

Detecção em Tempo Real do *Pop* do Café Durante a Torrefação

Rennan A. Cardoso* Flávio M. Borém**
Bruno Henrique G. Barbosa***

* Programa de Pós-graduação em Engenharia de Sistemas e Automação, Universidade Federal de Lavras, MG (e-mail: rennanalves@yahoo.com.br)

** Departamento de Engenharia Agrícola, Universidade Federal de Lavras, MG, (e-mail: flavioborem@ufla.br)

*** Departamento de Automática, Universidade Federal de Lavras, MG, (e-mail: brunohb@ufla.br)

Abstract: The sounds emitted by the popping coffee during the roasting can be used to assist the control of the roasting process. A pop detection system is here designed to operate on small horizontal rotary drum roasters in real time. To design the system, several sets of sound samples, recorded during various roasting, were selected and separated into two classes: with the presence of *pop*) and without the presence of *pop*). Characteristics were extracted from the data set, using second, third and fourth order cumulants, RMS (Root Mean Square) and extraction of higher value (peak value). After a pre-processing of the data, the Fisher discriminant was implemented to select the two most important characteristics among those obtained and, later, two distinct classifiers were evaluated: Bayesian and Perceptron. With 100% classification accuracy during test, the Perceptron classifier was selected to compose the *pop*) detector. The system was implemented in labview to evaluate sounds from roasting. Finally, a real-time evaluation showed good accuracy of the proposed detector.

Resumo: Os sons emitidos pelo estalo do café (estouro dos grãos de café também chamado de *pop*) durante a torrefação podem ser utilizados para auxiliar o controle do processo de torra do mesmo. Um sistema de detecção de *pop* foi projetado neste trabalho para atuar em torradores de tambor rotativo horizontal de pequeno porte, em tempo real. Para projetar o sistema, vários conjuntos de amostras de sons, gravados durante diversas torrefações, foram selecionados e separados em duas classes: com presença de *pop* e sem a presença de *pop*. Características foram extraídas a partir do conjunto de dados, utilizando cumulantes de segunda, terceira e quarta ordem, RMS (Root Mean Square) e extração de maior valor (valor de pico). Após um pré-processamento dos dados, o discriminante Fisher foi implementado para selecionar as duas características mais importantes dentre as obtidas e, posteriormente, dois classificadores distintos foram avaliados: Bayesiano e Perceptron. Com 100% de acerto durante teste, o classificador do tipo Perceptron foi o selecionado para compor o detector de *pop*. O sistema foi implementado em labview para avaliar sons advindos de torrefações. Por fim, uma avaliação feita em tempo real mostrou boa acurácia do detector proposto.

Keywords: Coffee roasting, pop detection, Neural network perceptron.

Palavras-chaves: Torrefação de café, detecção de pop, rede neural, inteligência artificial.

1. INTRODUÇÃO

O processo de torrefação é uma etapa crucial para a produção de café, pois é onde desenvolvem as propriedades organolépticas (aroma, sabor e cor), responsáveis pela qualidade da bebida (Hernández et al., 2008), uma vez que antes da torrefação os grãos não possuem indícios de aroma e sabor, característicos da bebida (Eggers and Pietsch, 2001). O objetivo da torrefação, portanto, é alterar as propriedades químicas dos grãos, utilizando

um aquecimento controlado, para que o aroma e o sabor desejado sobressaia (Leme et al., 2019).

A torrefação pode ser dividida em três estágios: secagem, pirólise e resfriamento. A etapa de secagem é caracterizada pela liberação de água, compostos voláteis e uma mudança suave da cor. Durante essa fase, a cor dos grãos muda de verde para amarelo. A segunda etapa é caracterizada pelas reações de pirólise, que acarreta alterações das composições químicas e físicas dos grãos, bem como a produção de gases, responsáveis pelo aroma característico do café torrado (Hernández et al., 2007). Inicialmente nessa fase, a cor dos grãos muda de amarelo para marrom claro e um inchaço dos grãos é observado, devido ao acúmulo de gases.

* Os autores gostariam de agradecer à CAPES, CNPq e FAPEMIG pelo suporte financeiro.

No decorrer dessa fase, o inchaço dos grãos aumentam até os grãos romperem, formando um fenômeno conhecido com *pop* (Wilson, 2014). Durante o período de *pop* do café é observado uma mudança intensa da colorações dos grãos e, portanto, deve ser planejado o fim da torra. Após o fim da torra, o café deverá ser arrefecido para evitar a torrefação indesejada dos grãos (Sivetz and Desrosier, 1979). Portanto, o arrefecimento constitui a ultima etapa da torrefação.

