



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE CIÊNCIAS EXATAS E DA NATUREZA
DEPARTAMENTO DE QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM QUÍMICA



DISSERTAÇÃO DE MESTRADO

UM ANALISADOR BASEADO EM VISÃO DE MÁQUINA PARA A
DETERMINAÇÃO DA CONCENTRAÇÃO DE BIOMASSA NO PROCESSO DE
FERMENTAÇÃO CERVEJEIRA

João Vitor Medeiros Mariz



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE CIÊNCIAS EXATAS E DA NATUREZA
DEPARTAMENTO DE QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM QUÍMICA



DISSERTAÇÃO DE MESTRADO

UM ANALISADOR BASEADO EM VISÃO DE MÁQUINA PARA A
DETERMINAÇÃO DA CONCENTRAÇÃO DE BIOMASSA NO PROCESSO DE
FERMENTAÇÃO CERVEJEIRA

João Vitor Medeiros Mariz*

Dissertação de mestrado apresentada como parte dos requisitos para obtenção do título de Mestre em Química, área de concentração Química Analítica, pela Universidade Federal da Paraíba.

Orientador: Prof. Dr. Mário César Ugulino de Araújo

Coorientador: Railson de Oliveira Ramos

***Bolsista do Conselho Nacional de Desenvolvimento Científico e Tecnológico**



João Pessoa
2023

Catálogo na publicação
Seção de Catalogação e Classificação

M343a Mariz, João Vitor Medeiros.

Um analisador baseado em visão de máquina para a determinação da concentração de biomassa no processo de fermentação cervejeira. / João Vitor Medeiros Mariz. - João Pessoa, 2023.

71 f. : il.

Orientação: Mario César Ugulino de Araújo.

Coorientação: Railson de Oliveira Ramos.

Dissertação (Mestrado) - UFPB/CCEN.

1. Fermentação cervejeira. 2. Fermentação alcoólica.
3. Visão de máquina. 4. Processamento de vídeo. 5.
Concentração de biomassa. I. Araújo, Mario César
Ugulino de. II. Ramos, Railson de Oliveira. III. Título.

UFPB/BC

CDU 663.45(043)

Um analisador baseado em visão de máquina para determinação da concentração de biomassa no processo de fermentação cervejaria.

Dissertação de Mestrado apresentada pelo aluno João Vitor Medeiros Mariz e aprovada pela banca examinadora em 20 de dezembro de 2023.

Documento assinado digitalmente
 **MARIO CESAR UGULINO DE ARAUJO**
Data: 20/12/2023 13:18:50-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Mário César Ugulino de Araújo
Departamento de Química – CCEN/UFPB
Orientador/Presidente

Documento assinado digitalmente
 **RAILSON DE OLIVEIRA RAMOS**
Data: 20/12/2023 17:44:48-0300
Verifique em <https://validar.iti.gov.br>

Dr. Railson de Oliveira Ramos
FAPESQ/CNPq-CG-PB
Co-Orientador

Documento assinado digitalmente
 **SOFACLES FIGUEREDO CARREIRO SOARES**
Data: 20/12/2023 18:55:55-0300
Verifique em <https://validar.iti.gov.br>

Dr. Sófacles Figueredo Carreiro Soares
UFPB/JPA-PB
Examinador Externo

Documento assinado digitalmente
 **LUCIANO FARIAS DE ALMEIDA**
Data: 21/12/2023 11:33:50-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Luciano Farias de Almeida
Departamento de Química – CCEN/UFPB
Examinador Interno

Assinaturas da Banca realizada em modo Webconferência, digitalizadas e certificadas pelo Prof. Dr. Mário César Ugulino de Araújo (SIAPE 0334937-3) em 21/12/2023.

*À minha mãe, Auxiliadora, à minha avó,
Josefa, e à toda a minha família, com muito
carinho eu dedico.*

Agradecimentos

- ✚ Ao professor Dr. Mário César Ugulino de Araújo e ao Dr. Railson de Oliveira Ramos, pela orientação e confiança durante a realização desse mestrado;
- ✚ Ao Dr. Sófacles Figueredo e aos professores Edvan Cirino e Luciano Farias, pelas importantes sugestões na construção dessa dissertação;
- ✚ Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pelo aporte financeiro;
- ✚ À Ruth, Tássio, Luciano, Rossana, Diana, Fernanda, Lucas, Manuel, Antônio, Aline, Amanda, Wallis, Wellington, David, Girlene, Paula e à toda família LAQA pelos momentos de conversa e descontração e pelas contribuições diretas ou indiretas na construção deste trabalho;
- ✚ Ao Mestre Robson Santiago, aos monitores Fillipe, Rayssa, Ely e Rafa, e a todos os que fazem a Escola de Capoeira Angola Ao Pé do Baobá, por todo o acolhimento e manutenção da saúde de meu corpo e mente no decorrer dessa jornada;
- ✚ À Bia, Mike, Victor, Jean, Luidy, Lalyson, Clarice, Thiago, Amanda, Vicente e José, meus amigos de Natal – RN, que, apesar da distância, estiveram sempre comigo no compartilhamento das angústias e felicidades;
- ✚ À Edithe Neta, minha companheira, a quem recorri nos momentos mais difíceis;
- ✚ À minha mãe, Auxiliadora, minha avó, Josefa, minhas tias Márcia e Damiana e à toda a minha família, a quem a tudo eu sou grato.

