

UMA REVISÃO SISTEMÁTICA SOBRE ALGORITMOS DE *MACHINE LEARNING* PARA PREDIÇÃO DA QUALIDADE DE ALIMENTOS BASEADA EM ANÁLISE DE COR

ARLIENE DO SOCORRO BATISTA DOS SANTOS¹; RENIRES DOS SANTOS TEIXEIRA²; LEONARDO NORA²; PATRICIA A. JAKES³

¹*Universidade Federal de Pelotas – arlenebatista@gmail.com*

²*Universidade Federal de Pelotas – reniresantos@gmail.com*

²*Universidade Federal de Pelotas – l.nora@me.com*

³*Universidade Federal de Pelotas – patricia.jakes@gmail.com*

1. INTRODUÇÃO

Machine Learning (ML) ou Aprendizado de Máquina é um subconjunto da Inteligência Artificial (IA) que permite que os computadores aprendam com dados, tornando-os capazes de resolver problemas complexos e fazer previsões com mais precisão, sem a necessidade de programar todas as regras manualmente (DENG; CAO; HORN, 2021). Em outras palavras, são fornecidos exemplos de tarefas ao computador e ele aprende a identificar padrões para melhorar seu desempenho de forma autônoma.

As técnicas de aprendizado de máquina têm diversas aplicações na indústria alimentícia. Com os avanços tecnológicos, os métodos tradicionais de avaliação da qualidade têm sido complementados ou substituídos por técnicas de ML. Isso tem sido especialmente observado quando essas técnicas são associadas à análise de cor, devido à sua capacidade de lidar com informações irrelevantes, extrair variáveis relevantes e construir modelos de calibração (LIN, *et al.*, 2023).

A cor é um atributo essencial que influencia a percepção de frescor e qualidade dos alimentos pelos consumidores. A cor é influenciada por uma série de fatores, desde a sua composição natural até as condições de armazenamento. Pigmentos, processamento, embalagem e armazenamento são elementos que, em conjunto, definem a tonalidade e a intensidade da cor de um produto alimentício. Assim, medir o perfil de cor dos alimentos pode ser usado para controlar a qualidade dos alimentos e examinar as mudanças na sua composição química (PANDISELVAM *et al.*, 2020).

Os métodos de aprendizado de máquina tornaram-se ferramentas úteis que, em conjunto com dispositivos de detecção para avaliação da qualidade, permitem uma avaliação rápida e eficaz da qualidade dos produtos alimentícios (NTURAMBIRWE; OPARA, 2024). Diante do exposto, o presente trabalho teve por objetivo sistematizar resultados de estudos científicos sobre o uso de *Machine Learning* para predição da qualidade dos alimentos baseada na cor.

2. METODOLOGIA

A revisão foi conduzida utilizando as bases de dados *Google Scholar*, *ScienceDirect* e *Web of Science*, com foco em publicações dos últimos cinco anos (2020 a 2024). Em cada base, usou-se diferentes estratégias. No *Google Scholar* foram utilizadas as palavras: *machine learning food quality* and *"color food"*, que retornou 96 resultados. Na plataforma *ScienceDirect*, a mesma busca foi realizada

com as palavras: '*machine learning food quality and color analysis in food and non-invasive food quality assessment*', refinado por Área Temática: Ciência da Computação e Título do Periódico: Computadores e Eletrônica na Agricultura que retornou 69 resultados. Na plataforma *Web of Science*, foram usadas as palavras: '*machine learning food quality and color analysis in food*', refinado por acesso aberto, que retornou 68 resultados. Foram selecionados 24 artigos em virtude da relevância e da adequação dos títulos e resumos ao tema abordado. Destes, 10 artigos foram escolhidos com base nos tipos de alimentos avaliados, na obtenção dos atributos das cores, e nos resultados obtidos.

3. RESULTADOS E DISCUSSÃO

A revisão dos estudos realizados demonstrou que a ML tem sido aplicada em uma variedade de produtos alimentícios, incluindo frutas, carnes e produtos processados. Os principais algoritmos tradicionais de aprendizado de máquina utilizados em pesquisas alimentares são *Partial Least Squares Regression* (PLSR), *Multiple Linear Regression* (MLR), *k-Nearest Neighbor* (kNN), *Partial Least Square Discriminant Analysis* (PLS-DA), *Random Forest* (RF), *Soft Independence Modeling Of Class Analogy* (SIMCA), e *Support Vector Machine* (SVM) (KANG *et al.*, 2022).