A determinação do perfil de temperatura e tempo utilizados durante o processo de torrefação é de suma importância, pois o sabor final é determinado por este perfil, tanto quanto as mudança de todas as outras variáveis físicas dos grãos (Baggenstoss et al., 2008). Portanto, durante a torrefação, para se obter um produto final com a qualidade desejada, o operador do torrador controla, normalmente de forma manual, a temperatura e planeja o final da torra, utilizando inspeções sensitivas que são perceptíveis durante as alterações dos grãos de café: alteração de cor, tamanho, textura dos grãos e fenômenos sonoros decorrentes do rompimento dos grãos (*pop*). As análises de cor e som são as preferidas pelos operadores, pois são as alterações mais evidentes. Este tipo de controle carrega inúmeras incertezas advindas da inspeção sensitiva e pode produzir cafés com qualidade diferente da desejada (Mahendran et al., 2012). De fato, a cor dos grãos do café também é importante para sua comercialização (de Oliveira et al., 2016). Portanto, um monitoramento em tempo real dessas variáveis é idealmente requerido.

Wilson (2014) utilizou um tipo de análise para identificar o *pop* do café a partir dos sons advindos da torrefação. Durante o experimento foram avaliados dois arquivos de som de torrefação. Análises indicaram que os sinais dos sons do *pop* podem ser identificados aplicando uma limiar na amplitude do sinal de sons da torrefações. Portanto, concluíram que um simples classificador que atua na amplitude do sinal de som pode ser usado para projetar um detector de *pop* em tempo real.

O objetivo deste trabalho foi desenvolver um detector em tempo real de *pop* que, ao considerar outras características além da amplitude do sinal de som, possa ser mais robusto a sons (distúrbios) externos presentes no ambiente onde a torrefação está sendo executada. Para tal, características de eventos com ou sem a presença de *pop* foram extraídas de sinais de som, gravados durante torrefações, e um classificador foi desenvolvido utilizando as melhores características. O projeto do detector de *pop* será explicado detalhadamente nas próximas seções.

2. MATERIAIS E MÉTODOS

2.1 Sistema de aquisição de som

Um microfone (Weile 301mv Mv Pc Lan House) conectado à placa de som de um computador pessoal foi usado como componente de *hardware* do sistema de aquisição. Conforme pode ser observado na figura 1, o microfone foi posicionado a uma distância de 10 mm do torrador de tambor rotativo horizontal (marca ATILLA, modelo gold de capacidade de 10 kg).




Figura 1. Posição dos componentes de aquisição em relação ao torrador.

Um *software* implementado em LabVIEW 2016 foi utilizado para fazer aquisição do som. A figura 2 mostra o fragmento do fluxo de dados do processo de aquisição dos sons utilizados no projeto do detector. Esse *software* tem a vantagem de ser desenvolvido em um ambiente gráfico amigável que permite aquisição de sinal e processamento de dados em tempo real (Martin et al., 2006). Os sons foram armazenados no disco rígido do computador pessoal em formato wav (do inglês *Waveform Audio File Format*), em uma frequência de 8 kHz e resolução de 16 bits.

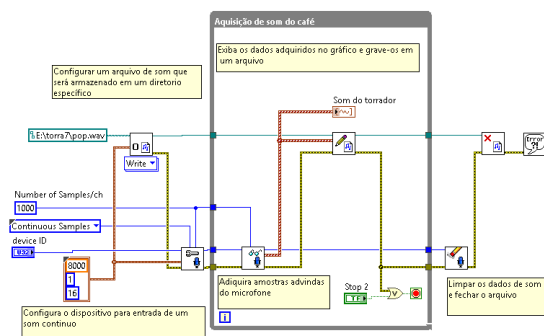


Figura 2. Fragmento do programa de aquisição de sons.

A partir de sons gravados durante 8 torrefações, um especialista selecionou diferentes janelas (vetores de dados) contendo um número de 50 amostras (cerca de 6,25ms) e atribuiu cada janela a uma das classes pré-determinadas: com *pop* e sem *pop*. As janelas foram escolhidas de forma a representar fielmente as duas classes. As Figuras 3 e 4 ilustram eventos de cada classe selecionados aleatoriamente do conjunto de janelas. É importante observar que distúrbios sonoros no ambiente podem provocar a presença de sinais sonoros com alta amplitude mas que não possuem *pop*, justificando a inserção de outras características do sinal para a obtenção de um detector de *pop* mais robusto a estes distúrbios, diferente do proposto em (Wilson, 2014). No total foram obtidas 110 janelas com *pop* e a mesma quantidade para as sem *pop* para o projeto do detector e 33 janelas de cada para validação do mesmo.

