24	1	28	29	0	

Fonte: Autoria própria.

Tabela 8 - Matriz de confusão para classificação da característica *soma > lim 120*

		Soma > lim 120							
		SVM		kNN		RNA		CUSUM	
Verdadeiro	Preditos								
	não alvo	alvo	não alvo	alvo	não alvo	alvo	não alvo	alvo	
não alvo	72	15	86	1	80	7	87	0	
alvo	3	26	5	24	5	24	25	4	

Fonte: Autoria própria.

Tabela 9 - Matriz de confusão para classificação da característica *soma > lim 140*

		Soma > lim 140							
		SVM		kNN		RNA		CUSUM	
Verdadeiro	Preditos								
	não alvo	alvo	não alvo	alvo	não alvo	alvo	não alvo	alvo	
não alvo	79	8	85	2	83	4	87	0	
alvo	2	27	6	23	5	24	15	14	

Fonte: Autoria própria.

Tabela 10 - Matriz de confusão para classificação da característica *soma > lim 180*

		Soma > lim 180							
		SVM		kNN		RNA		CUSUM	
Verdadeiro	Preditos								
	não alvo	alvo	não alvo	alvo	não alvo	alvo	não alvo	alvo	
não alvo	85	2	85	2	85	2	87	0	
alvo	0	29	0	29	0	29	6	23	

Fonte: Autoria própria.

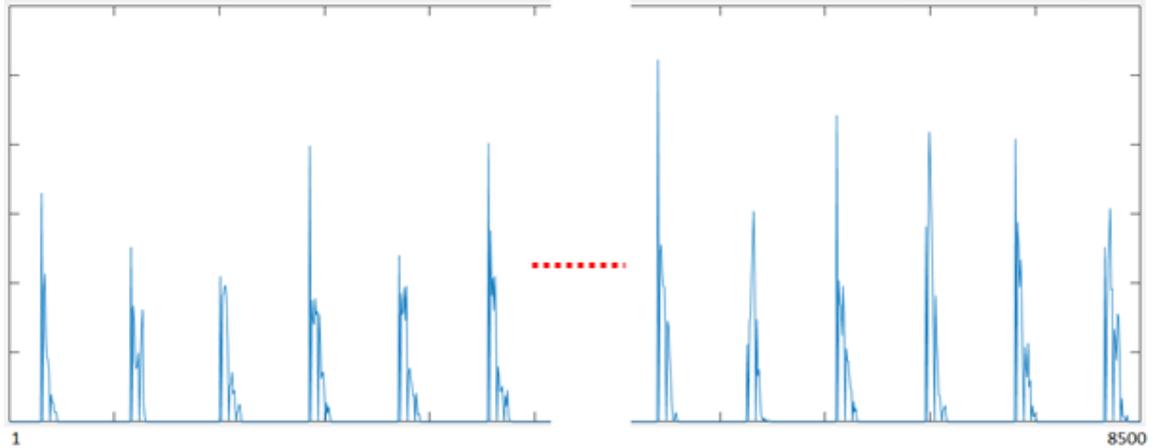
Tabela 11 - Matriz de confusão para classificação da característica *soma > lim 220*

		Soma > lim 220							
		SVM		kNN		RNA		CUSUM	
Verdadeiro	Preditos								
	não alvo	alvo	não alvo	alvo	não alvo	alvo	não alvo	alvo	
não alvo	86	1	87	0	87	0	87	0	
alvo	5	24	5	24	3	26	17	12	

Fonte: Autoria própria.

Além das características apresentadas nas Tabelas 2 a 11, realiza-se uma avaliação apresentando um vetor com o histograma completo como característica, ou seja, 255 valores para cada quadro. O método trabalha com amostras por janelas, dessa forma, ao se utilizar o mesmo tamanho de janela com agrupamento de 100 quadros utilizado anteriormente, obtém-se um vetor de característica de 25500 posições. Realiza-se uma sub-amostragem a cada 3 posições, reduzindo o tamanho do vetor para 8500 como pode ser visto na Figura 31.

Figura 31 - Exemplo de vetor característica utilizando o histograma completo



Fonte: Autoria própria.

A sub-amostragem foi realizada como passo intermediário que permite obter, com os computadores disponíveis para este trabalho, uma segunda redução de dimensionalidade utilizando-se o método de análise de componentes principais (PCA, do inglês *Principal Component Analysis*). Para se obter uma representatividade de 89,7% da amostra original (ou sem redução de dimensionalidade), 20 componentes principais são utilizadas.

Além disso, varia-se o tamanho da janela aplicada em diferentes valores de forma a identificar os melhores resultados. Apresentam-se os resultados para o tamanho de janela 100 na Tabela 12 e tamanho de janela 60 na Tabela 13.

Tabela 12 - Matriz de confusão para classificação da característica *histograma 100*

		Histograma 100							
		SVM		kNN		RNA		CUSUM	
Verdadeiro	Preditos								
	não alvo	alvo	não alvo	alvo	não alvo	alvo	não alvo	alvo	
não alvo	69	18	67	20	72	15	87	0	
alvo	11	18	13	16	14	15	29	0	

Fonte: Autoria própria.

