

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA - CURSO DE ENGENHARIA MECÂNICA
TRABALHO DE CONCLUSÃO DE CURSO

SISTEMA DE VISUALIZAÇÃO E INSPEÇÃO INTERNA DE CILINDROS

por

Válter Ferreira da Silva Júnior

Monografia apresentada ao Departamento de Engenharia Mecânica da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como parte dos requisitos para obtenção do diploma de Engenheiro Mecânico.

Porto Alegre, novembro de 2021.

CIP - Catalogação na Publicação

Silva Jr., Válter Ferreira. SISTEMA DE VISUALIZAÇÃO E INSPEÇÃO INTERNA DE CILINDROS / Valter Ferreira da Silva Júnior. -- 2021. 15 f.

Orientador: Herbert Martins Gomes.

Trabalho de conclusão de curso (Graduação) --
Universidade Federal do Rio Grande do Sul, Escola de Engenharia, Curso de Engenharia Mecânica, Porto Alegre, BR-RS, 2021.

1. Inspeção Visual. 2. Machine Learning. 3. Qualidade. 4. Classificação imagens. 5. Motores. I. Gomes, Herbert Martins, orient. II. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UFRGS com os dados fornecidos pelo(a) autor(a).

Válter Ferreira da Silva Júnior

SISTEMA DE VISUALIZAÇÃO E INSPEÇÃO INTERNA DE CILINDROS

ESTA MONOGRAFIA FOI JULGADA ADEQUADA COMO PARTE DOS
REQUISITOS PARA A OBTENÇÃO DO TÍTULO DE
ENGENHEIRO MECÂNICO
APROVADA EM SUA FORMA FINAL PELA BANCA EXAMINADORA DO
CURSO DE ENGENHARIA MECÂNICA

Prof. Cirilo Sepé Bresolin
Coordenador do Curso de Engenharia Mecânica

Área de Concentração: Mecânica dos Sólidos

Orientador: Prof. Dr. Herbert Martins Gomes

Comissão de Avaliação:

Prof. Dr. Herbert Martins Gomes

Prof. Dr. Ignácio Iturrioz

Prof. Dr. Jakson Manfredini Vassoler

Porto Alegre, novembro de 2021.

“É verdade que não sabemos muita coisa sobre este mundo. Mas é por isso que devemos seguir em frente e fazer o que pudermos. Uma coisa de cada vez.”

(Shiroe)

AGRADECIMENTOS

Primeiramente, agradeço aos meus pais, Valter e Sandra, que desde que me recordo me incentivaram ao estudo. Sempre muito dispostos a auxiliar e incentivar, com muita disposição e compreensão nestes longos anos de graduação. Também, agradeço ao meu irmão Cauã, que mesmo bastante jovem se mostrou presente e pronto para ouvir longos monólogos sobre temas específicos.

Agradeço à STIHL Ferramentas Motorizadas e aos meus amigos e colegas que nela encontrei, que me proveram com conhecimento, material, técnica e apoio para realizar este trabalho.

Agradeço aos meus amigos, sempre dispostos a auxiliar durante todo o percurso desde o início deste curso, compreensíveis na minha indisponibilidade em momentos de estudo e que diversas vezes trouxeram palavras de apoio em situações difíceis.

Agradeço ao meu orientador, Herbert, pela grande ajuda neste trabalho, apresentando ideias, soluções e, principalmente, norteando a execução deste artigo.

À Universidade Federal do Rio Grande do Sul, pelo seu corpo docente de excelência, que trazem à sala de aula o que há de mais novo e interessante dentro do conteúdo, providenciando assim, conhecimento atualizado de altíssima qualidade.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA - CURSO DE ENGENHARIA MECÂNICA
TRABALHO DE CONCLUSÃO DE CURSO – 2021

SISTEMA DE VISUALIZAÇÃO E INSPEÇÃO INTERNA DE CILINDROS

Válter Ferreira da Silva Júnior

valterfsj2@gmail.com

Resumo. *Em motores de combustão interna, um dos componentes mais importantes do sistema é o cilindro/bloco do motor, portanto faz-se necessária a garantia da qualidade da peça, principalmente quando fabricada em grande escala, empregando-se métodos ágeis e eficientes. Durante o processo de fabricação e testes desse componente, é feita a inspeção dos cilindros manualmente, método altamente subjetivo. Ao se desenvolver um dispositivo que padronize a visualização, capture imagens e avalie o cilindro automaticamente, pode-se ganhar, e muito, em velocidade e precisão, reduzindo a carga de trabalho sobre os técnicos que executam essas avaliações. O dispositivo será prototipado através da impressão 3d, utilizar-se-ão equipamentos para captura de imagem e iluminação capazes de serem controlados via protocolo USB e será desenvolvido software para análise e processamento das imagens em PYTHON. Ao final do trabalho obteve-se uma prova de conceito de um dispositivo capaz de posicionar e capturar imagens das janelas de admissão, escape e os canais de transferência, bem como fez-se uma inspeção automatizada, reportando o status OK/NOK quanto a possíveis defeitos nessas regiões. As matrizes de confusão e as métricas mostraram que a técnica se mostrou promissora para a aplicação.*

Palavras-chave: *Inspeção Visual, Machine Learning, Qualidade, Classificação imagens, Motores à combustão.*

Cylinder internal inspection and visualization system

Abstract. *In internal combustion engines, one of the most important components of the system is the cylinder/engine block, so it is necessary to ensure the quality of the part, especially when manufactured in large scale, using agile and efficient methods. During manufacturing and testing process of this component, the inspection of cylinders is done manually, a highly subjective method. By developing a device that standardizes the visualization, captures images and evaluates the cylinder automatically, it is possible to gain a lot in speed and precision, reducing the workload on the technicians that perform these evaluations. The device will be prototyped through 3d printing, the equipment used for image capture and lighting should be capable of being controlled via USB protocol and software will be developed for analysis and processing of images in PYTHON. At the end of the work, a proof of concept of a device capable of positioning and capturing images of the intake and exhaust windows and the transfer channels was obtained, as well as an automated inspection, reporting the OK/NOK status regarding possible defects in these regions. The confusion matrices and metrics showed that the technique proved promising for the application.*

Keywords: *Visual inspection, Machine Learning, Quality, Image classification, Combustion engines.*

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Motivação.....	1
1.2	Objetivos	1
2	REVISÃO BIBLIOGRÁFICA	1
3	FUNDAMENTAÇÃO TEÓRICA.....	2
3.1	Aprendizado de Máquina (Machine Learning).....	2
3.2	Dicionário de Palavras (<i>Bag-of-words</i>).....	3
3.3	Dicionário de palavras visuais (<i>Bag-of-keypoints</i>).....	4
3.4	Máquina de Suporte de Vetor (<i>Support Vector Machines, SVM</i>)	5
4	MATERIAIS E MÉTODOS	6
4.1	Câmera utilizada para aquisição de imagens	6
4.2	Bancada Experimental para aquisição de imagens	6
4.3	Modelo de cilindro e regiões analisadas	7
4.4	Pré-processamento de imagens	8
4.5	Algoritmo de extração de <i>features</i> , treinamento e classificação.....	8
4.6	Algoritmo de mistura de especialistas	9
4.7	Métricas utilizadas para avaliação da performance do classificador	10
4.8	Método de validação de resultados (<i>k-fold cross-validation</i>).....	11
5	RESULTADOS.....	11
5.1	Resultados do treinamento	11
6	CONCLUSÕES	14
	REFERÊNCIAS BIBLIOGRÁFICAS.....	16
	APÊNDICE.....	17
	ANEXO.....	18

LISTA DE FIGURAS

Figura 3.1 – Histograma de palavras de um <i>bag-of-words</i> de um texto de <i>e-mail</i> (a) não-SPAM (HAM) e (b) SPAM fictício. (Fonte: Autor)	3
Figura 3.2 – Histograma comparativo entre <i>bag-of-words</i> de um texto de e-mail SPAM e não-SPAM fictícios. (Fonte: Autor)	3
Figura 3.3 – Fluxograma de um algoritmo simplificado de classificador de e-mails. (Fonte:Autor)..	4
Figura 3.4 – Da esquerda para a direita: uma região <i>Harris</i> afim; a região normalizada; 8 mapas de gradiente que compõe o descritor SIFT. (Fonte: Csurka <i>et al.</i> (2004), p 6).....	4
Figura 3.5 – Dois conjuntos de dados separados por um hiperplano linear. Pode-se observar que a separação está otimizada visto que seus vetores de suporte se apresentam perpendiculares ao hiperplano. (Fonte: Autor)	5
Figura 4.1 – Propostas de equipamentos para a captura de imagem. (Fonte: Autor).	6
Figura 4.2 – Da esquerda para direita: Dispositivo de fixação, componente de posicionamento da câmera e cilindro posicionado no dispositivo de fixação. (Fonte: Autor).....	7
Figura 4.3 – Da esquerda para direita: imagem interna da janela de admissão, janela de escape e canais de transferência em diferentes configurações de posicionamento e iluminação. (Fonte: Autor).	7
Figura 4.4 – Da esquerda para direita: Canal de transferência sem porosidades, Classe - OK, Canal de transferência com porosidades, Classe – NÃO-OK. (Fonte: Autor).....	7
Figura 4.6 – Imagens pré-processadas de canais da Classe – NÃO-OK e Classe – OK. (Fonte: Autor).....	8
Figura 4.7 – Fluxograma apresentando os diversos filtros e pré-processamentos aplicados nas imagens. (Fonte: Autor).....	8
Figura 4.8 – Matriz de confusão esperada, contendo a Acurácia do classificador para o próprio banco de dados de treinamento (TP- <i>True Positive</i> , FP- <i>False Positive</i> , FN- <i>False Negative</i> , TN- <i>True Negative</i>). (Fonte: Autor).	9
Figura 4.9 – Fluxograma de um algoritmo simplificado de algoritmo de mistura de especialistas por votação simples e ponderada para classificação de imagens em duas classes. (Fonte: Autor).....	10
Figura 5.1 – Matrizes de confusão obtidas ao fim do treinamento com 5 diferentes tipos de filtros aplicados. (Fonte: Autor)	11
Figura 5.2 – Métricas de eficácia obtidas ao fim do treinamento com 5 diferentes tipos de filtros aplicados. (Fonte: Autor)	12