2.2 Projeto do detector de *pop*

Após a aquisição do som, o sistema de detecção de *pop* foi projetado. Os estágios da construção do modelo estão resumidos na Figura 5. Após a separação da janela de tamanho 50, os dados são normalizados de forma a obter um sinal com média nula e variância unitária. Após a normalização, são extraídos os cumulantes de segunda, terceira e quarta ordem e, a partir de um destes, é




Figura 3. Evento com presença de *pop*.

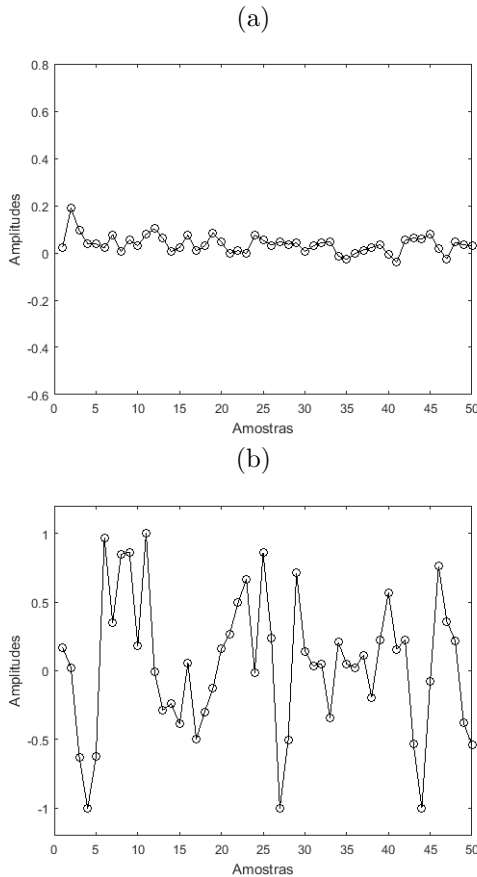


Figura 4. Eventos sem a presença de *pop*. (a) som normal sem *pop* e (b) som com distúrbios sonoros no ambiente mas sem *pop*.

aplicado um detector simples de limiar. Caso este detector já classifique a janela como uma sem presença de *pop*, o processo de detecção é finalizado. Caso contrário, o discriminante de Fisher é aplicado utilizando tanto os cumulantes extraídos quanto os valores de RMS (do inglês *Root Mean Square*) e de pico do sinal, estes dois últimos obtidos da janela de dados sem normalização. As duas características mais importantes segundo o discriminante de Fisher são utilizadas pelo classificador (Bayesiano ou Perceptron) de forma a prover a detecção ou não de *pop*. É importante mencionar que o discriminante de Fisher é aplicado apenas durante o projeto do detector e não

mais durante sua implementação em tempo real. Além disso, apenas uma ou três características são extraídas durante o processo de detecção em tempo real, uma se apenas o detector de limiar for executado e três caso o classificador seja também acionado. Isso faz com que o detector seja muito rápido de ser executado, tornando-o apto para tarefas em tempo real. Cada uma destas etapas serão detalhadas nas seções que seguem.

Extração de características Uma vez que janelas representativas de cada classe foram selecionadas, é necessário encontrar as características que melhor diferem a classe com *pop* em relação à classe sem *pop*.

Não existem características ideais que descrevem os conjuntos de dados pertencentes a um sistema e, portanto, a busca por características representativas de qualquer sistema é um tema de pesquisa em aberto (Nagata et al., 2020). Assim, cumulantes de segunda, terceira e quarta ordem em conjunto com o RMS e valor de pico foram utilizados como características do conjunto de janelas.

Cumulantes de segunda, terceira e quarta ordem Para o cálculo dos cumulantes, as janelas foram normalizadas com média nula e variância unitária. Segundo (Mendel, 1991) o cálculo dos cumulantes de segunda, terceira e quarta ordem para um vetor de comprimento finito pode ser expresso como (Naves et al., 2016; Guedes et al., 2016):

$$C_{2,x}(i) = \frac{2}{N} \sum_{n=0}^{N-1} X[n] X[n+i] \quad (1)$$

$$C_{3,x}(i) = \frac{2}{N} \sum_{n=0}^{N-1} X[n] X^2[n+i] \quad (2)$$

$$C_{4,x}(i) = \frac{1}{N} \sum_{n=0}^{\frac{N}{2}-1} X[n] X^3[n+i] - \frac{3}{\left(\frac{N}{2}\right)^2} \sum_{n=0}^{\frac{N}{2}-1} X[n] X[n+i] \cdot \sum_{n=0}^{\frac{N}{2}-1} X^2[n] \quad (3)$$

em que i é o i -ésimo atraso, e $X[n]$ é o n -ésimo elemento do vetor X .