Tabela 13 - Matriz de confusão para classificação da característica *histograma 60*

		Histograma 60							
		SVM		kNN		RNA		CUSUM	
Verdadeiro	Preditos								
	não alvo	alvo	não alvo	alvo	não alvo	alvo	não alvo	alvo	
não alvo	86	1	86	1	86	1	87	0	
alvo	3	26	5	24	3	26	29	0	

Fonte: Autoria própria.

É importante informar que se convencionou alvos como positivos (P) e não alvos como negativos (N). Na Tabela 14 identifica-se a convenção dos campos Verdadeiro Negativo (VN), Verdadeiro Positivo (VP), Falso Negativo (FN) e Falsos Positivo (FP) nas matrizes de confusão apresentadas nas Tabelas 2 a 13. Esta informação é apresentada como base para a definição dos índices de avaliação e curvas de característica de operação do receptor (ROC, do inglês, *Receiver Operating Characteristic*) a seguir.

Nas Tabelas 15 a 21 são apresentados sumários de alguns índices de avaliação dos resultados obtidos a partir das matrizes de confusão para cada característica versus método de classificação.

Tabela 14 - Indicação convencionada para as matrizes de confusão

Verdadeiro	Predito	
	não alvo	alvo
não alvo	<i>VN</i>	<i>FP</i>
alvo	<i>FN</i>	<i>VP</i>

Fonte: Autoria própria.

Os índices utilizados bem como a utilização das curvas ROC estão descritos em Zhu, Zeng e Wang (2010) e Prati, Batista e Monard (2008). Estes são:

- **Sensibilidade:** a proporção de verdadeiros positivos: a capacidade do sistema em prever corretamente a condição para casos que realmente a têm (Equação 7).

$$\text{Sensibilidade} = \frac{VP}{(VP + FN)}, \quad (7)$$

Tabela 15 - Sumário de sensibilidades para cada característica x método de classificação

Característica	Sensibilidades			
	SVM	kNN	RNA	CUSUM
Área	72,4138%	58,6207%	44,8276%	0,0000%
Extensão	93,1034%	93,1034%	93,1034%	0,0000%
Média Eixo X	89,6552%	96,5517%	96,5517%	0,0000%
Média Eixo Y	93,1034%	82,7586%	89,6552%	0,0000%
Mediana	79,3103%	82,7586%	79,3103%	0,0000%
Centro de Massa	96,5517%	82,7586%	96,5517%	0,0000%
Soma > lim 120	89,6552%	82,7586%	82,7586%	13,7931%
Soma > lim 140	93,1034%	79,3103%	82,7586%	48,2759%
Soma > lim 180	100,0000%	100,0000%	100,0000%	79,3103%
Soma > lim 220	82,7586%	82,7586%	89,6552%	41,3793%
Histograma 100	62,0690%	55,1724%	51,7241%	0,0000%
Histograma 60	89,6552%	82,7586%	89,6552%	0,0000%

Fonte: Autoria própria.

- **Especificidade:** a proporção de verdadeiros negativos: a capacidade do sistema em prever corretamente a ausência da condição para casos que realmente não a têm (Equação 8).

$$Especificidade = \frac{VN}{(VN + FP)}, \quad (8)$$

Tabela 16 - Sumário das especificidades para cada característica x método de classificação

Característica	Especificidades			
	SVM	kNN	RNA	CUSUM
Área	82,7586%	83,9080%	91,9540%	100,0000%
Extensão	100,0000%	98,8506%	97,7011%	100,0000%
Média Eixo X	100,0000%	95,4023%	98,8506%	100,0000%
Média Eixo Y	90,8046%	90,8046%	89,6552%	100,0000%
Mediana	88,5057%	90,8046%	90,8046%	100,0000%
Centro de Massa	95,4023%	98,8506%	96,5517%	100,0000%
Soma > lim 120	82,7586%	98,8506%	91,9540%	100,0000%
Soma > lim 140	90,8046%	97,7011%	95,4023%	100,0000%
Soma > lim 180	97,7011%	97,7011%	97,7011%	100,0000%
Soma > lim 220	98,8506%	100,0000%	100,0000%	100,0000%
Histograma 100	79,3103%	77,0115%	82,7586%	100,0000%
Histograma 60	98,8506%	98,8506%	98,8506%	100,0000%

Fonte: Autoria própria.

- **Eficiência:** a média aritmética da Sensibilidade e Especificidade. Na prática, a sensibilidade e a especificidade variam em direções opostas. Isto é, geralmente, quando um método é muito sensível a positivos, tende a gerar muitos falso-positivos, e vice-versa. Assim, um método de decisão perfeito (100 % de sensibilidade e 100% especificidade) raramente é alcançado, e um balanço entre ambos, deve ser atingido (Equação 9).

$$Eficiência = \frac{(Sensibilidade + Especificidade)}{2}, \quad (9)$$

Tabela 17 - Sumário das eficiências para cada característica x método de classificação

Eficiências				
Característica	SVM	kNN	RNA	CUSUM
Área	77,5862%	71,2644%	68,3908%	50,0000%
Extensão	96,5517%	95,9770%	95,4023%	50,0000%
Média Eixo X	94,8276%	95,9770%	97,7011%	50,0000%
Média Eixo Y	91,9540%	86,7816%	89,6552%	50,0000%
Mediana	83,9080%	86,7816%	85,0575%	50,0000%
Centro de Massa	95,9770%	90,8046%	96,5517%	50,0000%
Soma > lim 120	86,2069%	90,8046%	87,3563%	56,8966%
Soma > lim 140	91,9540%	88,5057%	89,0805%	74,1379%
Soma > lim 180	98,8506%	98,8506%	98,8506%	89,6552%
Soma > lim 220	90,8046%	91,3793%	94,8276%	70,6897%
Histograma 100	70,6897%	66,0920%	67,2414%	50,0000%
Histograma 60	94,2529%	90,8046%	94,2529%	50,0000%

Fonte: Autoria própria.