Figura 5.3 – Valores do <i>Matthews Correlation Coefficient</i> (MCC) obtidos para cada caso proposto. (Fonte: Autor)	12
Figura 5.4 – Matrizes de confusão resultantes da validação realizada nos sistemas de votação simples e ponderada, em ordem (Fonte: Autor).	13
Figura 5.5 – Métricas de eficácia obtidas pelos sistemas de classificação por votação simples e ponderada. (Fonte: Autor)	14
Figura 6.2 – Da esquerda para direita: Imagem original, Imagem com contornos analisados (em azul) e região de interesse destacada (em verde).	15
Figura A.1 – Exemplo de algoritmo proposto para trabalho futuro para utilização da técnica de <i>ensemble learning – stacking classifier</i> aliado a diversos classificadores distintos.	17

LISTA DE TABELAS

Tabela A.1 – Características técnicas do Boroscópio USB.	18
---	----

1 INTRODUÇÃO

1.1 Motivação

Durante o período de estágio na empresa STIHL Ferramentas Motorizadas, verificou-se que a empresa realiza diversas inspeções de qualidade em seus cilindros de motores, visto que esse componente é crítico para o sistema motor das diversas ferramentas ali produzidas. Uma das etapas da inspeção é a procura por defeitos e verificação do estado geral das janelas de admissão e escape, bem como os canais de transferência em todas as peças fabricadas. Essa inspeção, hoje, ainda é feita manualmente, e devido ao enorme volume de produção da fábrica, despense um grande número de operadores, resultando em um alto custo dessa inspeção, além dos problemas intrínsecos da inspeção humana, como a subjetividade. Tendo isso em mente, uma forma de automatizar essa inspeção, de maneira ágil e a baixo custo, poderia reduzir em muito os custos de produção e possibilitar o aumento da quantidade produzida.

1.2 Objetivos

Neste trabalho, propõe-se uma prova de conceito com base no desenvolvimento de um dispositivo capaz de posicionar e capturar imagens de maneira padronizada e software de inspeção capaz de acelerar a etapa de verificação de defeitos em cilindros de motores de combustão interna, reportando o status OK ou NÃO-OK. O dispositivo será prototipado e personalizado para ser utilizado em conjunto a um modelo específico de cilindro. O dispositivo de captura de imagem deve utilizar interface USB de forma a ser controlado via smartphone ou microcomputador, além disso, um sistema de iluminação visando a padronização de sombras e reflexos. As imagens capturadas devem apresentar uma boa qualidade visual de forma a ser utilizada em relatórios. Os defeitos devem ser claramente visíveis a olho nu.

2 REVISÃO BIBLIOGRÁFICA

Em seu trabalho, Saiz *et al.* (2018) propuseram um método baseado em aprendizado profundo (*deep learning*) para a classificação de superfícies de aço. Eles treinaram o sistema, utilizando uma Rede Neural Convolutiva (CNN, *Convolutive Neural Network*), para dados de imagens de um banco de dados público. Também testaram a robustez do sistema quanto a variações de iluminação das imagens, orientação e oclusões aleatórias. Compararam os resultados quanto à performance com outros 17 métodos de classificação correlatos. Como resultados concluíram que o sistema proposto se sobrepôs às outras metodologias sendo inclusive computacionalmente muito eficiente em termos do tempo de execução.

O estudo das regiões internas de motores de combustão interna através do uso de aprendizado de máquina também foi feito por Angermann *et al.* (2021) onde se propôs a análise de imagens de microscopia através de técnicas de aprendizado profundo (*deep learning*) para verificação do desgaste das camisas dos cilindros de grandes motores de forma não-destrutiva. O sistema foi baseado em uma Rede Neural Convolutiva (CNN), o banco de dados foi desenvolvido para o trabalho, onde uma série de imagens de microscopia das camisas dos cilindros, capturadas com equipamento de baixo custo e portátil, foi relacionada à curva de Abott-Firestone. Os autores puderam concluir um sistema capaz de estimar o estado dos principais valores de rugosidade superficial, ainda que se faça necessário o aprofundamento do estudo para maior confiabilidade da técnica.

O trabalho de Tajeripour e Ershad (2012) explica a utilização do método de detecção de irregularidades em imagens através da comparação de vetores de Padrões Binários Locais (LBP, *Local Binary Patterns*) e apresenta uma melhoria, que os autores chamaram de Padrões Binários Locais Melhorados (*Improved Local Binary Patterns*, ILBP) ambas técnicas consistem em treinar o

sistema alimentando-o com imagens sem defeitos, de forma a se obter um vetor de *features* padrão e apresentar uma nova imagem, agora com defeitos, para o extrator de características e realizar a comparação desses valores. Caso a diferença seja maior do que um valor de referência (*threshold*) o sistema acusa a não conformidade. A diferença entre o método tradicional para sua versão proposta é a modificação de valores dos vetores obtidos pelo LBP de forma a reduzir o peso de pequenas variações e majorar o efeito de mudanças bruscas de contraste na imagem. Para a definição do *threshold* foi utilizado o ponto máximo do método *log-likelihood function*. Ao final, os autores conseguiram reduzir a complexidade computacional do método em relação ao tradicional, possibilitando o uso do mesmo em tempo real, e ainda assim obter acurácias acima de 93%.

3 FUNDAMENTAÇÃO TEÓRICA

Nas próximas seções serão apresentadas as diversas técnicas empregadas neste trabalho, passando por uma breve revisão do conceito de aprendizado de máquina, análise de frequência de ocorrência de características, extração de features de imagens e o algoritmo de classificação de máquina de suporte de vetores.

3.1 Aprendizado de Máquina (Machine Learning)

O termo *Machine Learning* (Aprendizado de Máquina) pode ser definido como: “o campo de estudo que permite computadores aprenderem sem a necessidade de serem explicitamente programados.”¹ [SAMUEL, A.L, 1959, pp 210-229, tradução nossa], portanto é uma área da ciência da computação e de dados cujo conjunto de técnicas capacita computadores a aprenderem novas habilidades, sem a especificação em código da mesma. Os usos dessas técnicas simplificam difíceis problemas de otimização, classificação, identificação e previsão de dados visto que “Algoritmos de *Machine Learning* permitem realizar importantes tarefas a partir da generalização de exemplos e, normalmente, de maneira eficaz e efetiva onde, muitas vezes, não se faz possível com a programação tradicional”² [DOMINGOS, P., 2021, pp 78-87, tradução nossa]. Um bom exemplo é mostrado no próprio artigo de Samuel (1959) onde o mesmo desejava obter um programa que pudesse jogar o jogo de damas contra ele de forma similar a um humano, de maneira lógica e imprevisível. O programa foi desenvolvido e a ele foram instruídas as regras do jogo, uma vaga ideia de como jogar e alguns parâmetros que possivelmente estavam envolvidos com o jogo. Em um curto período de tempo, entre 8 a 10 horas, o programa realizou treinamento jogando contra si mesmo inúmeras vezes e ao final, presumidamente, foi capaz de aprender como jogar melhor do que seu desenvolvedor.

Existem diversas técnicas utilizadas em *Machine Learning*, como por exemplo, as Redes Neurais Convolutivas (*Convolution Neural Networks*), Padrões Binários Locais (*Local Binary Patterns*), Máquinas de Vetor de Suporte (*Support Vector Machines*) e Florestas Aleatórias (*Random Forests*). Além disso, o método de aprendizado pode ser classificado de duas maneiras, o aprendizado supervisionado e o não supervisionado. No aprendizado supervisionado o sistema é treinado com base em conjuntos de dados conhecidos e corretamente classificados e, posteriormente, novos dados, desconhecidos ao sistema, são mostrados a ele e a eficácia da classificação desse novo conjunto é medida. Já no método de aprendizado não supervisionado, um conjunto de dados é mostrado ao sistema sem classificação e o mesmo se encarrega de buscar e verificar padrões nos dados de forma a identificar possíveis subgrupos e a influência deles no todo. Após o treinamento, um grupo controle é mostrado ao programa de forma a avaliar a precisão do classificador.

¹ *Machine learning is the field of study that gives computers the ability to learn without being explicitly programmed*

² *Machine learning algorithms can figure out how to perform important tasks by generalizing from examples. This is often feasible and cost-effective where manual programming is not.*

3.2 Dicionário de Palavras (*Bag-of-words*)

Antes do grande *boom* dos algoritmos de Aprendizado Profundo (*deep learning*) já existiam diversos problemas reais onde se fazia necessário identificar e classificar padrões em dados. Problemas esses muitas vezes solucionados aplicando técnicas clássicas de classificação. Uma dessas técnicas é chamada de dicionário de palavras (*bag-of-words*), algoritmo amplamente utilizado para classificação e processamento de linguagem natural. Para o treinamento, textos são pré-processados de forma a retirar palavras de baixa relevância, e são expostos ao algoritmo que extrai um vocabulário de palavras, bem como sua frequência, formando, assim, o *bag-of-words*, que pode ser visualizado de maneira simples através de um histograma. Um exemplo típico para o processamento de palavras pode ser visto na Figura 3.1(a).