Devido a perda de informação que ocorre quando um valor maior que zero é usado, uma adaptação das equações (1, 2 e 3) propostas por (Ribeiro and Pereira, 2007) é descrita a seguir:

$$C_{2,x}(i) = \frac{1}{N} \sum_{n=0}^{N-1} X[n] X[\text{mod}(n+i, N)] \quad (4)$$

$$C_{3,x}(i) = \frac{1}{N} \sum_{n=0}^{N-1} X[n] X^2[\text{mod}(n+i, N)] \quad (5)$$

$$C_{4,x}(i) = \frac{1}{N} \sum_{n=0}^{N-1} X[n] X^3[\text{mod}(n+i, N)] - \frac{1}{N^2} \sum_{n=0}^{N-1} X[n] X[\text{mod}(n+i, N)] \cdot \sum_{n=0}^{N-1} X^2[n] \quad (6)$$

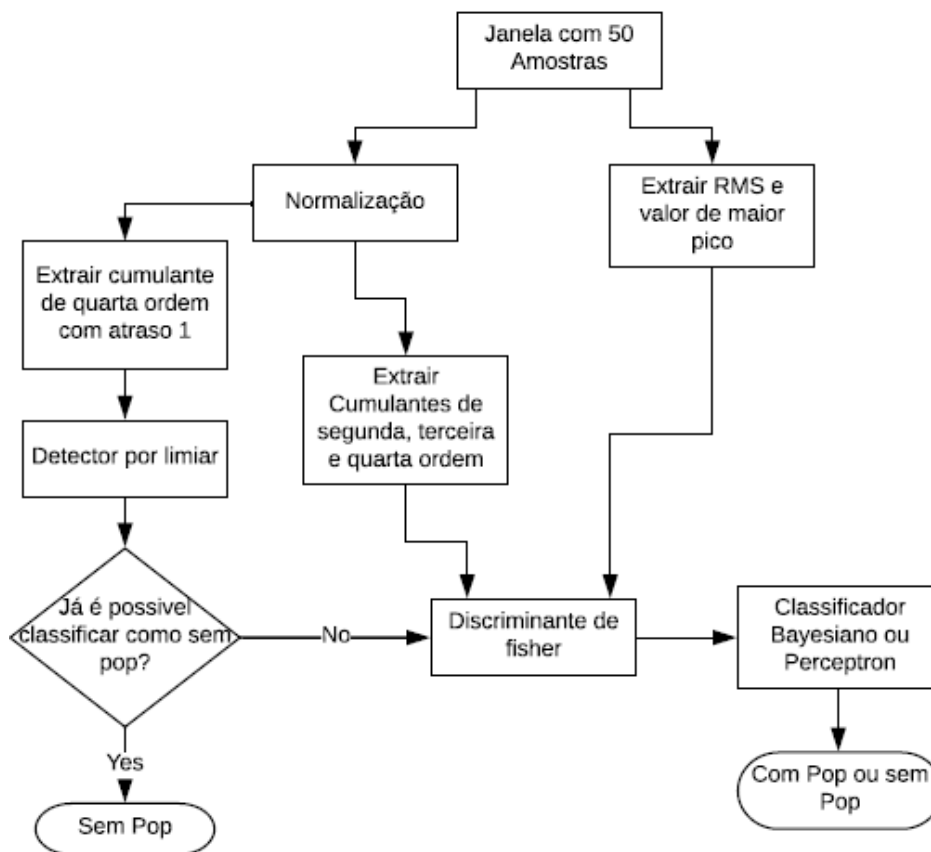


Figura 5. Método de detecção proposto.

em que $mod(n + i, N)$ é o resto inteiro da divisão de $n + i$ por N . A partir das equações (4, 5 e 6) foram calculados (26, 50 e 50) cumulantes, respectivamente para cada janela de dados.

RMS O valor de RMS de um vetor de amostras f é calculado por:

$$RMS(f) = \sqrt{\frac{\sum_{n=1}^N (f[n] - \bar{f})^2}{N - 1}} \quad (7)$$

sendo N o número de amostras e \bar{f} sua média.

Extrator de máximo valor O extrator aqui tratado busca de forma exaustiva o maior valor pertencente a um conjunto de dados. Esse tipo de característica extraída de um sinal informa que um evento pertence a uma classe a partir da amplitude de apenas uma amostra, como realizado em (Wilson, 2014). Normalmente esse tipo de característica é usada quando a principal informação de conjunto de dados está resumida em uma amostra.