Sumário

Lista de figuras	vi
Lista de Tabelas	viii
Lista de siglas e abreviaturas	ix
Resumo	x
Abstract	xi
 CAPÍTULO 1 – INTRODUÇÃO	 1
1. INTRODUÇÃO	2
1.1. CARACTERIZAÇÃO GERAL DA PROPOSTA	2
1.2. OBJETIVOS	5
1.2.1. Objetivo geral	5
1.2.2. Objetivos específicos	5
1.3. O CENÁRIO CERVEJEIRO NO BRASIL	6
1.4. BIOMASSA CERVEJEIRA	8
1.4.1. Determinação da concentração de biomassa cervejeira.....	9
1.5. VISÃO DE MÁQUINA	12
1.5.1. Aquisição de imagens	16
1.5.2. Pré-processamento de imagem/vídeo digital.....	21
1.5.3. Segmentação de objetos	23
 CAPÍTULO 2 – EXPERIMENTAL	 27
2. EXPERIMENTAL	28
2.1. INSTRUMENTAÇÃO	28
2.2. SOFTWARE DE CONTROLE	30
2.3. PROCESSAMENTO DE VÍDEO	32
2.4. PROCEDIMENTOS ANALÍTICOS	33
2.5. AMOSTRAS	33
2.6. MÉTODO DE REFERÊNCIA	34

2.7.	MÉTODO PROPOSTO	35
2.8.	AVALIAÇÃO ESTATÍSTICA.....	36
CAPÍTULO 3 – RESULTADOS E DISCUSSÕES		39
3.	RESULTADOS E DISCUSSÕES	40
3.1.	AQUISIÇÃO DE VÍDEO/IMAGEM NA CELA DE DETECÇÃO	40
3.2.	CONSTRUÇÃO DA CURVA E VALIDAÇÃO ESTATÍSTICA	43
CAPÍTULO 4 – CONCLUSÕES		49
4.	CONCLUSÕES.....	50
REFERÊNCIAS BIBLIOGRÁFICAS		51
MATERIAL SUPLEMENTAR		57

Lista de Figuras

Figura 1- Representação ilustrativa do comportamento da concentração de células nas fases lag, log (exponencial), estacionária e de morte.....	9
Figura 2 - Método da massa seca para determinação de concentração de biomassa. (i) secagem dos frascos; (ii) secagem no dessecador; (iii) pesagem dos frascos; (iv) coleta do mosto; (v) coleta das amostras; (vi) centrifugação; (vii) descarte do sobrenadante; (viii) secagem da biomassa; (ix) secagem no dessecador; e (x) pesagem do frasco com biomassa.....	11
Figura 3 – Descrição esquemática das etapas de processamento de um sistema de VM.....	15
Figura 4 - Imagem colorida (a) decomposta em seus planos de cores R (b), G (c) e B (d).....	20
Figura 5 - Imagem original com algumas moedas, histograma da imagem e o resultado da operação de limiarização.....	25
Figura 6 – Vista externa do analisador para determinação da concentração de biomassa baseado em visão de máquina. a – Porta e cabo USB; b – tampa do suporte para amostras; c – porta amostras; d – gabinete externo; e – potenciômetro.....	28
Figura 7 - Vista interna do analisador para determinação da concentração de biomassa baseado em visão de máquina. a - Porta amostras; b – gabinete interno; c – LEDs ultrabrilhante; d – película para difusão da luz;	29
Figura 8 - Componentes principais do sistema de iluminação interna do analisador. (i) LED branco ultrabrilhante; (ii) Folha acrílica prismática; (iii) Película difusora de polimetilmetacrilato.....	30
Figura 9- Estrutura de <i>frontend</i> do <i>software</i> de processamento de vídeo e controle do analisador.....	31
Figura 10 - Concentração de biomassa pelo método proposto. (i) Coleta do mosto; (ii) coleta das amostras; (iii) centrifugação; (iv) verificação da área do sedimento utilizando visão de máquina.	35
Figura 11 - Imagens das amostras usadas na construção da curva de calibração para determinação da concentração de biomassa utilizando VM para quantificar a área do	

sedimento. Concentrações, em gmL^{-1} , foram: a) 0,0014; b) 0,0016; c) 0,0022; d) 0,0026; e) 0,0057; f) 0,0061; g) 0,0080; h) 0,0083; i) 0,0107.40