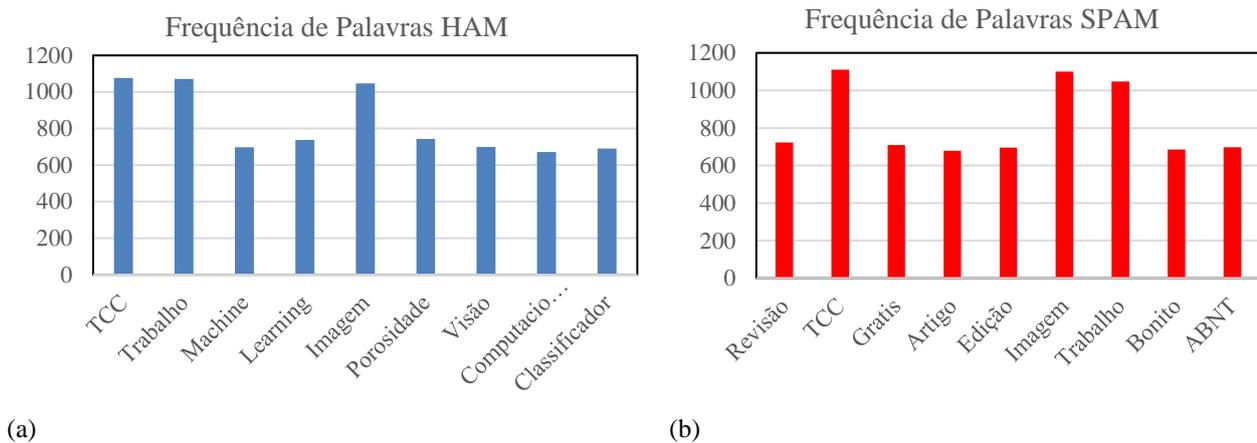


Figura 3.1 – Histograma de palavras de um *bag-of-words* de um texto de *e-mail* (a) não-SPAM (HAM) e (b) SPAM fictício. (Fonte: Autor)

A partir do estudo do histograma, pode-se encontrar as características de um texto e, assim, quando apresentado a um novo texto, classificá-lo. Essa técnica é muito utilizada em filtros de *SPAM*, onde um *bag-of-words* é extraído de diversos e-mails *SPAM* e comparado com a mensagem recebida. Caso sua similaridade seja estatisticamente relevante, a mensagem é classificada como *SPAM*, caso contrário, não. Nas Figura 3.1(b) podemos observar um *bag-of-words* fictício para *SPAM* bem como sua comparação, na Figura 3.2, com um texto não-spam (HAM). Nestes histogramas, pode-se perceber que há similaridade na frequência das palavras “TCC”, “Imagem” e “Trabalho”, porém, para todas as outras há grande diferença, portanto, o *e-mail* recebido não pode ser classificado como *SPAM*.

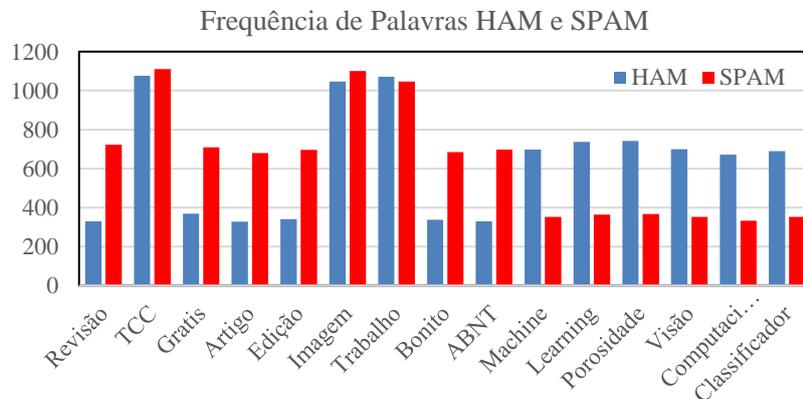


Figura 3.2 – Histograma comparativo entre *bag-of-words* de um texto de e-mail *SPAM* e não-*SPAM* fictícios. (Fonte: Autor)

Na Figura 3.3 é exemplificado um simples algoritmo, na forma de fluxograma, do funcionamento de um classificador de *e-mails*.

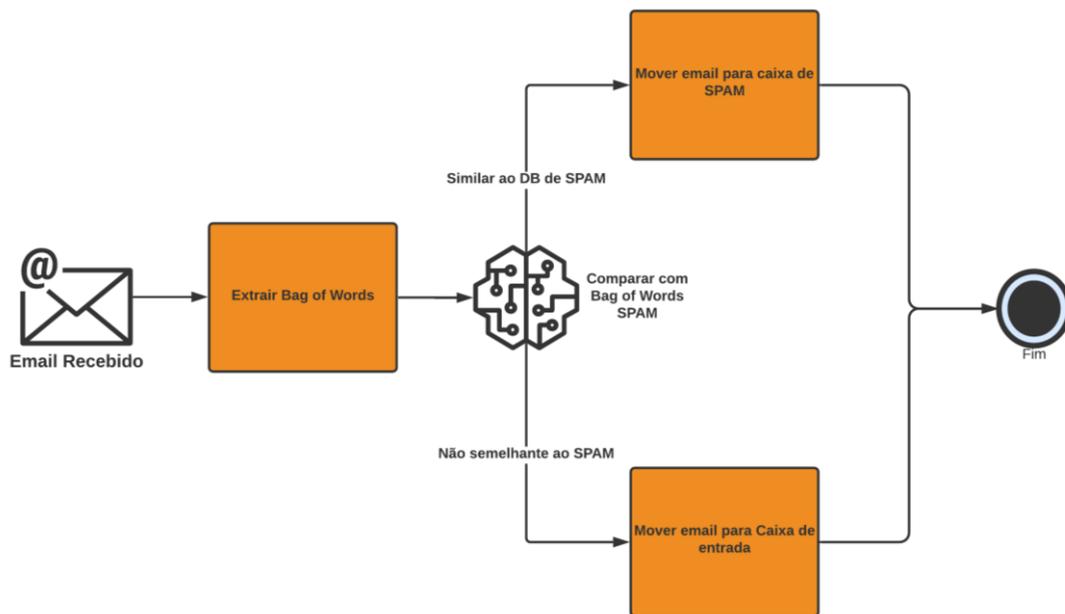


Figura 3.3 – Fluxograma de um algoritmo simplificado de classificador de e-mails. (Fonte:Autor)

3.3 Dicionário de palavras visuais (Bag-of-keypoints)

O trabalho de Csurka *et al.* (2004) propôs a utilização de uma técnica análoga ao *bag-of-words* para classificação de imagens, extraíndo características das imagens, chamadas de palavras visuais, e assim formando o *bag-of-keypoints*, também chamado de dicionário de características (*bag-of-features*) ou dicionário de palavras visuais (*bag-of-visual-words*). O extrator de características (*features*) proposto pelos autores é o Detector da região Afim de Harris (*Harris Affine Detector*), cujo funcionamento está descrito no artigo de Mikolajczyk e Schmid (2002). Neste extrator, as características são detectadas de maneira iterativa. Primeiramente pontos de interesse são localizados na imagem como máximos locais da função escalonada adaptada de Harris e do operador Laplaciano. Após, é traçada uma vizinhança de maneira elíptica cujo tamanho é determinado em função da escala utilizada e seu formato é caracterizado pelos autovalores do tensor de estruturas da imagem. O conjunto posição e a escala da vizinhança elíptica é iterada e somente é mantida caso ocorra convergência dentro de um número limite de iterações. Se o conjunto é aceito, a região elíptica é normalizada para uma circunferência, permitindo transformações afins. Descritores SIFT (*Scale Invariant Feature Transform*), são calculados para a região e resultam em um vetor de tamanho 128 pixels contendo as derivadas Gaussianas calculadas em 8 diferentes planos de orientação em uma região de tamanho 4x4. A Figura 3.4 exemplifica os mapas de gradiente correspondentes a essas orientações.

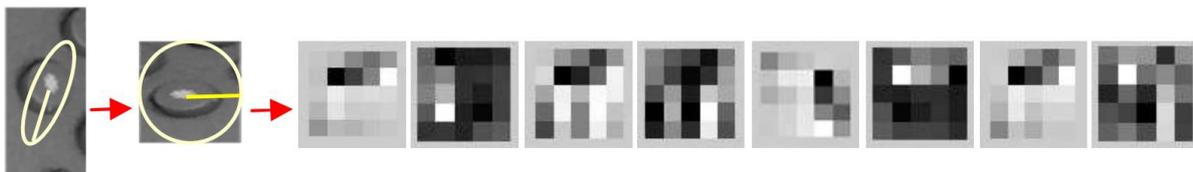


Figura 3.4 – Da esquerda para a direita: uma região *Harris* afim; a região normalizada; 8 mapas de gradiente que compõe o descritor SIFT. (Fonte: Csurka *et al.* (2004), p 6).

Após a extração dos vetores de descritores pelo método SIFT, pode-se realizar a construção do vocabulário de palavras visuais (*bag-of-visual-words*). Porém, devido à enorme quantidade de descritores encontrados por imagem, faz-se necessário o uso de técnicas de agrupamento (*clustering*).