Detector por Limiar Um detector simples por limiar foi utilizado para melhorar a seletividade das janelas de acordo com o valor de apenas uma característica extraída, fazendo com que várias janelas que não tivessem a presença de *pop* fossem prontamente detectadas, tornando o próximo detector a ser implementado com outras características o mais simples possível também, transformando essa abordagem em uma do tipo dividir para conquistar. A exclusão de janelas sem presença de *pop* justifica-se pelo

fato de que as mesmas são maioria em um processo de torrefação. Este algoritmo utiliza a inequação apresentado a seguir para selecionar as janelas de interesse:

$$\frac{1}{N} \sum_{n=0}^{N-1} X[n] X^3[mod(n + 1, N)] - \frac{1}{N^2} \sum_{n=0}^{N-1} X[n] X[mod(n + 1, N)] < 0,3 \quad (8)$$

$$\sum_{n=0}^{N-1} X^2[n] < 0,3$$

em que

$$\frac{1}{N} \sum_{n=0}^{N-1} X[n] X^3[mod(n + 1, N)] - \frac{1}{N^2} \sum_{n=0}^{N-1} X[n] X[mod(n + 1, N)] < 0,3 \quad (9)$$

$$\sum_{n=0}^{N-1} X^2[n]$$

é o cumulante de quarta ordem com atraso um. Este limiar foi obtido de forma empírica, analisando sons obtidos de diversas execuções do processo de torrefação. Esse cumulante possui valor próximo ao da curtose (cumulante de quarta ordem com atraso nulo), propriedade estatística muito utilizada para detectar se há *outliers* em um conjunto amostral (T. DeCarlo, 1997). A presença de um *pop* muitas

vezes pode ser interpretada como a de um *outlier*, uma vez que sua ocorrência é rápida e pontual dentro de uma janela. Em um evento onde não há *pop* como apresentado na figure 4 (a) a função de densidade de probabilidade que representa as 50 amostras é próxima de uma gaussiana, esta aproximação a uma distribuição gaussiana pode ser inferida pela curtose.

Discriminante Linear de Fisher Para reduzir a quantidade de características extraídas e, conseqüentemente, reduzir o custo computacional, o discriminante linear de Fisher foi utilizado para selecionar as duas características que melhor diferenciam as classes após a passagem das mesmas pelo detector de limiar supramencionado.

O discriminante linear de Fisher consiste em quantificar as características em função de sua média e variância em todo conjunto de dados disponível. O discriminante pode ser expresso pela fórmula (Barbosa and Ferreira, 2013):

$$DF_i = (\mu_{c_{i,A}} - \mu_{c_{i,B}})^2 \odot \frac{1}{\sigma_{c_{i,A}}^2 + \sigma_{c_{i,B}}^2} \quad (10)$$

em que DF_i é o i -ésimo cálculo do Discriminante de Fisher, $\mu_{c_{i,A}}$, $\mu_{c_{i,B}}$, $\sigma_{c_{i,A}}^2$ e $\sigma_{c_{i,B}}^2$ são as médias e variâncias da característica para as classes A e B, respectivamente. O símbolo \odot refere-se ao produto de Hadamard.

Foram avaliadas 128 características, sendo 126 pertencentes aos cumulantes de segunda, terceira e quarta ordem e duas pertencentes aos valores de RMS e valor de pico.

Após a seleção das duas melhores características, duas ferramentas de classificação foram avaliadas: classificador Bayesiano e classificador Perceptron. Foi observado que duas características são suficientes para distinguir as classes estudadas, como será apresentado na Seção 3.

Classificador Bayesiano O Classificador Bayesiano modela a distribuição de probabilidades de um conjunto de dados já rotulados e classifica dados desconhecidos, escolhendo a classe com maior probabilidade posterior (MAP) (de Oliveira et al., 2016). A classe é escolhida de forma a satisfazer a seguinte equação:

$$H_{MAP} = \arg_{H_i \in H} \max \rho(x|H_i) \rho(H_i) \quad (11)$$

em que $\rho(x|H_i)$ e $\rho(H_i)$ são função de densidade de probabilidade condicional baseada na distribuição Gaussiana e x é um conjunto de características correspondentes às classes com *pop* e sem *pop*, respectivamente. Maiores detalhes sobre este classificador são obtidas em (Mitchell et al., 1997).

Classificador Perceptron A arquitetura de um classificador perceptron abordada neste trabalho é constituída de um elemento chamado neurônio perceptron, este é formado de um vetor de entradas (duas características definidas segundo critério de Fisher) $x = [x1, x2]$, um vetor de pesos $w = [w1, w2]$, um valor de limiar b e uma saída y dada conforme a equação (Haykin and Network, 2004):

$$y = \rho(w.x + b) \quad (12)$$

em que $\rho(\cdot)$ é a função de ativação, que foi adotada como função degrau.