- **CCM**: o Coeficiente de Correlação de Matthews é uma medida de qualidade de duas classificações binárias que pode ser usada mesmo se as classes possuem tamanhos bastante diferentes. Retorna um valor entre (-1) e (+1), em que um coeficiente de (+1) representa uma predição perfeita, (0) representa uma predição aleatória media, e (-1) uma predição inversa. Esta estatística busca, assim como a eficiência, resumir a qualidade da tabela de contingência em um único valor numérico passível de ser comparado (Equação 10).

$$CCM = \frac{(VP * VN - FP * FN)}{\sqrt{(VP + FP) * (VP + FN) * (VN + FP) * (VN + FN)}} \quad (10)$$

Tabela 18 - Sumário dos Coeficientes de Correlação de Matthews (CCM) para cada característica x método de classificação

Coeficientes de Correlação de Matthews (CCM)				
Característica	SVM	kNN	RNA	CUSUM
Área	51,6398%	41,6151%	42,1637%	n/d*
Extensão	95,3998%	93,0484%	90,8046%	n/d*
Média Eixo X	93,0949%	89,0871%	95,4023%	n/d*
Média Eixo Y	79,1563%	71,2697%	74,8190%	n/d*
Mediana	65,0872%	71,2697%	68,6087%	n/d*
Centro de Massa	89,0871%	85,9423%	91,1033%	n/d*
Soma > lim 120	65,5930%	85,9423%	73,1076%	32,7327%
Soma > lim 140	79,1563%	81,1005%	79,0912%	64,1689%
Soma > lim 180	95,6022%	95,6022%	95,6022%	86,1357%
Soma > lim 220	85,9423%	88,4652%	93,0949%	58,8348%
Histograma 100	38,7298%	30,1232%	34,0997%	n/d*
Histograma 60	90,6887%	85,9423%	90,6887%	n/d*

*n/d: não definido

Fonte: Autoria própria.

- **Exatidão:** A proporção de predições corretas, sem levar em consideração o que é positivo e o que é negativo. Esta medida é altamente suscetível a desbalanceamentos do conjunto de dados e pode facilmente induzir a uma conclusão errada sobre o desempenho do sistema (Equação 11).

$$Exatidão = \frac{(VP + VN)}{(P + N)}, \quad (11)$$

Tabela 19 - Sumário das exatidões para cada característica x método de classificação

Característica	Exatidões			
	SVM	kNN	RNA	CUSUM
Área	80,1724%	77,5862%	80,1724%	75,0000%
Extensão	98,2759%	97,4138%	96,5517%	75,0000%
Média Eixo X	97,4138%	95,6897%	98,2759%	75,0000%
Média Eixo Y	91,3793%	88,7931%	89,6552%	75,0000%
Mediana	86,2069%	88,7931%	87,9310%	75,0000%
Centro de Massa	95,6897%	94,8276%	96,5517%	75,0000%
Soma > lim 120	84,4828%	94,8276%	89,6552%	78,4483%
Soma > lim 140	91,3793%	93,1034%	92,2414%	87,0690%
Soma > lim 180	98,2759%	98,2759%	98,2759%	94,8276%
Soma > lim 220	94,8276%	95,6897%	97,4138%	85,3448%
Histograma 100	75,0000%	71,5517%	75,0000%	75,0000%
Histograma 60	96,5517%	94,8276%	96,5517%	75,0000%

Fonte: Autoria própria.

- **Imprecisão:** A proporção de predições incorretas, sem levar em consideração o que é positivo e o que é negativo. Também como a exatidão, seu complemento, é altamente suscetível a desbalanceamentos dos dados (Equação 12).

$$Imprecisão = \frac{(FP + FN)}{(P + N)}, \quad (12)$$

Tabela 20 - Sumário das imprecisões para cada característica x método de classificação

Imprecisões				
Característica	SVM	kNN	RNA	CUSUM
Área	19,8276%	22,4138%	19,8276%	25,0000%
Extensão	1,7241%	2,5862%	3,4483%	25,0000%
Média Eixo X	2,5862%	4,3103%	1,7241%	25,0000%
Média Eixo Y	8,6207%	11,2069%	10,3448%	25,0000%
Mediana	13,7931%	11,2069%	12,0690%	25,0000%
Centro de Massa	4,3103%	5,1724%	3,4483%	25,0000%
Soma > lim 120	15,5172%	5,1724%	10,3448%	21,5517%
Soma > lim 140	8,6207%	6,8966%	7,7586%	12,9310%
Soma > lim 180	1,7241%	1,7241%	1,7241%	5,1724%
Soma > lim 220	5,1724%	4,3103%	2,5862%	14,6552%
Histograma 100	25,0000%	28,4483%	25,0000%	25,0000%
Histograma 60	3,4483%	5,1724%	3,4483%	25,0000%

Fonte: Autoria própria.