Basak *et al.* (2022) avaliaram a aplicação de modelos de aprendizado de máquina para a predição de Sólidos Solúveis Totais e pH de morangos utilizando a técnica de processamento de imagens. Os espaços de cor RGB, HSV e HSL foram utilizados como variáveis de entrada para modelos de aprendizado de máquina (MLR e SVM-R). As métricas de desempenho incluíram o Coeficiente de Determinação (R^2) e o Erro Quadrático Médio (RMSE). O modelo SVM-R com o espaço de cor HSV obteve o melhor desempenho, alcançando R^2 de 84,1% para TSS e 78,8% para pH na fase de treinamento, e 79,2% para TSS e 72,6% para pH na fase de teste.

LI, *et al.*, (2024) obtiveram as características de cor do chá verde por meio da tecnologia de visão computacional para capturar imagens das amostras de chá e extrair atributos de cor significativos. Modelos de aprendizado de máquina, como SVM, RF e DT-*Adaboost*, foram aplicados para correlacionar informações de cores com avaliação sensorial e construir modelos de avaliação baseados em cores. Entre eles, o modelo DT-*Adaboost* apresentou a melhor performance, obtendo uma Taxa de Discriminação Correta (CDR) de 98,50%, um valor de Desvio Percentual Relativo (RPD) de 14,827 e Coeficientes de Correlação (R_c e R_p) de 0,999 e 0,995, respectivamente.

Em carnes, a análise de cor com ML auxilia na identificação de sinais de deterioração e na avaliação da qualidade geral. Rady; Adedeji; Watson (2021) utilizaram a técnica de imagem em cores RGB juntamente com algoritmos de aprendizado de máquina para detectar adulterantes vegetais e animais em carne moída. As métricas de cor foram extraídas de diferentes canais de cores (vermelho, verde, azul) e da imagem em níveis de cinza, bem como da saturação na escala de cores HSI. Para medir a acurácia, o estudo empregou diferentes métodos de classificação e regressão. O classificador *Linear Discriminant Analysis* (LDA), combinado com técnicas de ensemble (*bagging*), obteve a melhor precisão de classificação (até 100% usando características selecionadas). A análise também utilizou árvores de regressão para quantificar o nível de adulteração, obtendo

valores de correlação (r) até 98% para todos os recursos, e 94,5% para recursos selecionados, mostrando eficácia na previsão dos níveis de adulterantes.

Em sua pesquisa, Alves *et al.* (2024) propuseram um método rápido, ambientalmente sustentável e preciso para a análise simultânea de sacarose, açúcares redutores, minerais (como cálcio, ferro, zinco, magnésio e manganês) e cor ICUMSA (padrão internacional de cor para produtos de açúcar) em amostras de açúcar mascavo. Para isso, utiliza imagens digitais obtidas por *smartphone* e o algoritmo de aprendizado de máquina *k-Nearest Neighbors* (kNN) para construir modelos preditivos que correlacionam características visuais com propriedades físico-químicas do açúcar mascavo, estratégia conhecida como DIP-kNN. As métricas de desempenho dos modelos preditivos incluíram o coeficiente de determinação (R^2), o erro quadrático médio (RMSE) e o erro absoluto médio (MAE). A abordagem DIP-kNN demonstrou ser mais sustentável em comparação com métodos convencionais. Utilizou-se a métrica AGREE (*Analytical GREENness*) para avaliar o impacto ambiental, na qual o modelo proposto obteve uma pontuação de 0,71, enquanto métodos tradicionais (como HPLC e espectrofotometria UV-VIS) variaram de 0,30 a 0,38.

Hany; Rashwan; Abdelmotilib (2023) apresentaram um novo método de aprendizado de máquina para prever a qualidade e as preferências dos consumidores de iogurte, usando atributos sensoriais e recursos de cor e textura extraídos de imagens de amostras de iogurte. O estudo aplicou quatro métodos de seleção de características: Análise de Componentes Principais (PCA), Análise de Componentes Independentes (ICA), Análise Discriminante Linear (LDA) (supervisionado) e t-SNE (Incorporação de Vizinho Estocástico Distribuído). Além disso, utilizou-se a técnica de classificação *Random Forest* para classificar as amostras em sete categorias de qualidade. O melhor desempenho foi obtido utilizando a técnica de seleção de características LDA, com uma acurácia de 58%, o que indica que foi possível prever, com precisão moderada, a qualidade e as preferências dos consumidores a partir das características sensoriais e de imagem.