Figura 12 - Posição dos microtubos no analisador para a aquisição dos dados, tomando como referência a dobra da tampa. a) Posição 1; b) Posição 2; c) Posição 3; e d) Posição 4.41

Figura 13 - Posicionamento dos microtubos na centrífuga destacando a dobra das tampas dos microtubos (em verde) voltadas para o eixo do equipamento.42

Figura 14 - As faces do microtubo vistas pelo analisador após centrifugação em quatro posições ortogonais entre si. a) Posição 1 inicial; b) Posição 2; c) Posição 3 e; d) Posição 4.....42

Figura 15 - (a) Perfil da concentração de biomassa ao longo do tempo utilizando o método da massa seca e o (b) perfil da área de pixels² registrada ao longo pelo método alternativo após o início da fermentação.44

Figura 16 - Curva analítica e gráfico dos resíduos para determinação de concentração de biomassa empregando o algoritmo de visão de máquina. a) curva analítica; b) gráfico dos resíduos.46

Figura 17 - Teste de região elíptica de confiança conjunta (EJCR) do modelo para determinação da concentração de biomassa utilizando algoritmo de visão de máquina.47

Lista de Tabelas

Tabela 1 - Resultados obtidos pela aplicação da ANOVA.....44

Tabela 2 – Equação do modelo de calibração construído e os resultados dos testes de regressão, falta de ajuste e homoscedasticidade para a curva analítica.....45

Lista de siglas e abreviaturas

- + ANOVA - Análise de Variância (do inglês: “*Analysis of variance*”);
- + Bbp – Bits por pixel;
- + CCD – Dispositivo de carga acoplada (do inglês “*charge-coupled device*”);
- + CMOS – Semicondutor de óxido de metal complementar (do inglês “*complementary metal oxide semiconductor*”);
- + DME - Extrato de Malte Seco (do inglês “*Dry Malt Extract*”);
- + EJCR - Região Elíptica de Confiança Conjunta (do inglês “*Elliptical Joint Confidence Region*”);
- + IoT - Internet das Coisas (do inglês “*Internet of Things*”);
- + LED - Diodo emissor de luz (do inglês “*light emitting diode*”);
- + VC - Visão computacional;
- + VI – *Virtual Instrument*;
- + VM - Visão de máquina;
- + M2M - Máquina para máquina (do inglês “*machine to machine*”);
- + MAPA – Ministério da Agricultura, Pecuária e Abastecimento;
- + MQ_{faj} – Média quadrática da falta de ajuste;
- + MQ_{ep} – Média quadrática do erro puro;
- + R^2 – Coeficiente de determinação;
- + RGB - Vermelho, Verde e Azul (do inglês “*Red*”, “*Green*” e “*Blue*”);
- + ROI – Região de interesse (do inglês “*region of interest*”).

Resumo

Neste estudo, propôs-se um método analítico com características de rapidez e sensibilidade, desenvolvido para determinação de concentração de biomassa durante o processo de fermentação cervejeira. Para isso, foi desenvolvido um analisador que incorpora sistemas de controle de iluminação e captura de filmes digitais. Um *software* de controle com interface amigável e intuitiva foi desenvolvido em ambiente *LabView^(R)*, contando com sistema de amostragem de frames de vídeo e análise utilizando a tecnologia de visão de máquina, que foi empregada para o reconhecimento da área dos sedimentos. Amostras de mosto cervejeiro foram utilizadas para os ensaios de calibração e predição. A utilização do algoritmo de visão de máquina apresentou resultados promissores, permitindo a construção de um modelo estatístico de regressão com valor de coeficiente de determinação (R^2) de 0,9849, indicando um excelente ajuste linear. O modelo construído foi validado por Análise de Variância (ANOVA) e a acurácia das predições confirmada pelos testes t pareado e o teste de Região Elíptica de Confiança Conjunta (EJCR). O método proposto reduziu o tempo de análise de mais de 24 h do método de referência para 17 min. Também extinguiu a necessidade da realização de diversas etapas laboriosas preconizadas pelo método de referência. Dessa forma, a instrumentação e o método desenvolvido podem ser considerados uma alternativa interessante para o monitoramento da concentração de biomassa no decorrer do processo de produção cervejeira, além de abrir portas para a implementação dessa mesma metodologia voltada para outros tipos de bebidas que empregam o processo de fermentação, destacando-se na velocidade de análise e no baixo custo de implementação e explorando recursos da indústria 4.0, como processamento inteligente, miniaturização de processos e visão de máquina.

Palavras-chave: Visão de máquina; processamento de vídeo; fermentação alcoólica; concentração de biomassa.