- **Curvas ROC e AUC:** O gráfico ROC é baseado na probabilidade de detecção, ou taxa de verdadeiros positivos (tpr), ou sensibilidade, calculado pela Equação 13, e na probabilidade de falsos alarmes, ou taxa de falsos positivos (fpr) calculado pela Equação 14. Para se construir o gráfico ROC plota-se fpr no eixo dos ordenadas e tpr no eixo das abscissas. A linha diagonal ascendente do ponto (0,0) ao ponto (1,1) representa o comportamento estocástico. Quanto mais a curva tende a se aproximar do ponto (0,1), melhor o desempenho do classificador. A área abaixo da curva (AUC, do inglês *Area Under Curve*) tem sido muito utilizada na literatura como índice de desempenho do classificador sendo 1 o valor máximo ou desempenho perfeito. As curvas para todos os classificadores e características estão apresentadas na Figura 32

$$tpr = \frac{VP}{(VP + FN)}, \quad (13)$$

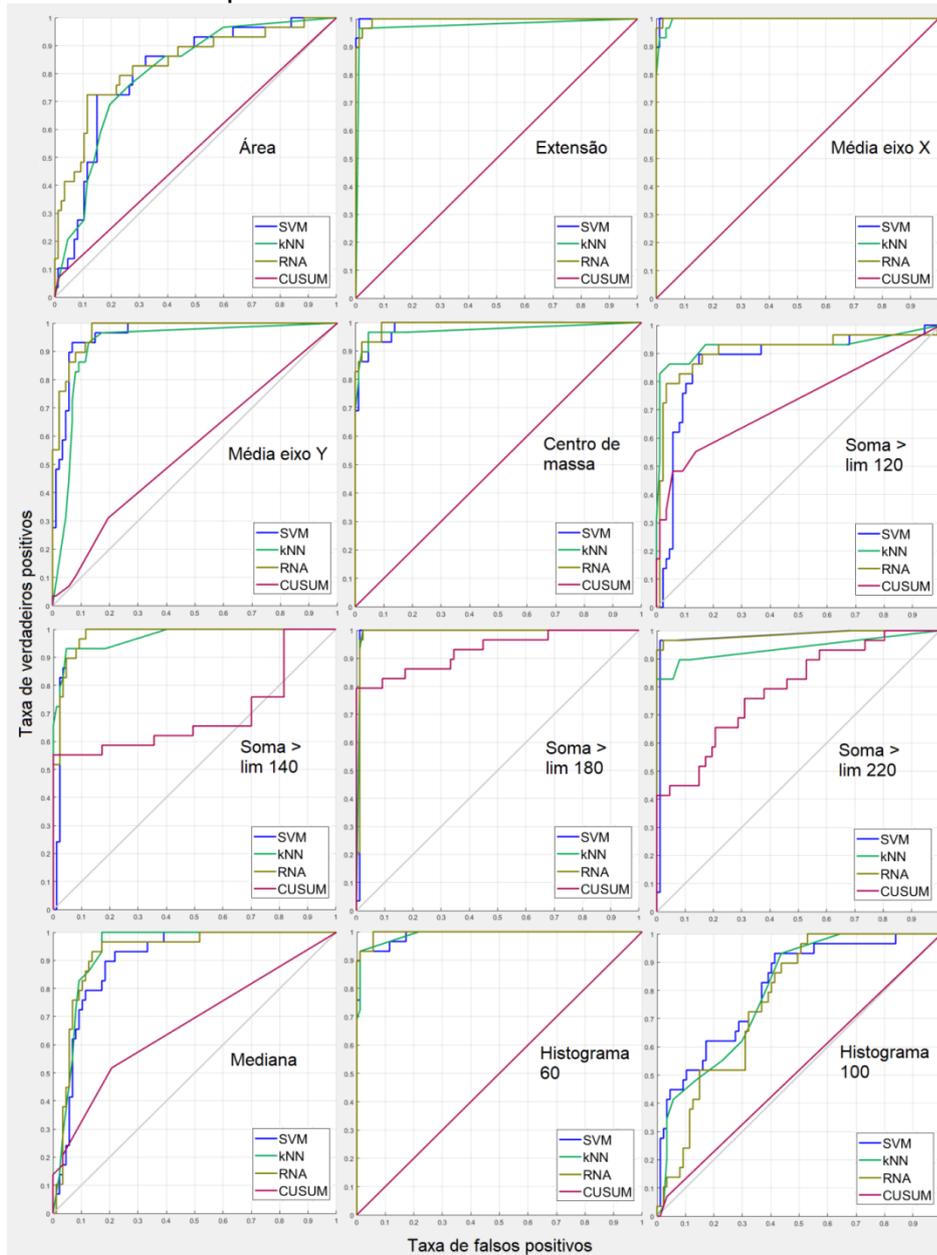
$$fpr = \frac{FP}{(FP + VN)}, \quad (14)$$

Tabela 21 - Sumário de AUC para cada característica *versus* método de classificação

Área abaixo da curva (AUC)				
Característica	SVM	kNN	RNA	CUSUM
Área	0,8070	0,8010	0,8331	0,5287
Extensão	0,9992	0,9768	0,9968	0,5000
Média Eixo X	0,9988	0,9962	0,9992	0,5000
Média Eixo Y	0,9612	0,9233	0,9734	0,5557
Mediana	0,9013	0,9324	0,9235	0,6694
Centro de Massa	0,9857	0,9744	0,9917	0,5000
Soma > lim 120	0,8720	0,9269	0,9104	0,7279
Soma > lim 140	0,9711	0,9727	0,9790	0,6952
Soma > lim 180	0,9889	0,9929	0,9905	0,9287
Soma > lim 220	0,9768	0,9376	0,9857	0,7915
Histograma 100	0,8090	0,7969	0,7654	0,5168
Histograma 60	0,9881	0,9895	0,9956	0,5000

Fonte: Autoria própria.