Nesta técnica, utiliza-se o algoritmo de agrupamento iterativo de k -médias, que é um dos métodos mais simples de agrupamento de uso do erro médio quadrático.

Após os descritores estarem devidamente agrupados, o problema de classificação de novas imagens passa a ser um problema supervisionado de classificação de dados de múltiplas classes. Esse problema é solucionado apresentando ao sistema imagens pré-classificadas em dois grupos, treinamento e teste, onde o algoritmo extrai o vocabulário (*bag-of-features*) de cada classe e grupo e as compara, de forma a obter uma métrica da eficácia do sistema. Após atingir uma precisão aceitável, pode-se apresentar uma nova imagem, não classificada para o classificador e o mesmo deverá ser capaz de corretamente determinar a categoria desta imagem. Para sistema de classificador entre os grupos de vocabulários, pode-se utilizar diversas técnicas, como *Support Vector Machine* (SVM) e o algoritmo de Naive Bayes.

3.4 Máquina de Suporte de Vetor (*Support Vector Machines*, SVM)

As máquinas de suporte de vetores foram propostas no trabalho de Cortes e Vapnik (1995) e estão entre os algoritmos mais robustos de predição e classificação. A partir de um conjunto de dados de treinamento, previamente classificados em dois grupos, o sistema os distribui em um espaço de p -dimensões contendo os vetores de dados de tamanho p . Neste espaço, o algoritmo procura os hiperplanos de tamanho $p-1$ que dividem corretamente os dados, de forma que dados da classe 1 fiquem “acima” do hiperplano e os dados da classe 2 fiquem abaixo desse hiperplano. O hiperplano escolhido para melhor representar o classificador é aquele que apresenta a maior distância do plano a cada classe. A Figura 3.5 exemplifica dois conjuntos de dados separados por um hiperplano e seus vetores de suporte.

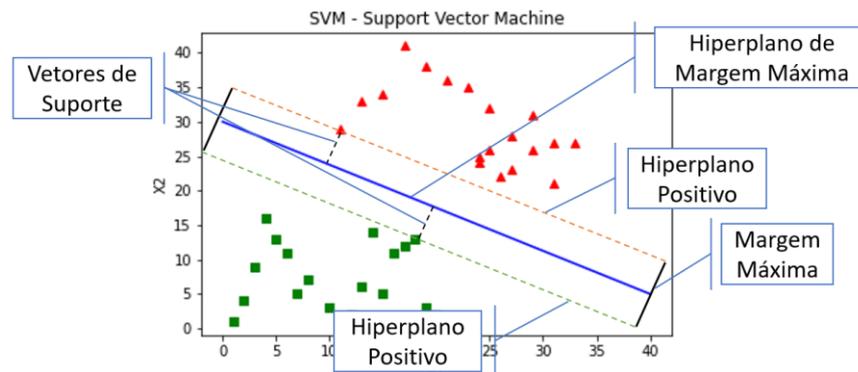


Figura 3.5 – Dois conjuntos de dados separados por um hiperplano linear. Pode-se observar que a separação está otimizada visto que seus vetores de suporte se apresentam perpendiculares ao hiperplano. (Fonte: Autor)

Esse modelo de classificador é bastante robusto para dados separáveis por hiperplanos lineares, porém, apresenta particularidades para dados não-linearmente separáveis. Visando solucionar esse problema, os autores propuseram o uso de funções de *kernel* de forma a mover o problema para um novo espaço de *features* onde passa a ser possível obter um hiperplano capaz de dividir os grupos em sua máxima distância. Vale ressaltar que apesar do hiperplano obtido no espaço de *features* ser linear, o plano pode ser não-linear no espaço original. Diversas funções de *kernel* podem ser utilizadas, como por exemplo as funções polinomiais, gaussianas e tangente hiperbólicas. A utilização do *kernel trick* (funções de *kernel* utilizadas para criar classificadores não-lineares) apresenta como inconveniente o aumento do problema de generalização, fazendo com que seja necessário aumentar o volume de dados para uma efetiva classificação. A biblioteca SCIKIT-LEARN (2021) aberta do Python foi a adotada para esta tarefa de classificação com SVM.

4 MATERIAIS E MÉTODOS

4.1 Câmera utilizada para aquisição de imagens

Para este projeto, foi proposta a utilização de 4 técnicas de captura de imagem. Estas foram propostas em função das limitações do projeto, não sendo este o foco do trabalho. A utilização de outras técnicas de captura de imagem pode trazer resultados diferentes para o algoritmo de classificação, portanto, podem ser estudadas com mais profundidade em próximo estudo. Também foi discutida a sua viabilidade tanto técnica quanto financeira. A primeira proposta foi a utilização de câmeras junto a um *Raspberry Pi*, equipamento que teria um custo na ordem dos R\$ 1000,00. Trata-se de um dispositivo *standalone* visto que é um microcomputador de placa única, porém as câmeras disponíveis específicas para este equipamento possuem grandes distâncias focais, impossibilitando o uso na aplicação.

Fez-se contato com empresas buscando soluções de mercado para o sistema de inspeção, porém, o alto custo das propostas (superior a 120 mil euros) impossibilitou a escolha. Esse sistema atenderia todos os requisitos do projeto, inspecionando e gerando relatórios sobre geometria e qualidade dos cilindros de diâmetros superiores a 14mm.

Uma terceira opção foi a fabricação de um sistema com o uso de câmeras e espelhos, esse equipamento se mostrou muito barato para se fabricar, porém, o *setup* se mostrou muito caro e complexo, necessitando o uso de uma câmera profissional, com controle manual de foco e lentes específicas para o correto foco na região, além da dificuldade de se padronizar o posicionamento.

A última proposta, que foi a escolhida, foi o uso de um boroscópio USB, que é encontrado em lojas de artigos eletrônicos com facilidade e com custo na ordem dos R\$ 70,00. Esse equipamento é capaz de focar em superfícies a 30mm de distância, conectar-se tanto com smartphones quanto com computadores e seu tamanho diminuto facilita o posicionamento. A desvantagem encontrada nesse equipamento é a definição da imagem obtida, que é de 640x480px com 96dpi. Informações mais detalhadas sobre este equipamento estão disponíveis na tabela A.1 do anexo. Um resumo dos equipamentos propostos pode ser melhor visualizado na Figura 4.1.



Figura 4.1 – Propostas de equipamentos para a captura de imagem. (Fonte: Autor).

4.2 Bancada Experimental para aquisição de imagens

Para realizar a padronização da imagem faz-se necessária a padronização do posicionamento do cilindro em relação ao boroscópio, portanto, um sistema de fixação foi proposto. Os cilindros fabricados pelo grupo STIHL são fixados ao restante do grupo motor através de parafusos, e assim possuem uma furação dimensionalmente precisa. Logo, utilizar uma base com pinos coincidentes com estes furos mostra-se como uma solução eficiente e robusta para a aplicação. O dispositivo de fixação foi projetado através do uso de softwares CAD e fabricado através de impressão 3D em ABS, conforme pode ser visto na Figura 4.2.



Figura 4.2 – Da esquerda para direita: Dispositivo de fixação, componente de posicionamento da câmera e cilindro posicionado no dispositivo de fixação. (Fonte: Autor).

4.3 Modelo de cilindro e regiões analisadas

O modelo de cilindro foi escolhido com base no volume de produção, frequência de não-conformidades encontradas no processo fabril, custo de retrabalho e/ou sucateamento e visibilidade do defeito. A partir da análise desses parâmetros, foi definida a utilização de um cilindro de motosserra fabricado pelo método de fundição por gravidade de alumínio.

Neste modelo existem 6 regiões de interesse: as janelas de admissão e escape, e 4 canais de transferência. Na Figura 4.3 exemplificam-se essas regiões.



Figura 4.3 – Da esquerda para direita: imagem interna da janela de admissão, janela de escape e canais de transferência em diferentes configurações de posicionamento e iluminação. (Fonte: Autor).

Os defeitos observados com maior frequência e visibilidade são as porosidades, principalmente nos canais de transferência, e estas regiões serão as analisadas. As imagens serão classificadas somente quanto à presença ou não dessas porosidades. A Figura 4.4 apresenta um exemplo de cada classe, ou seja, uma imagem apresentando porosidade e a outra, não.

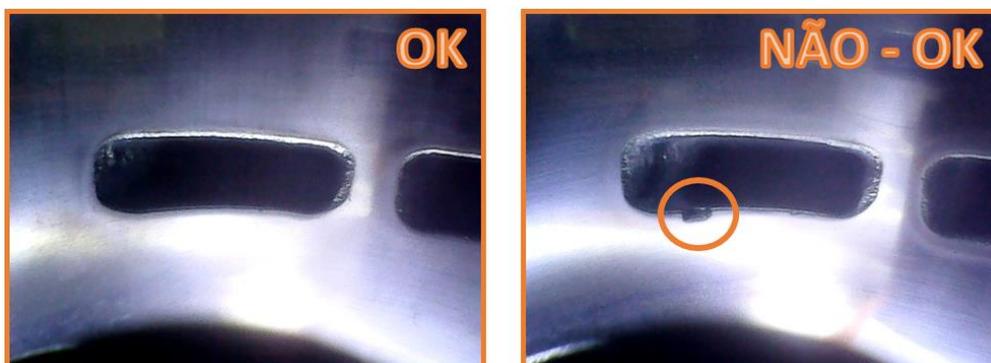


Figura 4.4 – Da esquerda para direita: Canal de transferência sem porosidades, Classe - OK, Canal de transferência com porosidades, Classe – NÃO-OK. (Fonte: Autor).