Abstract

In this study, we proposed an analytical method with characteristics of speed and sensitivity, developed for the determination of biomass concentration during the beer fermentation process. To achieve this, an analyzer was developed, incorporating lighting control systems and digital film capture. A user-friendly and intuitive control software was developed in the LabView(R) environment, featuring video frame sampling and analysis using machine vision technology, employed for sediment area recognition. Brewer's wort samples were used for calibration and prediction assays. The use of the machine vision algorithm yielded promising results, enabling the construction of a statistical regression model with a coefficient of determination (R^2) value of 0.9849, indicating an excellent linear fit. The constructed model was validated through Analysis of Variance (ANOVA), and prediction accuracy was confirmed by paired t-tests and the Joint Elliptical Confidence Region (EJCR) test. The proposed method reduced the analysis time from over 24 h in the reference method to 17 min, eliminating the need for several laborious steps prescribed by the reference method. Thus, the developed instrumentation and method can be considered an interesting alternative for monitoring biomass concentration during the beer production process, as well as paving the way for the implementation of this methodology for other types of fermented beverages. This method stands out for its analysis speed, low implementation cost, and exploration of Industry 4.0 resources, such as intelligent processing, process miniaturization, and machine vision.

Keywords: Machine vision; video processing; alcoholic fermentation; biomass concentration.

Capítulo 1.

INTRODUÇÃO

1. INTRODUÇÃO

1.1. CARACTERIZAÇÃO GERAL DA PROPOSTA

A acurada determinação da concentração de biomassa desempenha um papel crucial no setor cervejeiro e em diversos outros ramos da indústria de bebidas fermentadas. Também conhecido como concentração de células, esse parâmetro refere-se ao acúmulo de leveduras e outros microrganismos que atuam na fase fria da produção cervejeira, a fermentação alcoólica. Tanto no contexto da produção de cervejas artesanais quanto em linhas de produção mais comerciais, a quantificação da biomassa é essencial para monitorar e controlar o processo de fermentação, influenciando diretamente na qualidade e consistência do produto.

A verificação de um perfil que indique baixa concentração da biomassa pode, por exemplo, denunciar um ambiente com leveduras de baixa viabilidade, ou indicar uma quantidade insuficiente de leveduras ativas para a conversão completa e eficiente dos açúcares, podendo levar a um processo fermentativo mais lento que o previsto ou a uma interrupção precoce da fermentação. Do contrário, a constatação de uma concentração mais alta desse parâmetro pode indicar um ambiente mais propício à reprodução dos microrganismos que para a própria fermentação, podendo gerar subprodutos indesejados e comprometer a qualidade sensorial da cerveja.

O monitoramento da concentração de biomassa ao longo do processo pode indicar também em qual fase do crescimento celular as leveduras se encontram, sendo estas as fases *lag*, em que as leveduras estão se habituando ao ambiente, *log*, em que há um significativo crescimento das células, fase estacionária, em que há uma estabilidade da concentração celular, e a fase de morte das leveduras, um dos indicativos do fim da fermentação (Silva, 2009). A partir da avaliação e do bom entendimento desse parâmetro os cervejeiros podem ajustar as condições de fermentação, como temperatura, nutrientes, oxigenação, dimensionamento do fermentador e otimização do uso de insumos de acordo com as necessidades da levedura, garantindo a consistência e a qualidade da cerveja, principalmente quando usados, aliado à estas medidas, bons modelos cinéticos que auxiliam nessas estimativas, como os trabalhos de De Andrés-Toro *et al* (1998), Gee (1990), Gee e

Ramirez (1994), e Marc *et al* (1983), que utilizam, a concentração de biomassa como parâmetro de entrada de seus modelos cinéticos.

Existem diversas maneiras de realizar o monitoramento da concentração de biomassa, ou concentração de células, durante o processo fermentativo. O Instituto Adolf Lutz, por exemplo, determina duas metodologias gravimétricas para esse procedimento, que, em termos práticos, consistem na secagem de um volume de amostra seguido de sua pesagem (Instituto Adolf Lutz, 2008). No entanto, tradicionalmente, na rotina dos laboratórios de análise, utiliza-se o método da massa seca, descrito em Sonego (2016), a fim de reduzir etapas desse processo e minimizar o tempo e, principalmente, o volume gasto. Esse método pode ser compreendido como uma adaptação da metodologia padrão indicada pelo Instituto Adolf Lutz, dada a sua similaridade. Tais metodologias gravimétricas são bastante efetivas na determinação da concentração da biomassa garantindo uma adequada precisão e exatidão. No entanto, a quantidade de etapas envolvidas nos processos e o tempo necessário para a realização das análises são fatores significativamente inconvenientes, sem citar ainda a utilização de um alto volume amostral.