Durante a fase de treinamento do classificador os seguintes passos são aplicados (Haykin and Network, 2004):

- (1) Atribuir rótulos binários para as características pertencentes a cada classe (com *pop* e sem *pop*).
- (2) Computar os rótulos y_i fornecido pelo perceptron, conforme a Equação 12.
- (3) Atualizar o vetores w e b segundo as equações:

$$w_j(t) = w_j(t-1) + \alpha x(d-y) \quad (13)$$

$$b(t) = b(t-1) + \alpha \quad (14)$$

em que α corresponde ao ganho de adaptação ou passo de aprendizagem e d a saída desejada.

- (4) Retornar ao segundo passo até que ocorra 1000 iterações.

Após a fase de treinamento, a seguinte equação é utilizada para separar as classes:

$$f(x) = x_1.w_1 + x_2.w_2 + b \quad (15)$$

sendo que quando o valor de f for menor do que zero, a classe atribuída é a com *pop*, caso contrário é atribuída a classe sem *pop* para o conjunto de entradas utilizado.

3. RESULTADOS

Esta seção apresenta primeiramente os resultados do discriminante de Fisher e dos classificadores Bayesiano e Perceptron e, em seguida, os detalhes e resultados obtidos na fase de implementação do detector de *pop* em tempo real no *software* Labview. O detector simples de limiar obteve 100% de acerto tanto em dados de treino como em validação. A partir da sua aplicação, são analisadas as próximas etapas: seleção de características e classificadores.

3.1 Resultados da Seleção de Características

A partir da aplicação do discriminante de Fisher, duas características foram escolhidas, conforme ilustrado na figura 6: cumulante de terceira ordem com atraso 49 e o valor de pico. É interessante observar que realmente o valor de pico é uma característica de suma importância, como constatado por (Wilson, 2014). No entanto, também é importante estar claro que esta seleção de características é obtida apenas das janelas que passaram pelo detector simples de limiar, caso contrário o valor de pico poderia deixar de ser tão relevante como o ocorrido.

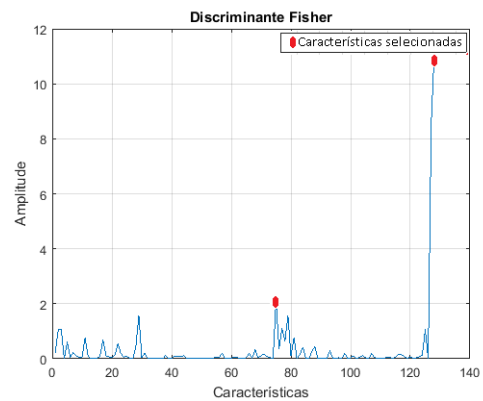


Figura 6. Representação do Discriminante Fisher para as 128 características dos dados de treino.

3.2 Resultados da Classificação

As duas características selecionadas pelo discriminante de Fisher foram utilizadas como entradas dos classificadores propostos. Para avaliação dos mesmos, o desempenho foi analisado em dados de treino e validação.

Para definir qual dos dois classificadores propostos será utilizado para classificar os dois tipos de som advindos da torrefação em um sistema de detecção em tempo real, foi verificada a porcentagem de acerto de cada um. O classificador Bayesiano obteve 98,70% e 98,48% de acerto, enquanto que o Perceptron obteve 100% e 100%, para treino e validação, respectivamente.

As figuras 7 (a) e (b) ilustram graficamente a distribuição de probabilidades obtida pelo classificador Bayesiano. Círculos representam a função de densidade de probabilidade de cada classe.

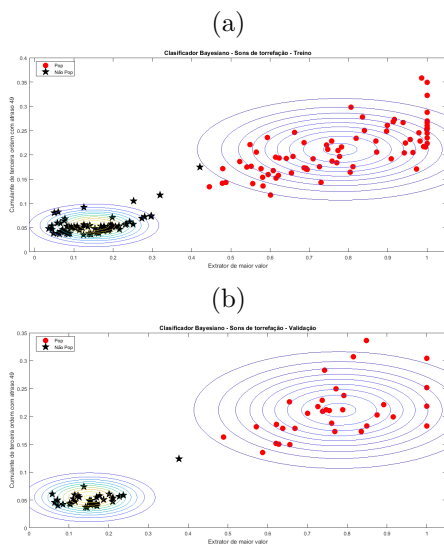


Figura 7. Simulação do classificador Bayesiano com: (a) dados de treinamento; (b) dados de validação.

A região de separação do classificador Perceptron é apresentada nas figuras 8 (a) e (b). Os valores encontrados para os parâmetros w_1 , w_2 e b (vide Equação 15) são, respectivamente: -3,83, -0,75 e 1,44.