4.4 Pré-processamento de imagens

Visando a redução da influência de pequenos desvios de iluminação, posicionamento e ruídos da imagem no algoritmo de extração de *features*, as imagens serão processadas, através do uso de código desenvolvido, pelo autor, em PYTHON (2021), de forma a conterem somente os canais analisados. Entretanto, parâmetros específicos para pré-processamento da imagem devem ser manualmente ajustados para cada conjunto de imagem. A Figura 4.5 exemplifica imagens pré-processadas.

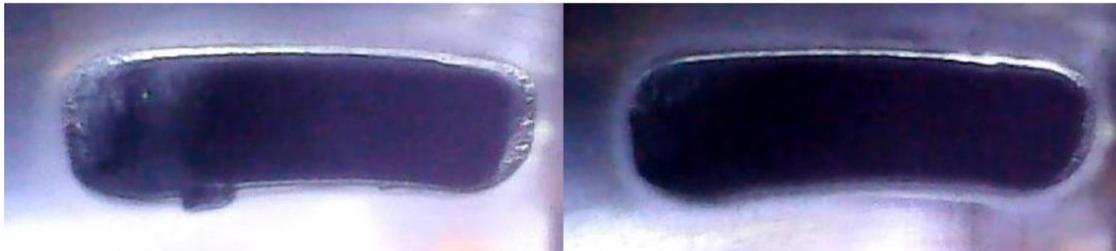


Figura 4.6 – Imagens pré-processadas de canais da Classe – NÃO-OK e Classe – OK. (Fonte: Autor).

A partir da extração das imagens da região de interesse, filtros foram aplicados visando a melhoria da detecção de falhas. Os filtros aplicados foram: (i) monocromático, (ii) extração de bordas, (iii) monocromático + *gaussian blur* e (iv) escala de cinza. A Figura 4.7 apresenta os filtros utilizados.



Figura 4.7 – Fluxograma apresentando os diversos filtros e pré-processamentos aplicados nas imagens. (Fonte: Autor).

4.5 Algoritmo de extração de *features*, treinamento e classificação

O software de inspeção foi desenvolvido na linguagem PYTHON e baseou em técnicas de aprendizado de máquina supervisionado, como máquinas de suporte de vetores, redes neurais e florestas aleatórias. Ele é capaz de reconhecer características de imagens previamente rotuladas como OK ou NÃO-OK e classificar novas imagens a partir de suas características.

O software foi desenvolvido implementando a solução de Csurka *et al.* (2004) para a formação do *bag-of-features* a partir do banco de imagens pré-processadas e pré-rotuladas.

O banco de dados, contendo 75 imagens, sendo 55 OK e 20 NÃO-OK, foi dividido em duas partes, sendo a primeira contendo 70% das imagens que serão utilizadas para o treinamento do classificador e a segunda contendo os restantes 30% que serão utilizadas para teste do classificador.

Após a extração de *features*, elas são utilizadas como dados de entrada para uma *SVM*, que deve encontrar os hiperplanos que melhor dividem as imagens nas classes, este processo é chamado de treinamento do classificador.

Ao fim do treinamento, o classificador é testado utilizando o próprio banco de dados de treinamento como dados de entrada, resultando numa métrica de precisão e uma matriz de confusão para o treinamento. Nesta etapa, é esperado uma acurácia de 100%, visto que estamos realizando a classificação de dados já conhecidos pelo classificador e, portanto, a matriz de confusão deve apresentar diagonal principal populada com valores 1.0 e demais valores como 0. A Figura 4.8 exemplifica uma matriz de confusão esperada para treinamento.

		valores previstos	
		OK	Não OK
Valores Preditos	OK	100% (TP)	0% (FN)
	Não OK	0% (FP)	100% (TN)
		Acurácia	100%

Figura 4.8 – Matriz de confusão esperada, contendo a Acurácia do classificador para o próprio banco de dados de treinamento (TP-True Positive, FP-False Positive, FN-False Negative, TN-True Negative). (Fonte: Autor).

4.6 Algoritmo de mistura de especialistas

Segundo Marques *et al.* uma técnica amplamente utilizada para ganho de performance de classificação é o uso de classificadores múltiplos, também conhecidos como mistura de especialistas ou, até mesmo, *ensemble learning*. Essa técnica consiste da união de diversos classificadores individualmente treinados que são de alguma forma combinados.

Neste trabalho, utilizaremos as técnicas de votação simples e ponderada (*Hard/Soft Voting Classifier*). Realizaremos 5 treinamentos distintos, cada um utilizando como dado de entrada os *bag-of-keypoints* extraído de um dos seguintes conjuntos de dados: Imagens originais, região de interesse recortada, monocromático, extração de bordas e monocromático + *gaussian blur*. Vale ressaltar que todas as imagens, por padrão do processo de extração de *features SIFT*, passam por um filtro de escala de cinza.

Após treinamento de cada um dos classificadores, os *voting classifiers* são montados e validados. Os algoritmos executam as seguintes operações, em ordem, recebem o *bag-of-keypoints* de uma imagem do conjunto de validação e apresenta esses dados a todos os classificadores onde cada um, individualmente, reportam resultado da classificação, em nosso caso OK ou NÃO-OK. Em sequência, o algoritmo realiza votação entre os resultados e o vencedor é reportado. A votação simples é vencida pela classe que obtiver 50%+1 votos e em caso de empate, é mantido o resultado do classificador com maior precisão, critério que nunca será utilizado neste trabalho visto o número ímpar de conjuntos de imagem. Já a votação ponderada carrega a informação da probabilidade da predição, função da precisão e acurácia do classificador, junto a seu voto de forma a prevalecer resultados de maior confiança. No improvável caso de empate, é mantido o resultado do classificador de maior peso. A Figura 4.9 apresenta de forma gráfica uma versão simplificada do algoritmo utilizado.

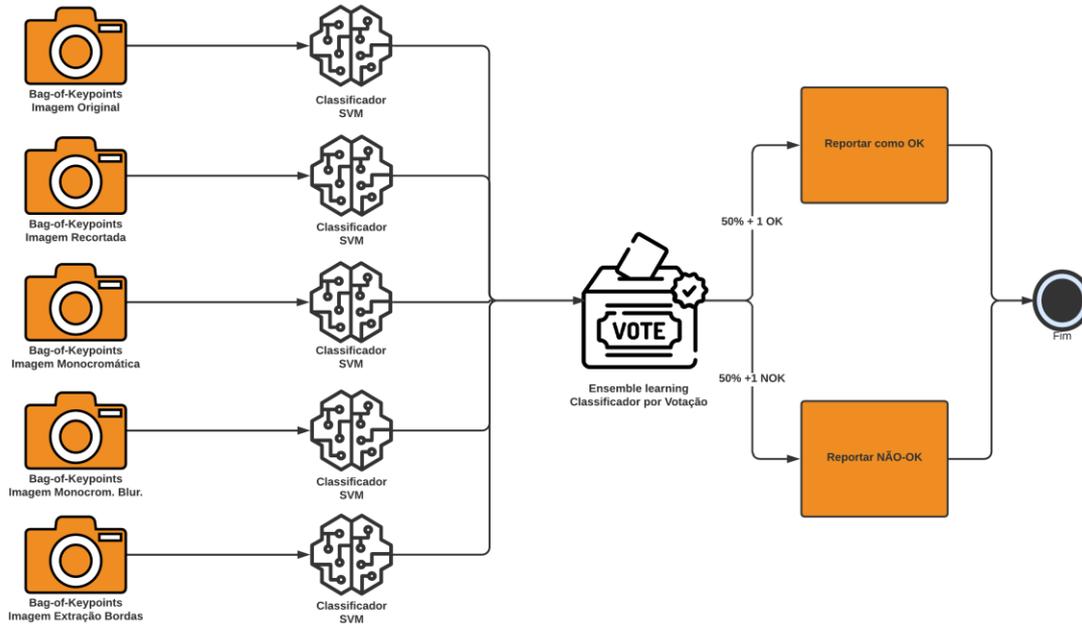


Figura 4.9 – Fluxograma de um algoritmo simplificado de algoritmo de mistura de especialistas por votação simples e ponderada para classificação de imagens em duas classes. (Fonte: Autor)

4.7 Métricas utilizadas para avaliação da performance do classificador

Depois de realizado o treinamento, o banco de dados de teste (30% do total de imagens) é exposto ao classificador de forma a testar a sua performance quando introduzidas novas imagens desconhecidas, ao programa. Terminando a classificação, o software informa a precisão e matriz de confusão encontradas, de forma a avaliar a eficácia do programa.

A partir da matriz de confusão, é possível obter métricas que permitem a comparação de resultados entre diversos treinamentos e algoritmos. Uma delas é o MCC, indicado pela Equação (4.1):

$$MCC = \frac{(TP \times TN - FP \times FN)}{\sqrt{(TP + FP) \times (TP + FN) \times (TN + FP) \times (TN + FN)}} \quad (4.1)$$

A Equação (4.1) representa o coeficiente de correlação de Matthews (MCC, *Mathews Correlation Coefficient*), que conforme Chicco e Jurman (2020), é uma das medidas mais robustas para representação e comparação de resultados de matrizes de confusão. Esse valor pode variar de -1 (predição perfeitamente errada) a 1 (predição perfeita) e 0 (predição randômica).

A Precisão é apresentada na Equação (4.2) e representa a homogeneidade dos resultados da classificação.

$$PPV = \frac{TP}{TP + FP} \quad (4.2)$$

A Acurácia, representada pela sigla ACC e descrita na Equação (4.3), é a métrica que informa a capacidade do algoritmo de classificar corretamente.