Na literatura, diversos são os trabalhos em que propõem-se métodos alternativos para avaliação de outros parâmetros importantes na produção cervejeira, como teor de açúcar, álcool, pH e até dióxido de carbono (Cernuda *et al.*, 2017; Chapman *et al.*, 2019; Klein *et al.*, 2012), mas propostas alternativas para o acompanhamento da biomassa são raramente apresentadas, o que condiz com a conclusão do estudo de Gianezini (2018), em que, numa avaliação do cenário de produção cervejeira, em especial no Brasil, o autor constata que há uma alta carência de inovação do ponto de vista das engenharias de produção e do controle de qualidade no setor. Concomitantemente, as tendências da Indústria 4.0 seguem rumo à novas abordagens em instrumentação analítica, com a miniaturização de testes, processamento inteligente e sistemas de automação (Alonso *et al.*, 2019), o que coloca ainda mais “pressão” para o desenvolvimento tecnológico deste segmento.

Tendo em vista os desafios apresentados, a visão de máquina pode surgir como uma ferramenta promissora nesse setor, sendo uma tecnologia altamente integrada com a engenharia de sistemas de *software* mecânico-óptico-eletrônico utilizada para examinar objetos, materiais e processos, a fim de detectar defeitos e

melhorar a qualidade, a eficiência operacional e a segurança de produtos e sistemas (Batchelor, 2012).

Em outras palavras, a visão de máquina emprega algoritmos computacionais e técnicas de processamento de imagens para extrair informações significativas e realizar análises objetivas em dados visuais. Envolve a capacidade de adquirir e processar automaticamente informações visuais a partir de imagens ou vídeos, com o objetivo de identificar padrões, objetos, características ou realizar tarefas específicas, como reconhecimento de padrões, segmentação de objetos e análise de movimento. É uma área de pesquisa e desenvolvimento fundamental, inclusive, para o campo das inteligências artificiais e tem aplicações em diversos setores devido ao seu baixo tempo de resposta, alta precisão e eficiência, além de permitir uma análise sem a necessidade de entrar em contato com a amostra. Dentre esses setores estão os sistemas de reconhecimento facial, automação industrial, veículos autônomos, avaliação de qualidade de produtos, robótica, produção agrícola e sistemas de classificação de alimentos (Ramos et al., 2022).

Diante disso, o objetivo deste trabalho é desenvolver um método alternativo baseado na tecnologia de visão de máquina para a determinação da concentração de biomassa no processo de fermentação de cervejas. A proposta visa superar as limitações dos métodos tradicionais e das alternativas existentes, almejando uma solução precisa, eficiente e adaptável às demandas da Indústria 4.0. Ao fazê-lo, busca-se não apenas aprimorar o controle da fermentação cervejeira, mas também contribuir para a evolução da análise de biomassa em uma ampla gama de aplicações industriais, promovendo a eficiência, a sustentabilidade e a qualidade dos processos produtivos, alinhando-se aos princípios da Indústria 4.0.

1.2. OBJETIVOS

1.2.1. OBJETIVO GERAL

Desenvolver um equipamento analítico baseado na tecnologia de visão de máquina para compor uma metodologia alternativa para determinação da concentração de biomassa em mosto cervejeiro durante o processo fermentativo.

1.2.2. OBJETIVOS ESPECÍFICOS

- Desenvolver um analisador com sistema de captura de vídeo e controle de luminosidade para viabilizar a análise.
- Desenvolver um programa com interface amigável e intuitiva para comunicação entre analista, computador e analisador, com funções de seleção de diferentes planos de cor, seleção de região de interesse e captura de imagem e vídeo digital.
- Realizar a fermentação de mosto cervejeiro para suceder os testes analíticos utilizando o equipamento e o programa desenvolvidos.
- Validar o método proposto para a determinação da concentração de biomassa comparando seus resultados com aqueles obtidos por um método de referência.

1.3. O CENÁRIO CERVEJEIRO NO BRASIL

O Brasil tem experimentado um crescimento significativo no mercado de bebidas nos últimos anos. Em relação ao mercado cervejeiro, a abertura de novos estabelecimentos, criação de cursos, festivais, eventos e concursos torna perceptível e evidencia uma evolução da “cultura cervejeira” no país. O Brasil tem, de fato, um amplo mercado consumidor e produtor dessa bebida. A nível global, dados recentes demonstram que o país ocupa o terceiro lugar no ranking de maiores consumidores e de produtores de cerveja do mundo (Dias, 2018).

Segundo a Associação Brasileira da Indústria de Cerveja (CervBrasil), no Brasil são produzidos aproximadamente 14,1 bilhões de litros de cerveja por ano, sendo essa uma indústria que atende 99% dos lares brasileiros (CERVBRASIL, 2023). Em termos de registros legais de estabelecimentos regularizados pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA) - formalidade administrativa que autoriza as cervejarias a funcionarem baseando-se em sua atividade, linha de produção, capacidade técnica e condições sanitárias -, em 2021 verificou-se um aumento de 12% no número de estabelecimentos produtores de cerveja em relação ao ano anterior, atingindo o expressivo número de 1.549 cervejarias no país (BRASIL, 2022).