Figura 32 - Curvas ROC para todas as características e classificadores



Fonte: Autoria própria.

Buscam-se os modelos de melhor desempenho, ou maiores valores, através da eficiência, exatidão, CCM e AUC, além da imprecisão com o menor valor. A avaliação de sensibilidade e especificidade torna-se importante neste caso, pois a identificação dos alvos corretamente é mais relevante que a detecção de não alvos, ou seja, deseja-se que o sistema tenha a maior sensibilidade possível pois deixar de detectar a passagem de escória podem causar maiores prejuízos ao processo. Pode ser observado nas Tabelas 15 a 21, que a característica “Soma > lim 180”,

representando a soma das ocorrências acima do limite 180 do histograma como citado na seção 4.2, apresenta os melhores índices utilizando os métodos kNN, SVM e RNA. Na Tabela 10, pode-se verificar que estes três métodos classificam corretamente todos os alvos e classificam incorretamente apenas duas amostras não alvo como alvo (falso positivo), com isto a sensibilidade obtida para cada um é de 100%. Dentro da característica “soma > lim 180”, o kNN apresenta um AUC ligeiramente melhor que os demais de 0,9929. As características extensão e “média do eixo X” apresentam resultados muito próximos utilizando o método SVM. O custo computacional utilizando-se o histograma é mais elevado se comparada as outras características sendo descartado como opção por não apresentar desempenho superior. O método CUSUM não consegue realizar classificações adequadas em características com maior variabilidade, os valores de 0% para sensibilidade, 25% para imprecisão, 50% para eficiência, 75% para exatidão e 100% para especificidade não devem ser considerados para as características que obtém este resultado, pois não há nenhuma classificação alvo obtida. Além disso, uma análise das curvas ROC para o CUSUM, apresentadas na Figura 32, indicam comportamento estocástico, ou próximo a ele, na maioria das características.

Um modelo é gerado a partir da característica “soma > lim 180” para cada método de classificação utilizando-se 70% das corridas (68 no total). Neste caso, os modelos otimizados obtidos apresentam os seguintes atributos:

- SVM: Kernel linear com $C=0,30504$.
- kNN: Distância de Manhattan com $k=4$.
- RNA: *feedforward* com uma camada oculta de 3 neurônios.
- CUSUM: com 5 vezes o valor do desvio padrão a partir da média, e com um deslocamento médio mínimo detectável igual a 10 vezes o desvio padrão.

Este modelo é aplicado então, nas corridas separadas para teste aplicando-se o método descrito na seção 4.2. É importante destacar que o número de não alvos apresentados deve-se ao fato de extraírem-se 74 janelas em cada uma das 29 corridas para teste (30% do total), totalizando 2146 janelas. Já o número de alvos é

29, ou seja, um para cada corrida. Vale ressaltar também que classificações positivas abaixo de 3 segundos antes da passagem de escória são consideradas falsos positivos (classe não alvo predita como alvo). A matriz de confusão é apresentada na Tabela 22.

Tabela 22 - Matriz de confusão para classificação da característica *soma > lim 180* em todas janelas das corridas teste

Verdadeiro	SVM		kNN		RNA		CUSUM	
	Preditos							
	não alvo	alvo						
não alvo	2145	1	2145	1	2145	1	2136	10
alvo	1	28	0	29	2	26	8	21

Fonte: Autoria própria.

Tabela 23 - Índices gerais para a simulação de corridas-teste

Índice	SVM	kNN	RNA	CUSUM
Sensibilidade	96,5517%	100,0000%	92,8571%	72,4138%
Especificidade	99,9534%	99,9534%	99,9534%	99,5340%
Exatidão	99,9080%	99,9540%	99,8620%	99,1724%
Imprecisão	0,0920%	0,0460%	0,1380%	0,8276%
Eficiência	98,2526%	99,9767%	96,4053%	85,9739%
CCM	96,5051%	98,2963%	94,4916%	69,6207%

Fonte: Autoria própria.

A partir dos resultados, constata-se na Tabela 23, uma sensibilidade de 100% para o modelo kNN comparada aos 96,5517% do SVM e 92,8571% da RNA, ou seja, a escória foi identificada em todos os casos sem ocorrência de falsos negativos (classe alvo predita como não alvo). Observa-se um falso positivo utilizando-se tanto o kNN, SVM ou RNA, ou seja, é possível que o método gere uma informação de escória mesmo não sendo em alguns poucos casos. A eficiência do método chega a 99,9767% com o kNN, 98,2525% com o SVM e 96,4053% com a RNA.

Já com relação ao momento de identificação da passagem de escória, avalia-se também o resultado com relação ao instante em que a escória é detectada apresentada na Tabela 24. Este último índice é importante, representando a capacidade de predição do evento alvo antes que ocorra estando relacionado com o tempo de reação na detecção da passagem de escória. Quanto antes for detectada, melhor será para o processo.