Nesse sentido, evidenciou-se que há um consenso crescente sobre a eficácia da ML na análise da qualidade de alimentos através da cor. A segmentação de imagens, a extração de características de cor em diferentes espaços colorimétricos e a aplicação de algoritmos se mostraram ferramentas poderosas para construir modelos preditivos precisos para utilização na indústria de alimentícia. Além disso, a capacidade de quantificar a percepção humana da cor, como demonstrado por Hany; Rashwan; Abdelmotilib (2023) abre novas possibilidades para a otimização de produtos e a garantia da satisfação do consumidor.

4. CONCLUSÕES

Considerando os resultados apresentados nesta revisão, observou-se que a aplicação de técnicas de aprendizado de máquina na avaliação da cor de alimentos demonstra um grande potencial para a indústria alimentícia. As técnicas de ML já estão sendo aplicadas industrialmente na otimização da cadeia de suprimentos, controle de qualidade, personalização de produtos e segurança alimentar (CARVALHO, 2024). Através da aplicação de técnicas de aprendizado de máquina aliada a captura de imagens dos alimentos e obtenção de dados sobre sua cor,

poderá ser possível a construção de modelos preditivos capazes de identificar alterações relacionadas à qualidade e à deterioração, melhorando a segurança alimentar.

5. REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, V. et al. An eco-friendly approach for analysing sugars, minerals, and colour in brown sugar using digital image processing and machine learning. **Food Research International**, v. 191, p. 114673, set. 2024.

BASAK, J. K. et al. Prediction of Total Soluble Solids and pH of Strawberry Fruits Using RGB, HSV and HSL Colour Spaces and Machine Learning Models. **Foods**, v. 11, n. 14, p. 2086, jul. 2022.

CARVALHO, C. Aplicações de Inteligência Artificial na indústria de alimentos. Disponível em: <<https://www.foodconnection.com.br/especialistas/aplicacoes-de-inteligencia-artificial-na-industria-de-alimentos>>. Acesso em: 24 set. 2024.

DENG, X.; CAO, S.; HORN, A. L. Emerging Applications of Machine Learning in Food Safety. **Annual Review of Food Science and Technology**, v. 12, n. Volume 12, 2021, p. 513–538, 25 mar. 2021.

HANY, M.; RASHWAN, S.; ABDELMOTILIB, N. M. A Machine Learning Method for Prediction of Yogurt Quality and Consumers Preferences using Sensory Attributes and Image Processing Techniques. **Machine Learning and Applications: An International Journal**, v. 10, n. 1, p. 1–7, 30 mar. 2023.

KANG, Z. et al. Advances in Machine Learning and Hyperspectral Imaging in the Food Supply Chain. **Food Engineering Reviews**, v. 14, n. 4, p. 596–616, 1 dez. 2022.

LI, J. et al. Rapid Color Quality Evaluation of Needle-Shaped Green Tea Using Computer Vision System and Machine Learning Models. **Foods**, v. 13, n. 16, p. 2516, jan. 2024.

LIN, Y. et al. Applications of machine learning techniques for enhancing nondestructive food quality and safety detection. **Critical Reviews in Food Science and Nutrition**, v. 63, n. 12, p. 1649–1669, 7 maio 2023.

NTURAMBIRWE, J. F. I.; OPARA, U. L. Machine learning applications to non-destructive defect detection in horticultural products. **Biosystems Engineering**, v. 189, p. 60–83, 1 jan. 2020.

PANDISELVAM, R. et al. The influence of non-thermal technologies on color pigments of food materials: An updated review. **Current Research in Food Science**, v. 6, p. 100529, 1 jan. 2023.

RADY, A. M.; ADEDEJI, A.; WATSON, N. J. Feasibility of utilizing color imaging and machine learning for adulteration detection in minced meat. **Journal of Agriculture and Food Research**, v. 6, p. 100251, 1 dez. 2021.