Adicionalmente a isso, o mercado consumidor brasileiro mostra-se cada vez mais exigente no que diz respeito à qualidade da bebida. A população que consome cerveja no país tem aumentado progressivamente seu interesse em produtos que ofereçam uma variedade de estilos, sabores, aromas e combinações de ingredientes novos e de qualidade, acompanhando uma tendência mundial já estabelecida. As cervejarias artesanais e as cervejarias ciganas têm se mostrado capazes de atender a essa demanda produzindo bebidas de alta qualidade e ricas em nuances sensoriais. Em um trabalho onde analisa a indústria de cervejas artesanais no Brasil, Dias e Falconi (2018) demonstraram graficamente o crescimento exponencial deste tipo de estabelecimento desde a década de noventa até o ano de 2018, onde se calcula, com base em dados do MAPA, o registro de 835 indústrias de cerveja artesanal no território nacional até a data em que o estudo foi publicado. Para uma melhor compreensão dessa categoria de mercado, o Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (SEBRAE), junto à Associação Brasileira de Cerveja Artesanal

(ABRACERVA), realizou, em 2019, o primeiro censo contemplando estatísticas a respeito das cervejarias independentes brasileiras. A partir dessa avaliação, nota-se que a maioria dos estabelecimentos (61%) se consideram microcervejarias, e a maior parte destes (75%) tem uma atuação recente no mercado (até 4 anos de existência). A produção de 25% dos estabelecimentos consultados é realizada em fábricas de terceiros (cervejarias ciganas), 8% em bares próprios (os chamados “Brewpubs”) e 67% realizam sua produção em fábrica própria (SEBRAE, 2019). Sabendo disso, é possível traçar um perfil médio desses negócios: microempresas, de recente atuação no mercado, onde a maioria possui a fábrica própria, mas boa parte depende do aluguel de equipamentos e espaço de terceiros para produzir, o que pode ser um indicativo da necessidade de inovação, miniaturização e da popularização das ferramentas necessárias a essa produção.

A produção de cervejas artesanais requer bons equipamentos, habilidade, conhecimento técnico e atenção aos detalhes em cada etapa do processo, que pode ser dividido nos seguintes passos: malteação, moagem, maceração, fervura, resfriamento, fermentação, maturação, filtração, carbonatação, estabilização microbiológica e embalagem (Salanta *et al.*, 2020). Desde a escolha dos ingredientes até o envase, cada passo deve ser cuidadosamente executado para garantir a excelência da cerveja. Além disso, é fundamental manter um controle de qualidade rigoroso para evitar qualquer problema que possa comprometer a segurança e a qualidade da bebida. Do ponto de vista da produção, a aparelhagem necessária para a análise desses parâmetros (como biomassa, açúcares, pH, teor alcoólico etc.) pode ter um custo elevado para os produtores artesanais iniciantes, levando alguns empreendedores a optarem pelo aluguel dos equipamentos e do espaço para operar, como nas cervejarias ciganas.

Nesse contexto, o acompanhamento do desenvolvimento da biomassa durante a produção da cerveja desempenha um papel crucial. No entanto, dentre os principais parâmetros controlados durante o processo de fabricação das bebidas (pH, açúcares, teor alcoólico e biomassa), o método adotado como referência pode ser considerado um dos mais laboriosos, mais demorados podendo levar de um a dois dias para ser finalizado com rigor analítico.


1.4. BIOMASSA CERVEJEIRA

A biomassa cervejeira refere-se ao acúmulo de leveduras e/ou outros microrganismos que atuam na fase fria da produção da cerveja, a fermentação alcoólica. A acurada e contínua determinação da sua concentração desempenha um papel crucial no setor cervejeiro e em diversos outros ramos da indústria de bebidas. A partir desse controle, é possível avaliar a eficiência do processo de fermentação a fim de garantir a qualidade do produto.

A determinação da concentração de biomassa, ou concentração de células, no mosto cervejeiro é um dos indicativos, por exemplo, da viabilidade da levedura, auxiliando a diagnosticar contaminações, ou ainda a verificar se há quantidade suficiente de leveduras ativas para que a conversão dos açúcares do mosto cervejeiro em álcool e dióxido de carbono se dê de forma completa e eficiente. Do contrário, a fermentação pode ocorrer de forma mais lenta que o previsto ou ser interrompida prematuramente, resultando num produto de má qualidade.