Tabela 24 - Momento de detecção da passagem de escória

	Segundos antes da passagem de escória		
	Entre 3 e 2 segundos	Entre 2 e 1 segundos	Entre 1 e 0 segundos
SVM	0	0	28
kNN	0	0	29
RNA	0	0	26
CUSUM	0	0	21

Fonte: Autoria própria.

Dentro das 29 corridas-teste, nota-se ainda na Tabela 24 que os modelos não conseguem prever o evento com antecedência maior que 1 segundo. Entretanto, o modelo kNN é preciso na detecção do momento de início da passagem de escória acertando em todos os casos.

6 CONCLUSÃO E TRABALHOS FUTUROS

A evolução das aplicações no campo de Processamento Digital de Imagens e Visão Computacional ainda se mostram tímidas em ambientes industriais. As possibilidades são amplas e merecem ser mais bem exploradas neste ramo. As técnicas dessas duas áreas e a evolução dos equipamentos como câmeras e computadores podem permitir a inspeção de processos produtivos em tempo real, com menos riscos e falhas por parte de operadores humanos, assim como trazer ganhos de produtividade e qualidade do produto.

A aplicação de identificação da passagem de escória, ou ainda mais, predizer o evento, ainda é um desafio. Muitos trabalhos, como alguns citados aqui, buscam realizar um modelamento físico do processo, mas existem variáveis de difícil mensuração e controle dificultando uma transposição para o processo de forma consistente. A introdução de inteligência artificial ao processo pode trazer ganhos interessantes. Este trabalho, por exemplo, apresenta resultados que trazem benefícios ao processo produtivo industrial ao auxiliar o operador com uma identificação do início do fluxo de passagem de escória. Dessa forma, diminui-se o tempo de reação para o fim do basculamento do convertedor, uniformiza-se a variabilidade do conhecimento tácito do operador e, por consequência reduz-se a quantidade de escória passada para a panela de aço. Com isso, melhora-se a limpidez do produto, diminui-se o desgaste dos refratários, aumenta o número de reutilizações da panela e melhora a eficiência da desoxidação e dessulfuração do aço. Além disso, diminui-se a possibilidade de problemas nos processos seguintes da fabricação do aço. A eliminação da variabilidade manual com a correta identificação do momento de encerrar o vazamento representa uma redução de custo significativa para indústrias siderúrgicas.

O processo de detecção da região e segmentação do jato de aço no vazamento apresenta um resultado robusto, mesmo com muitas variabilidades que ocorrem no processo e conseqüentemente na imagem gerada. Existe a perda da detecção da região durante a adição de fundentes na panela de aço devido à quantidade de emissões geradas pelas reações, mas isto não afeta o objetivo do trabalho por

ocorrer em um momento que não interfere na região de interesse no fim do processo de vazamento. Além disso, tão logo se encerre a adição destes fundentes, o método é eficaz em recuperar a detecção da região do jato.

Os resultados alcançados pelo método proposto de identificação da melhor característica e classificação, com a utilização do janelamento, demonstram um elevado índice de acerto para identificação automática da passagem de escória no vazamento de um convertedor de aciaria, chegando a valores de 99,98% (eficiência). O método não foi capaz de antever a ocorrência do evento, sendo este um ponto que pode ser melhor desenvolvido em futuros trabalhos. O uso de outras técnicas como *deep learning* e outras arquiteturas de RNA, além da avaliação de outros tipos de atributos também merecem ser trabalhadas. Adicionalmente, o método abre possibilidades de identificação de outras características do processo de vazamento de aço do convertedor: indicação dos momentos de adição de fundentes, agarramentos de escória no furo ou outros tipos anormalidades podem ser estudados visando uma possível identificação automática.

O momento em que a escória é identificada demonstrou que é possível uma aplicação prática dos métodos utilizados, podendo-se utilizar os modelos kNN, SVM e RNA com excelentes resultados. O kNN apresentou o melhor desempenho dentre eles por uma pequena margem. Testes com mais corridas devem ser realizados para melhor garantir a robustez e aplicabilidade dos métodos aqui propostos.

REFERÊNCIAS

ACHARYA, T.; RAY, A. K. **Image processing, principles and applications**. New Jersey: John Wiley and Sons, 2005.

ALBUQUERQUE, M. P. et al. **Aplicação da técnica de momentos invariantes no reconhecimento de padrões em imagens digitais**. 2011. Disponível em: <<http://www.cbpf.br/~chacon/mhu/>>. Acesso em: 25 set. 2017.

ALIBABA. **TATA steel plant using block slag stopping dart for converter**. 2017. Disponível em: <http://masyt.en.alibaba.com/product/1708067491-200214095/TATA_steel_plant_using_block_slag_stopping_dart_for_converter.html>. Acesso em: 01 out. 2017.

ANDRZEJEWSKI, P.; DIENER, A.; PLUSCHKELL, W. Model investigations of slag flow during last stages of ladle teeming. 1987. **Steel Research**, v. 58, n. 12, p. 547-52.

BASSEVILLE, M.; NIKIFOROV, I. V. **Detection of Abrupt Changes: theory and application**. [s.n.]: Prentice Hall, 1996. Cap. 2, 35-42.

BRAGA, A.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000.

BURGES, C. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge Discovery**, 2(2):121-167, 1998.