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.3)$$

Já o *Recall*, que representa a proporção de itens corretamente classificados como OK dentro do universo de imagens classificadas como OK, é descrito na Equação (4.4).

$$TPR = \frac{TP}{TP + FN} \quad (4.4)$$

4.8 Método de validação de resultados (*k-fold cross-validation*)

Devido ao pequeno tamanho do banco de dados disponível, é provável que haja métricas altamente voláteis quando o algoritmo é exposto a diferentes conjuntos de dados para validação, pois, dependendo de suas características pode haver predileção de classificação de determinadas imagens. Visando a obtenção de métricas mais robustas para o classificador, é prática comum a utilização de técnica de validação cruzada (*cross-validation*), onde se executa k treinamentos e subsequentes validações, onde em cada iteração os conjuntos de dados de treinamento e validação são alterados de forma a obter métricas independentes do conjunto de dados de entrada. Posteriormente, calcula-se a média e o desvio padrão para cada uma das medições e este passa a ser o resultado utilizado para a avaliação do sistema, portanto, todos os resultados neste trabalho serão apresentados na forma de valor médio, e, onde cabível, seu desvio padrão.

Neste trabalho, foram realizadas 5 validações cruzadas (*5-fold cross-validation*) para cada uma das métricas estudadas.

5 RESULTADOS

Nesta seção serão discutidos os treinamentos realizados com os diversos pré-filtros aplicados nas imagens e no modelo de classificador descrito, assim como a comparação de seus resultados a partir da análise de suas métricas obtidas das matrizes de confusão. Ao final, um dos treinamentos é escolhido como o mais promissor a ser utilizado para o desenvolvimento do produto final, bem como um parecer quanto a eficácia do dispositivo construído.

5.1 Resultados do treinamento

A partir da metodologia descrita no respectivo trabalho, uma máquina de suporte de vetores (SVM) foi treinada utilizando os modelos (*Bag-of-Keypoints*) contendo as imagens das variadas classes. Ao fim do treinamento obtivemos as matrizes de confusão dispostas na Figura 5.1.

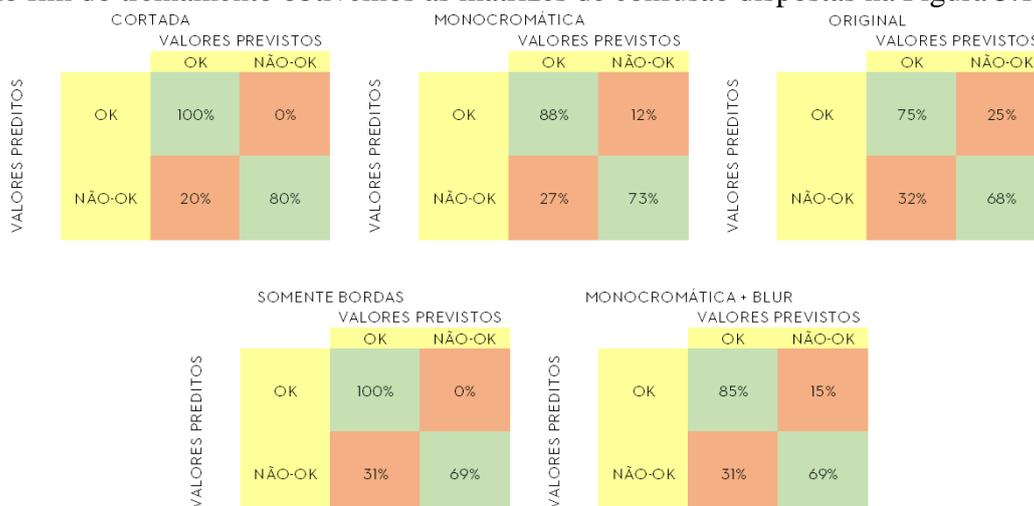


Figura 5.1 – Matrizes de confusão obtidas ao fim do treinamento com 5 diferentes tipos de filtros aplicados. (Fonte: Autor)

Estes resultados apresentaram tendência para a escolha do uso das classes de imagens puramente cortadas ou a análise apenas das bordas. Essa afirmação é reforçada visto resultados visivelmente maiores para a correta avaliação de resultados, tendo 100% de acertos quando classificando regiões

OK. Além disso, apenas nestes dois modelos foi verificada a ausência de erros do tipo 2, que aceitaria cilindros defeituosos, e a presença de erros do tipo 1, que tornam o classificador superconservador, retornando *status* de não conformidade mesmo para alguns casos onde não há real defeito.

Porém, a avaliação das matrizes de confusão é de matéria amplamente discutida na literatura e é consenso que se faz necessária a extração de métricas, ou seja, valores objetivos e comparáveis para a definição e comparação da eficácia de cada algoritmo e/ou treinamento. Para tal, as métricas apresentadas nas Equações (4.2), (4.3) e (4.4) que representam a Precisão, Acurácia e *Recall* foram calculadas para cada uma das matrizes de confusão e foram dispostas de forma gráfica na forma da Figura 5.2.

Podemos observar, novamente, que os valores apresentados pelos grupos de imagens puramente cortadas e a avaliação apenas das bordas estão consistentemente mais altos do que os apresentados pelas outras classes. É observado valores de acurácia de $92\% \pm 4\%$ e uma precisão de $82\% \pm 5\%$ para as imagens simplesmente cortadas, isso representa que o classificador, neste caso, é capaz classificar uma imagem corretamente na grande maioria das vezes. Já para as imagens cujas bordas foram extraídas, foi encontrado valores de acurácia de $88 \pm 5\%$ e precisão de $79\% \pm 5\%$, valores um pouco aquém daqueles apresentados pela classe de imagens cortadas, porém, ainda assim, bastante significantes. Ambos os grupos apresentaram um *Recall* de 100%.

Para uma comparação mais técnica, seguindo recomendação apresentada por Chicco e Jurman (2020), o cálculo do MCC disposto na Equação (4.1), foi realizado para cada um dos casos e novamente apresentado de forma gráfica conforme disposto na Figura 5.3.

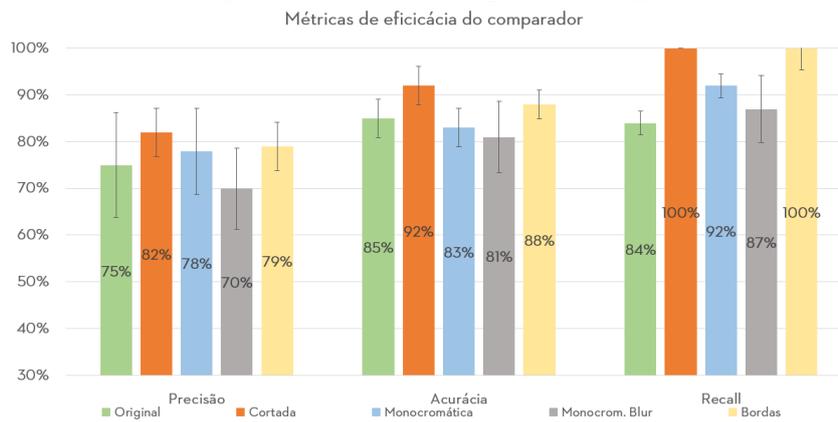


Figura 5.2 – Métricas de eficácia obtidas ao fim do treinamento com 5 diferentes tipos de filtros aplicados. (Fonte: Autor)

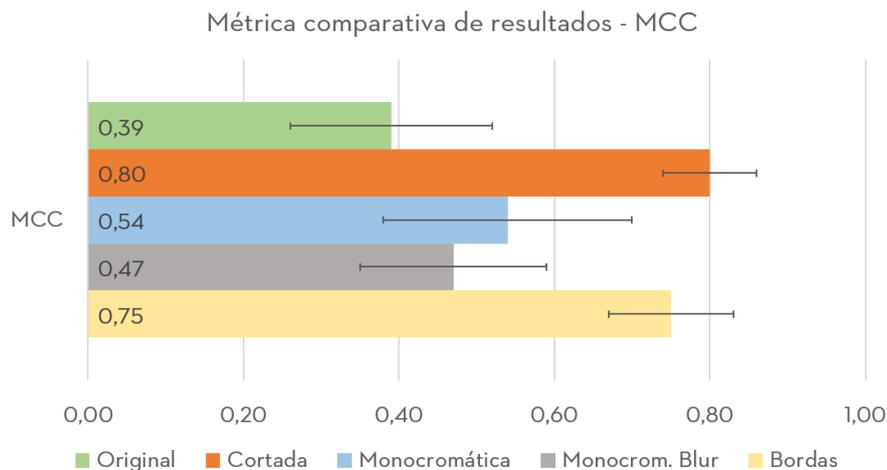


Figura 5.3 – Valores do *Matthews Correlation Coefficient* (MCC) obtidos para cada caso proposto. (Fonte: Autor)

Tendo, agora, os resultados obtidos dos valores de MCC para os diversos casos aqui analisados, podemos afirmar que os casos de imagens puramente cortadas e imagens das bordas apresentam melhores resultados de classificação de cilindros OK e NÃO-OK. Todavia, a sutil diferença entre os valores obtidos para MCC entre a classe cortada ($0,80 \pm 0,06$) e classe bordas ($0,75 \pm 0,08$) não necessariamente apresenta superioridade de um método em detrimento ao outro, visto que, é provável que haja variações destes valores quando o algoritmo for exposto a uma base de dados contendo maior número de imagens.