O monitoramento da concentração da biomassa ao longo do processo também proporciona ao cervejeiro estimar em qual fase do crescimento celular as leveduras se encontram, sendo elas as fases *lag* ou adaptação, fase *log* ou exponencial, fase estacionária e fase de declínio ou de morte, como ilustrado na [Figura 1](#). A fase *lag* ocorre logo após a inoculação, na qual as leveduras se adaptam às condições físicas do meio e aos nutrientes disponíveis, praticamente não havendo crescimento celular. Durante a fase exponencial ocorre a fermentação do substrato disponível no mosto, atingindo o valor máximo de sua velocidade de crescimento celular com intensa multiplicação. A fase estacionária é caracterizada pela diminuição da velocidade de crescimento e pelo equilíbrio entre morte e crescimento celular, com o número de células viáveis praticamente constante por um tempo considerável. A queda na concentração celular indica a fase de declínio, em que a morte celular causada pelo esgotamento de substrato e inibição pela maior concentração de etanol supera a velocidade de crescimento (NOGUEIRA; FILHO, 2005).

Figura 1- Representação ilustrativa do comportamento da concentração de células viáveis nas fases lag, log (exponencial), estacionária e de morte.



Fonte: Adaptado de Santos (2022).

A partir da avaliação desse parâmetro associado à outras análises, como pH, densidade original e teor alcoólico, os cervejeiros podem ajustar as condições de fermentação do sistema, como temperatura, nutrientes, oxigenação, dimensionamento adequado do fermentador, planejando a produção de acordo com as necessidades apresentadas pela levedura, garantindo a consistência e a qualidade da cerveja. Dito isso, a quantificação da biomassa desempenha um papel essencial no controle da produção das bebidas, permitindo que cervejeiros otimizem o uso de insumos, reduzindo assim os seus gastos.

1.4.1. Determinação da concentração de biomassa cervejeira

A seguir, é apresentada a principal metodologia padrão para a determinação da concentração de células. A escolha de cada método pelo analista varia, evidentemente, em função dos materiais e equipamentos que constam à sua disposição.

1.4.1.1. Método da massa seca

A determinação de biomassa utilizando o método da massa seca, também conhecido como método gravimétrico, baseia-se na mensuração da massa seca de

uma amostra com volume conhecido, dividida por este volume. Como não é possível estimar de maneira descomplicada a abundância de água que reside dentro das células, e assumindo que essa quantidade pode variar, a secagem adequada da amostra é imprescindível para garantir que o valor mensurado seja referente apenas à massa das células.

A determinação da massa da amostra (MA) é realizada pela diferença entre a massa do recipiente contendo a amostra seca (RA) menos a massa do mesmo recipiente sem amostra (RS), também seco ([Equação 1](#)), que deve ter sua massa determinada previamente utilizando uma balança analítica.


$$MA = RA - RS \qquad \text{Eq. 1}$$

Depois de estimada a quantidade de massa seca (MA), o valor calculado deve ser dividido pelo volume inicial (V) tomado da amostra, finalmente revelando a concentração de biomassa (X), como descrito na [Equação 2](#).

$$X = \frac{MA}{V} \qquad \text{Eq. 2}$$

Após ser registrada a massa do recipiente seco, um dado volume de amostra é depositado no seu interior e uma centrífuga é utilizada para decantar a massa celular ao fundo. No procedimento descrito por Sonogo (2016), por exemplo, foi utilizada a centrifugação a 10.000 rpm por 10 minutos. Depois da centrifugação, o sobrenadante é retirado do recipiente e o precipitado é lavado duas vezes utilizando água destilada. O corpo de fundo é, então, levado a estufa para secagem a 80 °C durante um período de 24h. Além disso, devido ao caráter higroscópico das células, antes de realizar as pesagens utilizando a balança analítica, os recipientes, após serem retirados da estufa, devem ser resfriados até a temperatura ambiente no interior de um dessecador. A [Figura 2](#) apresenta uma síntese desse procedimento.

Figura 2 - Método da massa seca para determinação de concentração de biomassa. (i) secagem dos frascos; (ii) secagem no dessecador; (iii) pesagem dos frascos; (iv) coleta do mosto; (v) coleta das amostras; (vi) centrifugação; (vii) descarte do sobrenadante; (viii) secagem da biomassa; (ix) secagem no dessecador; e (x) pesagem do frasco com biomassa.



Fonte: elaborado pelo autor.

O método da massa seca apresenta uma significativa efetividade na determinação da concentração de biomassa, não à toa é uma das metodologias mais utilizadas para este fim. Pode-se dizer que sua grande vantagem vem da sua simplicidade, no entanto, o tempo de preparo da amostra é longo, levando mais de 24 horas, e a metodologia é bastante laboriosa, envolvendo a necessidade de diversos passos analíticos. Por esse motivo, segundo Santos (2022), o método gravimétrico é muitas vezes utilizado para a obtenção dos valores de concentração das soluções padrão usadas para curva de calibração, para que a concentração das amostras seja determinada por outros métodos, como o método da densidade óptica, por exemplo, conforme aplicado por Veloso (2017).