CARDOSO, D.; GOMES, V. V. **Estudo de sistemas de visão artificial e a implementação de um software de visão para o uso no futebol de robôs**. 2005. Disponível em: <<http://www.ebah.com.br/content/ABAAAAWCAAJ/estudo-sistemas-visao-artificial>>. Acesso em: 28 out. 2017.

CHENG, H. D. et al. Color image segmentation: advances and prospects. **Pattern Recognition**. v. 34, 2259-2281, 2001.

CHRISTO, Eliane da S. **Previsão de Potência Reativa**. Tese (Doutorado em Engenharia Elétrica) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. 2. ed. New York: Wiley-Interscience, 2001.

ERPEN, Luís Renato Cruz. **Reconhecimento de padrões em imagens por descritores de forma**. UFRGS. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal do Rio Grande do Sul, Porto Alegre 2004.

EVERITT, B. S. et al. **Cluster Analysis**. 5th ed. [s.l.: s.n.], 2011.

FACCIO, K.; WERNER, L. Comparando gráfico CUSUM e Redes Neurais Artificiais no contexto do Controle Estatístico de Qualidade. 2010. **Revista INGEPRO**. v. 02, n. 11, nov. 2010.

FONSECA, M. S. **Segmentação de imagem - Segmentação limiar em tons de cinza**. Disponível em: <<http://www2.ic.uff.br/~aconci/limiarizacao.htm>>. Acesso em: 26 set. 2017.

FRUEHAN, R. J. Making, Shaping and treating of steel: steelmaking and refining volume. In: _____. **AISE Steel Foundation**. [s.l.: s.n.], 1998. cap. 8.

FU, K. S.; MUI, J. K. A survey on image segmentation. **Pattern Recognition**, v. 13. p. 3-16, 1981.

FUKUNAGA, K.; NARENDRA, P. M. A branch and bound algorithm for computing k-nearest neighbors. **IEEE Transactions on Computers**, v. 100, n. 7, p. 750-753, 1975.

GONZALES, R. C.; WOODS, R. E. **Processamento digital de imagens**. São Paulo: Edgard Blücher, 2000.

GRAHAM, K. J. et al. **Slag carryover control at ArcelorMittal Dofasco**. 2008. AISTech, PR-353-061.

HAMMERSCHMID, P. et al. **K. Vortex formation during drainage of metallurgical vessels**. **Ironmaking and Steelmaking**. v. 11, n. 6, p. 332-39, 1984.

HAYKIN, S. **Neural Networks a Comprehensive Foundation**. [S.l.]: Prentice Hall, 1999. p. 24-28.

JAIN, A. K. **Fundamentals of digital image processing**. New Jersey: Prentice-Hall, 1989.

JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical pattern recognition: a review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n.1, p.4-37, 2000.

JESUS, R. E.; ALMONFREY, D. Segmentação e classificação de caracteres em placas de aço. 2014. CONGRESSO BRASILEIRO DE AUTOMÁTICA, 1254-1257.

JESUS, R. E. et al. **Segmentação e identificação automática de placas de aço**. 2016. ERI-GO, p. 249-259.

JOACHIMS, T. **Learning to classify texts using support vector machines: methods, theory and algorithms**. [S.l.]: . Kluwer Academic Publishers, 2002.

KIM, K. I. et al. Support vector machines for texture classification. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 24(11):1542-1550, 2002.

KORIA, S.C.; KANTH, U. Model studies of slag carry-over during drainage of metallurgical vessels. **Steel Research**, v. 65, n. 1, p. 8-14, 1994.

LI, J. et al. **Application of thermographic slag detection system in baosteel**. 2007. AISTech, PR-351-107.

LIMA, I.; PINHEIRO, C. A. M.; SANTOS, F. A. O. **Inteligência artificial**. Rio de Janeiro: Elsevier, 2014.

LORENA, A. C.; CARVALHO A. C. Uma introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada**. Porto Alegre, UFRGS, v. 14, 2007.

MARTINS, E. R. S. et al. Caracterização de lesões intersticiais de pulmão em radiograma de tórax utilizando análise local de textura. 2005. **Radiol Bras** [online]. v. 38, n. 6, p.421-426, 2005. Disponível em: <<http://dx.doi.org/10.1590/S0100-39842005000600008>>.

MCCULLOCH, W.; PITTS W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, 5, p. 115-133, 1943.

MONTGOMERY, D. C. **Introdução ao controle estatístico da qualidade**. 4. ed. Rio de Janeiro: LTC, 2004.

MOREIRA, D. B.; LANA, M. F. **A geração de escória de aciaria LD pelo método de convertedor com sopro de oxigênio**. 2007. Disponível em: <<http://tubarao.arcelormittal.com/aplicacoes/documentos/02sql07/custom/inc/imagem.asp?arquivold=%7BC337280C-F932-44E4-8A01-FE8A284795D4%7D&campo=arquivo>>. Acesso em: 15 set. 2017.

NIKHIL, R. P.; SANKAR, K. P. A review on image segmentation techniques. **Pattern Recognition**, 26 (9), 1993.

NIXON, M.; AGUADO, A. **Feature extraction & image processing**. 2nd ed. [S.l.]: Elsevier, 2008.