Tendo em posse, agora, classificadores treinados e funcionais, foi realizada configuração do sistema de votação simples e ponderada e executada a validação. As suas respectivas matrizes de confusão foram computadas conforme a Figura 5.4. Nela podemos verificar que ambos classificadores *ensemble learning* (mistura de especialistas) apresentaram diagonal principal com termos iguais a 100%, indicando que filtros de imagens diferentes podem ser utilizados para facilitar a correta classificação, também pode-se inferir que existe predileção de tratamento para ressaltar determinada característica da imagem para o classificador. A obtenção do resultado perfeito deve ser lidada com atenção visto o pequeno conjunto de dados disponível e a possibilidade de haver *overfitting*, termo utilizado para quando há a superespecialização para classificação de dados de um determinado conjunto.

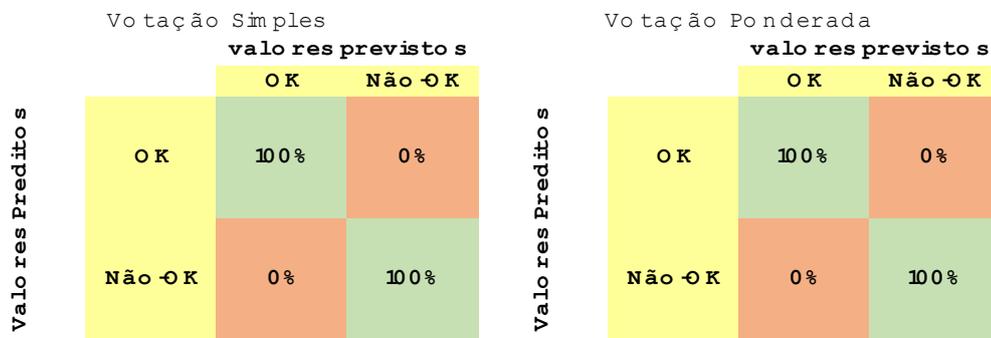


Figura 5.4 – Matrizes de confusão resultantes da validação realizada nos sistemas de votação simples e ponderada, em ordem (Fonte: Autor).

As métricas de acurácia, precisão, *recall* e MCC foram calculadas com a utilização das técnicas da validação cruzada e, agora, apresentam valores mais realistas e estão dispostas na Figura 5.4. Pode-se verificar a similaridade dos resultados entre os classificadores de votação simples e ponderada, com pequena vantagem para o segundo, devido ao menor desvio na precisão. Também, é sensível a melhoria de resultados frente àqueles apresentados pelos algoritmos mais simples, houve aumento relativo da precisão e acurácia em relação ao melhor caso anteriormente apresentado, porém, concomitantemente, uma leve diminuição do *Recall*, que se mantém dentro da faixa de desvio esperado.

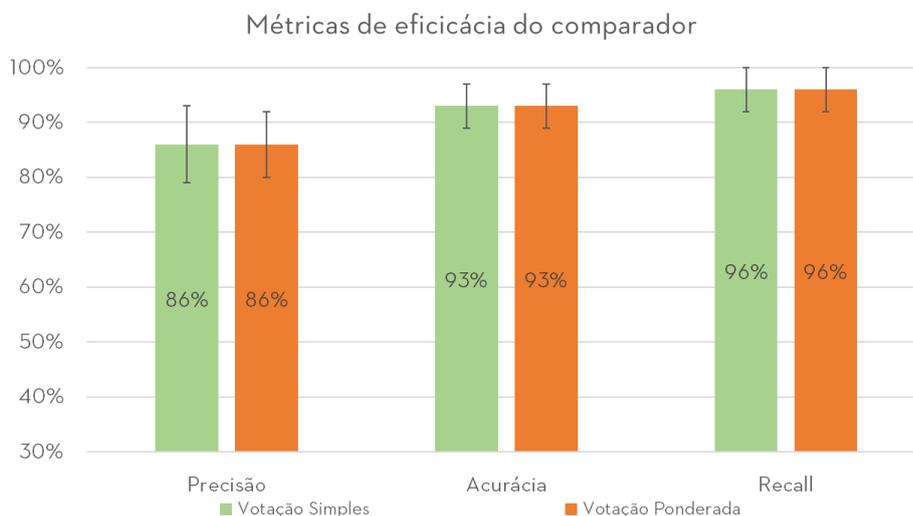


Figura 5.5 – Métricas de eficácia obtidas pelos sistemas de classificação por votação simples e ponderada.
(Fonte: Autor)

Visando possibilitar a comparação com os outros casos estudados, para estes classificadores *ensemble learning* também se calculou os valores de MCC, conforme disposto na Figura 5.6. Agora com estes resultados obtidos é possível verificar se houve melhoria na classificação ao empregar as técnicas de mistura de especialistas. Ao realizar essa comparação, nota-se que houve aumento do MCC médio para os melhores casos, passando de 0,80 para 0,86, com desvios menores, portanto, esses resultados reforçam a efetividade da técnica quando utilizando essa configuração de dispositivo de fixação e captura de imagem.

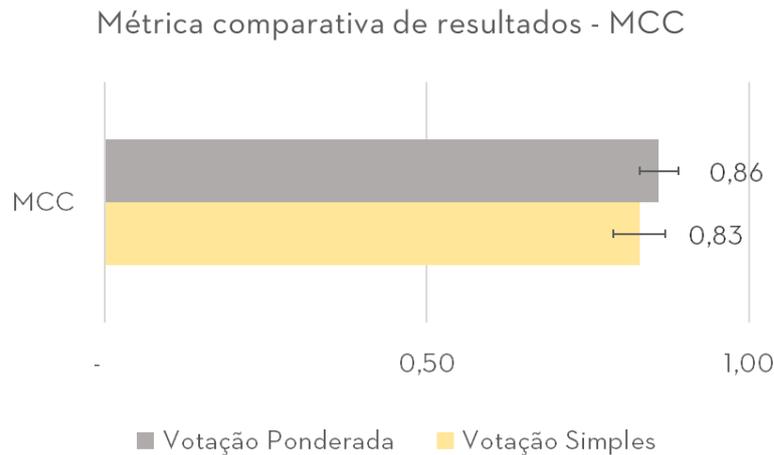


Figura 5.6 – Valores do *Matthews Correlation Coefficient* (MCC) obtidos para os classificadores *ensemble Learning* (Fonte: Autor).

6 CONCLUSÕES

A partir dos resultados obtidos no trabalho, foi possível construir um dispositivo capaz de obter imagens internas de cilindros de maneira rápida e simples, cuja qualidade é aceitável para a confecção de relatórios técnicos. Também, devido a padronização da iluminação e posicionamento, estas imagens podem apresentar comparabilidade visual, permitindo, assim, a inspeção visual e a verificação de artefatos que podem vir a surgir durante o tempo fabril ou testes no equipamento, processo antes subjetivo.

Tendo em posse um banco de dados de imagens de cada um dos canais de transferência do modelo de cilindro utilizado, fez-se diversos pré-processamentos e que foram utilizados como dados de entrada, bem como as imagens não tratadas, para o treinamento do algoritmo de classificação de imagens. Os resultados apresentados demonstram que é possível realizar inspeção através do método proposto, visto que foi obtido casos cuja precisão e acurácia se mantiveram acima dos 90%, não apresentando erros do tipo 2 e uma baixa frequência de erros do tipo 1, que são relativamente aceitáveis visto que tornam o classificador superconservador. Os resultados foram reforçados a partir da utilização da métrica MCC (*Matthews Correlation Coefficient*) que, novamente, apresentou altos valores, de forma que se pode concluir a eficácia do método.

Dentro do grupo de imagens utilizadas para treinamento, as imagens contendo apenas a região de interesse com suas características visuais inalteradas apresentaram melhores resultados frente àquelas processadas e as imagens originais, isso possivelmente se deve ao fato de reduzirmos a quantidade de informação pouco variante e inútil contida da imagem, amplificando a importância dos defeitos procurados. Também, as imagens processadas com filtros de cor e/ou redução de ruído apresentaram resultados aquém daquelas simplesmente recortadas. Esse resultado leva a inferência de que a aplicação desses filtros reduz excessivamente a quantidade de informações da imagem, tornando os mapas de gradiente extraídos pouco diferenciáveis.

O aumento do volume de dados, como em grande parte dos casos de problemas de aprendizado de máquina, pode ser de significativa valia para a melhoria dos resultados. Neste caso, é de extrema necessidade visto que erros na classificação podem trazer custos de sucateamento de material em conformidade, mediante erro do tipo 1, custos de garantia ou sucateamento da peça em momento de fabricação com maior valor agregado devido a erros do tipo 2, e/ou a necessidade de uma segunda inspeção visual por operador treinado, conflitando com o propósito do trabalho.

É proposta, para trabalhos futuros, a fabricação de dispositivo capaz de avaliar mais de um tipo de cilindro (diâmetro) e com câmera de melhor qualidade, possibilitando a análise de outros tipos de defeitos, como a variação da inclinação dos chanfros das aberturas dos cilindros, que podem modificar o perfil de emissões de gases do motor e necessitam de imagens com maior resolução e informação de profundidade.

Também é sugerido o uso de outros tipos de classificadores e regressores de dados amplamente discutidos na literatura, como, por exemplo, a regressão logística, árvores de decisão e florestas aleatórias. Estes algoritmos, num segundo momento, podem ser utilizados também para implementação de diversas técnicas de *ensemble learning*, principalmente de classificadores empilhados (*stacking classifiers*) onde se adiciona aos dados de entrada, no caso ao *bag-of-keypoints*, o resultado da classificação de cada imagem de forma a aumentar o volume de informações expostas ao algoritmo de classificação. Um modelo esquemático proposto para essa técnica está disposto na Figura A.1 do apêndice.