Como pode ser observado em ambos classificadores, as duas características selecionadas realmente ajudam a separar bem as classes, tornando o processo de detecção de *pop* bem sucedido.

3.3 Resultados do detector de *pop* em tempo real

O detector de *pop* foi implementado em LabVIEW, pois essa ferramenta permite a aquisição e processamento do som em tempo real, com alta confiabilidade.

Por sua simplicidade de implementação e pelo seu desempenho tanto em dados de treinamento como nos de validação, o classificador Perceptron foi implementado no Labview, em conjunto com o sistema de detecção de limiar simples, conforme apresentado na figura 5. Portanto, os resultados de classificação descritos no item 3.2, também se aplicam à implementação em Labview.

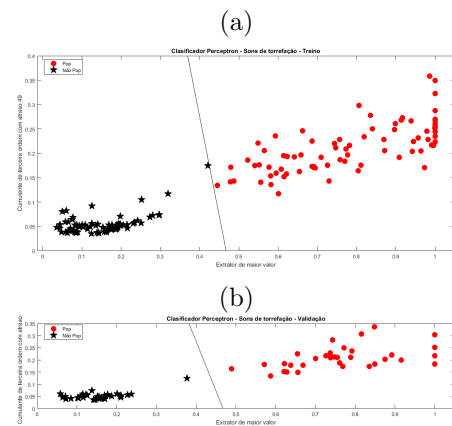


Figura 8. Simulação do classificador Perceptron com: (a) dados de treinamento e (b) dados de validação.

A figura 9 mostra parte do sistema de detecção de *pop*. Esta implementação foi possível devido ao baixo custo computacional que a metodologia usada proporciona.

Para avaliar, em tempo real, a eficiência do método proposto, foi utilizado um áudio gravado durante a torrefação de 5 kg de café cru. Esse áudio foi adquirido com a mesma frequência de amostragem e resolução usadas durante o projeto do classificador. Uma representação do áudio foi ilustrada na figura 10, em que os possíveis *pops* foram identificados por especialistas e a saída do detector correspondente também foi apresentada.

Dessa forma, pode-se inferir que o detector de *pop*, durante uma simulação em tempo real, alcançou uma classificação semelhante à obtida por inspeção sonora durante a torrefação, validando a metodologia empregada.

4. CONCLUSÕES

A identificação do *pop* por inspeção sonora é uma das alternativas que contribui para a identificação do grau de torra do café, durante a torrefação. Este trabalho procurou suprir a ausência de um sistema de tempo real de detecção de *pop*, em um torrador de tambor rotativo horizontal, que utilizasse apenas análises do som adquirido durante a torrefação.

O objetivo do detector é emular a identificação do *pop* que é feita pelo operador do torrador. Portanto, o sistema desenvolvido é capaz de detectar todos os *pops* representativos e, não identificar como *pop*, todos os outros sons que indesejavelmente podem ser gravados durante a torrefação, como ruídos do ambiente.

REFERÊNCIAS

- Baggenstoss, J., Poisson, L., Kaegi, R., Perren, R., and Escher, F. (2008). Coffee roasting and aroma formation: application of different time- temperature conditions. *Journal of Agricultural and Food Chemistry*, 56(14), 5836–5846.
- Barbosa, B.H.G. and Ferreira, D.D. (2013). Classification of multiple and single power quality disturbances using a decision tree-based approach. *Journal of Control, Automation and Electrical Systems*, 24(5), 638–648.
- de Oliveira, E.M., Leme, D.S., Barbosa, B.H.G., Rodarte, M.P., and Pereira, R.G.F.A. (2016). A computer vision

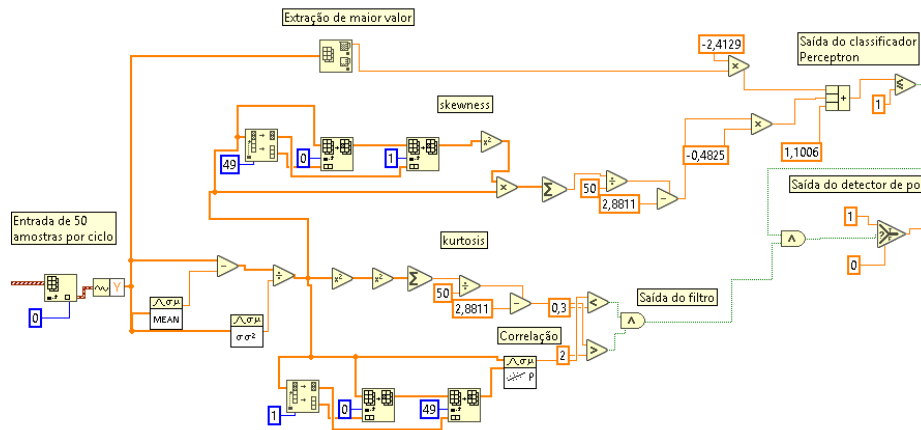


Figura 9. Fragmento do programa onde se encontra o classificador.