NOBLE, W. S. Support vector machine applications in computational biology. In: SCHÖLKOPF, B.; TSUDA, K.; VERT, J. (eds.). **Kernel Methods in computational biology**. [S.l.]: MIT Press, 2004. p. 71-92..

OLIVEIRA, A. C. S. et al. Aplicação de redes neurais na previsão da produção de álcool. **Revista Ciência Agrotécnica**. Lavras, UFLA, v. 34, n. 2, mar./abr. 2010.

PAGE, E. S. Continuous Inspection Schemes. **Biometrika**. v. 41, n. 1, p. 100-115, jun. 1954.

PIMENTA, H. M.; VALADARES, C. A. G.; BELLIGOLI, G. C. D. Estudo da passagem de escória na etapa de vazamento de aço panela/distribuidor. 1997. SEMINÁRIO DE ACIARIA DO IAS. 11., 1997, Buenos Aires. [**Anais...**]. Buenos Aires: [s.n.], 1997. p. 199-207.

PONTIL, M.; VERRI, A. Support vector machines for 3-D object recognition. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 20(6):637-646, 1998.

PRATI, R. C.; BATISTA, G. E. A. P. A.; MONARD, M. C. Curvas ROC para a avaliação de classificadores. **IEEE Latin America**, 6(2):215-222, 2008.

QUEIROZ, S. S. F.; PINTO, K. L. N. Extração de características e reconhecimento de padrões e objetos. **Vetor**. Rio Grande, v. 24, n. 2, p. 2-13, 2014.

RIZZO, E. M. S. **Introdução aos processos de refino primário dos aços nos convertedores a oxigênio**. 2006. Associação Brasileira de Metalurgia e Materiais. p. 55.

ROCHA, Cristina S. C. da. **Técnicas de reconhecimento de padrões para a classificação de sinais fisiológicos**. 2013. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Minas Gerais, Belo Horizonte, 2013..

ROERDINK, J. B. T. M.; MEIJSTER, A. The watershed transform: definitions, algorithms and parallelization strategies. **Fundam Inform**. 41:187-228, 2000.

RSI. **Image processing in IDL**. [s.l.:s.n.], 2005. p.10.

RUSS, J. C. **The image processing handbook**. Boca Raton: CRC Press, 1998. p. 430-434.

SALDANHA, M. F. S.; FREITAS, C. C. **Segmentação de imagens digitais: uma revisão**. 2010. Instituto Nacional de Pesquisas Espaciais (INPE). DOC 06.22.18.13.

SANKARANARAYANAN, R. **Modeling of slag entraining funnel formation ('vortex') during liquid metal transfer operations**. 1994. 441 p. Thesis (Doctor of Philosophy) - McGill University, Montreal, Quebec, Canada, 1994.

SATO, C. T.; RAMIRES, M.; TAVARES, R. P. Avaliação do comportamento escória / aço durante o esgotamento da panela por meio de modelagem física. **Tecnol. Metal. Mater**. São Paulo, v. 5, n. 4, p. 210-214, abr.-jun. 2009.

SEVERINO, O.; GONZAGA, A. A new approach for color image segmentation based on color mixture. **Machine Vision and Applications**. v. 24, p. 607-618, 2013.

SHAKHNAROVICH, G.; DARRELL, T.; INDYK, P. **Nearest-neighbor methods in learning and vision: Theory and practice**. [S.l.]: MIT Press, 2005.

SHAPIRO, L. G.; STOCKMAN, G. C. **Computer Vision**. New Jersey: Prentice-Hall, 2001.

STANGE, R. L.; J. NETO, J. **Reconhecimento de padrões em classificadores - comparação de técnicas e aplicações**. 2010. Memórias do WTA.

STARR, C. **Biology**: concepts and applications. 2005. [S.l.]: Thomson Brooks/Cole.

STEFFEN, R. Fluid flow phenomena of metal and slag during drainage of metallurgical vessels. INTERNATIONAL CONFERENCE SECONDARY METALLURGY. 1987, Aachen, Germany. [**Anais...**]. Aachen, Germany, 1987, p. 97-118.

VAPNIK, V. N. **The nature of statistical learning theory**. 2nd. ed. New York: Springer Verlag, 1999.

VAPNIK, V. N.; CHERVONENKIS, A. Y. **On the uniform convergence of relative frequencies of events to their probabilities**. **Theory of Probability and its Applications**, 16(2):283-305, 1971.

WEBB, A. R. **Statistical pattern recognition**. 2. ed. Chichester: John Wiley & Sons, 2002. p. 93.

WIKIPEDIA. **Espectro visível**. 2017. Disponível em: <https://pt.wikipedia.org/wiki/Espectro_vis%C3%ADvel>. Acesso em: 25 set. 2017.

YONG, X.; FENG, D.; RONGCHUN, Z. **Optimal selection of image segmentation algorithms based on performance prediction**. Sydney: Australian Computer Society, 2004.

ZHU, W.; ZENG, N.; WANG, N. **Sensitivity, Specificity, Accuracy, Associated Confidence Interval and ROC Analysis with Practical SAS Implementations**. 2010. NESUG 2010, Health Care and Life Sciences. Life Sciences, p. 1-9.

ZUBEN, F. J. V.; MOSCATO, P. A. **Tópicos em Engenharia de Computação V**. 2002. DCA/FEEC/Unicamp. Disponível em: <ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia368_02/>. Acesso em: 12 out. 2017.