Além disso, também proponho para trabalhos futuros a aplicação de diferentes técnicas para a classificação de imagens, como o uso de redes neurais, utilizando a imagem como dado de entrada, ao invés dos descritores SIFT, ou ainda a utilização de outros descritores como ORB (*Oriented FAST and rotated BRIEF*) e SURF (*Speeded up robust features*), avaliação da utilização da posição dos descritores em detrimento aos mapas de gradiente e, como método mais promissor, o uso de procedimentos de visão computacional para identificação e análise de contorno. Um exemplo de pré análise está representado na Figura 6.2.

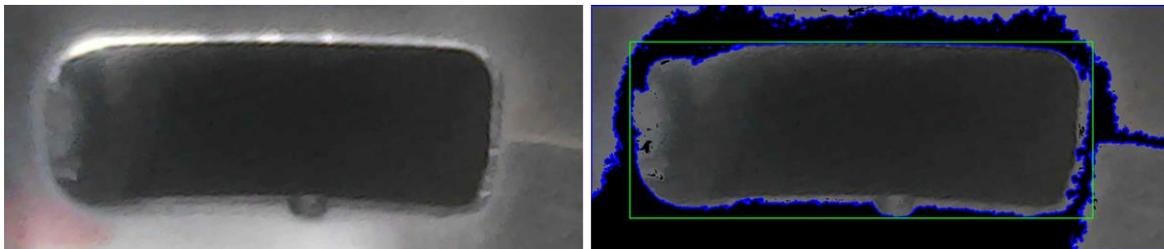


Figura 6.2 – Da esquerda para direita: Imagem original, Imagem com contornos analisados (em azul) e região de interesse destacada (em verde).

Finalmente, podemos concluir que a utilização da técnica proposta vem apresentando resultados promissores, que devem apresentar melhora com o aumento do banco de dados de imagens, principalmente de defeitos. Portanto, o método foi validado e pode ser melhor explorado e testado para outros casos, visando realizar inspeção em tempo real na linha de produção. Conclusões mais assertivas quanto o classificador de melhor desempenho pode ser futuramente avaliado mediante a testes estatísticos de análise de variância, ficando como sugestão para trabalhos futuros.

REFERÊNCIAS BIBLIOGRÁFICAS

ANGERMANN, C., JÓNSSON, S., HALTMEIER, M., MORAVOVÁ, A., LAUBICHLER, C., KIESLING, C., KOBE, M., FIMML, W. **Machine Learning for Nondestructive Wear Assessment in Large Internal Combustion Engines**. 2021, Computing Research Repository (CoRR), 2021, arXiv: 2103.08482.

CHICCO D., JURMAN G. **The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation**. 2020, BMC Genomics. Vol 21, pp: 6-1-6-13. doi:10.1186/s12864-019-6413-7. PMC 6941312. PMID 31898477.

CORTES, C., VAPNIK, V. **Support-vector networks**. 1995, Mach Learn 20, pp 273-297. doi: 10.1007/BF00994018.

CSURKA, G., DANCE, C., FAN, L., WILLAMOWSKI, J., BRAY, C. **Visual categorization with bags of keypoints**. 2004, Workshop on Statistical Learning in Computer Vision, ECCV. v. 1, pp 1-22.

DOMINGOS, P. **A few useful things to know about machine learning**. 2021, Communications of the ACM, v. 55, n°10, pp 78-87, doi: 10.1145/2347736.2347755.

MIKOLAJCZYK, K., SCHMID, C. **An affine invariant interest point detector**. 2002, Computer Vision-ECCV 2002. ECCV 2002, pp 128-142. doi: 10.1007, ISBN 3-540-47969-4.

PYTHON. **Support Vector Machine Python Example. Towards data science**. Disponível em: <https://towardsdatascience.com/support-vector-machine-python-example-d67d9b63f1c8>. Acesso em: 1 de setembro de 2021.

SAIZ, F. A., SERRANO, I., BARANDIARÁB, I., SÀNCHEZ, J. R. **A robust and fast deep learning-based method for defect classification in steel surface**. 2018, International Conference on Intelligent Systems (IS), 2018, pp. 455-460, doi: 10.1109/IS.2018.8710501.

SAMUEL, A. L. **Some studies in machine learning using the game of checkers**. 1959, IBM Journal of research and development, v. 3, n°3, pp. 210-229, doi: 10.1147/rd.33.0210.

SCIKIT. **Support Vector Machines – Scikit-Learn Documentation**. Disponível em: <https://scikit-learn.org/stable/modules/svm.html#mathematical-formulation>. Acesso em: 1 de setembro de 2021.

TAJERIPOUR, F., ERSHAD, S. F. **Porosity detection by using Improved Local Binary Patterns**. 2012, EHAC'12/ISPRA/NANOTECHNOLOGY'12: Proceedings of the 11th WSEAS international conference on Electronics, Hardware, Wireless and Optical Communications, and proceedings of the 11th WSEAS international conference on Signal Processing, Robotics and Automation, and proceedings of the 4th WSEAS international conference on Nanotechnology, 2012, pp. 116-121, ISBN 978-1-61804-069-5.

MARQUES, A., GARCIA, V., SANCHEZ, J., Sep 2012. **Exploring the behaviour of base classifiers in credit scoring ensembles**. Expert Systems with Applications, v.39, n°11, pp 10244-10250, doi: 10.1016/j.eswa.2012.02.092.

APÊNDICE

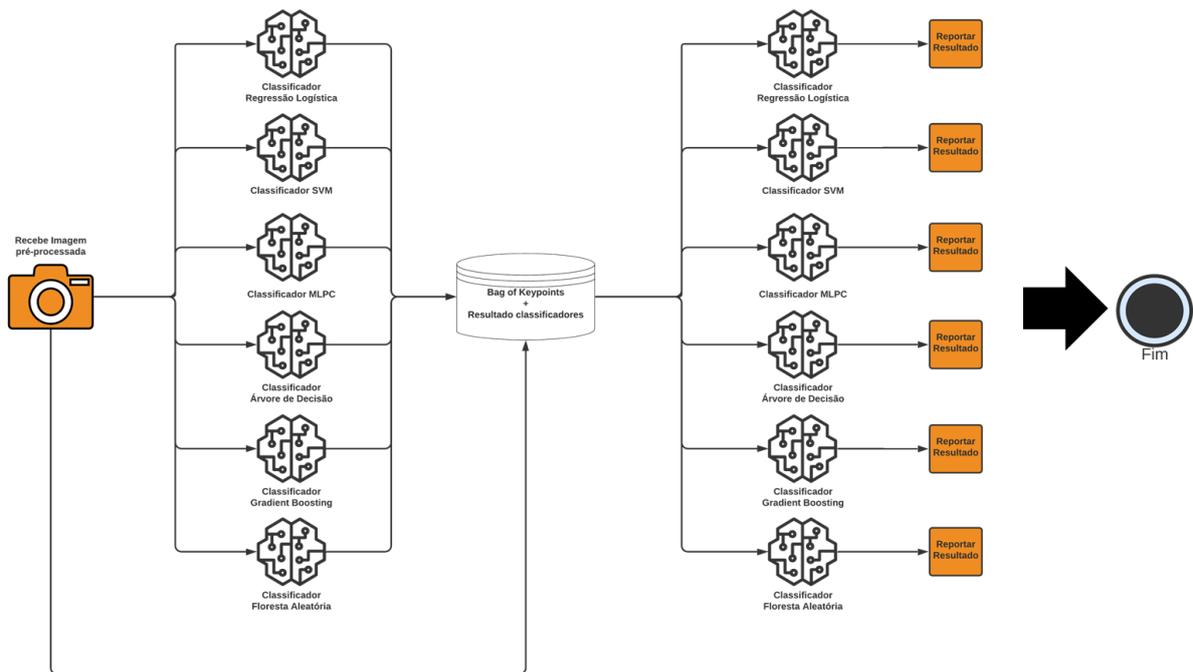


Figura A.1 – Exemplo de algoritmo proposto para trabalho futuro para utilização da técnica de *ensemble learning – stacking classifier* aliado a diversos classificadores distintos.

ANEXO

Câmara Inspeção Endoscópica Android

2m de cabo, câmera de 7 milímetros a prova d'água endoscópica USB e Android com 6 LEDs com iluminação ajustável, assista direto no celular.

CARACTERÍSTICAS

Endoscópio USB com um tubo de inserção flexível;

Pode ser facilmente operado por ligar diretamente no computador ou celular através da porta usb;

Alimentado por USB 2.0. com cabo de 2 m de comprimento;

Diâmetro da câmara é de 7 milímetros / 0.28in, com 6 LEDs ao redor da lente para iluminar a área de inspeção;

A cabeça de câmara e o cabo são resistentes à água, permitindo o operador trabalhar em vários tipos de ambientes;

Pode tirar fotos e gravar vídeos através do seu celular, computador ou laptop facilmente com o software incluído.

ESPECIFICAÇÕES

Diâmetro Câmera: 7 milímetros

Comprimento do cabo: 2 m

Resolução: 640 * 480

Taxa de quadros: 30 fps

Pixels: 300k pixels

Ampla ângulo de visão visual: 67 °

Distância focal: 4cm

Foto formato: jpg

Formato de vídeo: avi

Light: 6 LED branco ajustável

Interface: interface USB 2.0

Sistemas de apoio: Android / Windows 2000 / xp / win V2.6 08/07 / Windows Vista / Linux

Tabela A.1 – Características técnicas do Boroscópio USB.