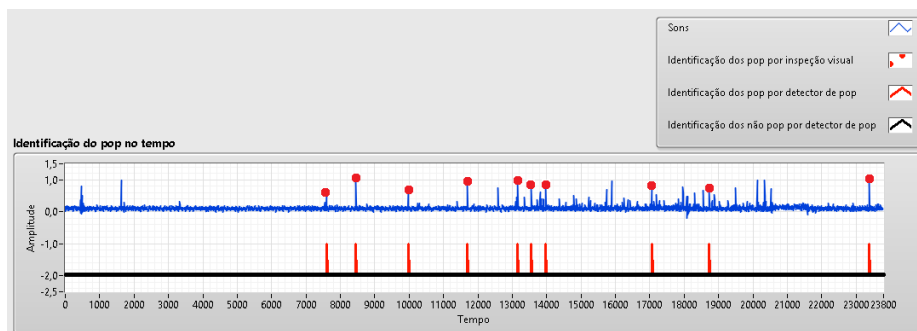


Figura 10. Simulação de detector em tempo real

system for coffee beans classification based on computational intelligence techniques. *Journal of Food Engineering*, 171, 22–27.

Eggers, R. and Pietsch, A. (2001). Technology i: roasting. *Coffee: recent developments*, 90–107.

Guedes, J.D., Ferreira, D.D., and Barbosa, B.H. (2016). A non-intrusive approach to classify electrical appliances based on higher-order statistics and genetic algorithm: a smart grid perspective. *Electric Power Systems Research*, 140, 65–69.

Haykin, S. and Network, N. (2004). A comprehensive foundation. *Neural networks*, 2(2004), 41.

Hernández, J., Heyd, B., Irlés, C., Valdovinos, B., and Trystram, G. (2007). Analysis of the heat and mass transfer during coffee batch roasting. *Journal of Food Engineering*, 78(4), 1141–1148.

Hernández, J., Heyd, B., and Trystram, G. (2008). Prediction of brightness and surface area kinetics during coffee roasting. *Journal of Food Engineering*, 89(2), 156–163.

Leme, D.S., da Silva, S.A., Barbosa, B.H.G., Borém, F.M., and Pereira, R.G.F.A. (2019). Recognition of coffee roasting degree using a computer vision system. *Computers and Electronics in Agriculture*, 156, 312–317.

Mahendran, R., Jayashree, G., and Alagusundaram, K. (2012). Application of computer vision technique on sorting and grading of fruits and vegetables. *J Food Process Technol S1-001*. doi, 10, 2157–7110.

Martin, M.E., Wabuyele, M.B., Chen, K., Kasili, P., Panjehpour, M., Phan, M., Overholt, B., Cunningham, G., Wilson, D., DeNovo, R.C., et al. (2006). Development of an advanced hyperspectral imaging (hsi) system with

applications for cancer detection. *Annals of biomedical engineering*, 34(6), 1061–1068.

Mendel, J.M. (1991). Tutorial on higher-order statistics (spectra) in signal processing and system theory: Theoretical results and some applications. *Proceedings of the IEEE*, 79(3), 278–305.

Mitchell, T.M. et al. (1997). Machine learning. 1997. *Burr Ridge, IL: McGraw Hill*, 45(37), 870–877.

Nagata, E.A., Ferreira, D.D., Bollen, M.H., Barbosa, B.H., Ribeiro, E.G., Duque, C.A., and Ribeiro, P.F. (2020). Real-time voltage sag detection and classification for power quality diagnostics. *Measurement*, 164, 108097.

Naves, R., Barbosa, B.H., and Ferreira, D.D. (2016). Classification of lung sounds using higher-order statistics: A divide-and-conquer approach. *Computer Methods and Programs in Biomedicine*, 129, 12–20.

Ribeiro, M.V. and Pereira, J.L.R. (2007). Classification of single and multiple disturbances in electric signals. *EURASIP Journal on Advances in Signal Processing*, 2007(2), 15–15.

Sivetz, M. and Desrosier, N.W. (1979). Coffee technology. Avi Westport, CT.

T. DeCarlo, L. (1997). On the meaning and use of kurtosis. *Psychological Methods*, 2(3), 292–307.

Wilson, P.S. (2014). Coffee roasting acoustics. *The Journal of the Acoustical Society of America*, 135(6), EL265–EL269.