Na literatura, inúmeros são os trabalhos em que são propostos métodos alternativos para avaliação de parâmetros importantes na produção de cerveja, como teor de açúcar, álcool, pH e até dióxido de carbono (Cernuda *et al.*, 2017; Chapman *et al.*, 2019; Klein *et al.*, 2012), o que reforça a conclusão de Santos (2022), em que os autores afirmam que os parâmetros mais simples do processo de fermentação

alcoólica já estão adequados às demandas pela modernização, atendendo às expectativas trazidas pela indústria 4.0. No entanto, propostas alternativas e inovadoras para o acompanhamento da biomassa são raramente apresentadas.

A falta de automação na medição de biomassa também pode ser um problema para as empresas de bebidas fermentadas. A medição é tradicionalmente realizada manualmente, o que pode levar a erros humanos e aumentar o tempo e o custo do processo.

1.5. VISÃO DE MÁQUINA

A visão humana é notável pela sua capacidade de interpretar o mundo ao nosso redor, processando, há milhares de anos, informações visuais de forma instantânea e complexa, garantindo a nossa permanência enquanto espécie nos permitindo o reconhecimento de animais, plantas, objetos e cenários, e contribuindo com o avançar das nossas tecnologias ao longo das eras. Para reunir o máximo possível de informações necessárias e negligenciar o máximo de informações desnecessárias do nosso mundo visual, o sistema visual humano passou por diversas otimizações impressionantes no decorrer da evolução (Hornberg, 2006). A partir do início do século XIX, a segunda revolução industrial moldou a indústria introduzindo a produção em massa através da divisão das etapas de manufatura e das linhas de fabricação e montagem dedicadas. Desse contexto até o atual, a indústria da manufatura foi e é extremamente dependente da habilidade que os seres humanos possuem para analisar contextos visuais. Essa habilidade é explorada em inúmeras tarefas, como o desenvolvimento de projetos, avaliação de processos, montagem, acabamento e controle de qualidade.

Dentre os principais usos da visão humana na indústria estão a metrologia e a inspeção. Para Emmer (2017), a metrologia é referida como uma coleta sistemática e altamente precisa de dados no tempo e no espaço. Para Groover (2008), a inspeção é um processo no qual uma característica de uma peça ou produto, como a dimensão de um furo ou de um objeto, por exemplo, é examinada para determinar se está de acordo com a especificação do projeto. O que justifica esses usos é o fato de que a visão é uma técnica de análise que não polui o objeto e nem o cenário sob observação e, com poucas exceções, os níveis de luz necessários para um humano inspecionar

um produto industrial utilizando a visão não afetam de forma alguma tal objeto. A visão é um recurso que fornece uma grande quantidade de informações muito detalhadas sobre uma ampla variedade de características de um objeto, tais como a sua forma, a cor, a textura, a qualidade de um acabamento, revestimentos, contaminação de superfície etc. (Batchelor, 2012; Ramos, 2021).

A visão humana, no entanto, está sujeita a várias limitações que tornam desafiadora sua aplicação em muitos cenários industriais e tecnológicos. Os fatores que contribuem para isso são principalmente a subjetividade do observador, fadiga, tédio, desconforto visual, doenças, distrações, limitações de escala, velocidade de inspeção etc. Muitas tarefas de inspeção requerem medições dimensionais e/ou volumétricas precisas, que as pessoas não podem realizar com alta precisão e velocidade. Esses fatores podem afetar a capacidade que a visão humana possui em avaliar processos duradouros e detalhados de maneira consistente. Segundo Newman e Jain (1995), a eficácia de um operador humano em tarefas de inspeção chega, nos melhores casos, a 80% em linhas de produção nas quais 100% dos produtos são inspecionados. Logo, a inspeção humana nem sempre pode aplicar critérios de avaliação objetivos com rigor, principalmente quando as propriedades estéticas de itens altamente variáveis devem ser julgadas. Por essas razões, os engenheiros sonharam há muito tempo em construir uma máquina que pudesse “ver” (Batchelor, 2012).

Nos últimos anos, a quarta revolução industrial, também conhecida como Indústria 4.0, surge com novos conceitos acerca das relações de produtividade e manufatura. A inserção de tecnologias como IoT (*Internet of Things*), algoritmos de aprendizagem de máquina e Visão Computacional (VC) na indústria permitiu o desenvolvimento de sistemas inteligentes capazes de tomar decisões de forma autônoma, elevando os níveis de flexibilidade e adaptabilidade dos processos produtivos. Novos conceitos de fábricas projetadas sob essa perspectiva se mostraram mais competitivas no mercado, pois adotam um modelo de produção de alta variedade que pode atender uma demanda personalizada (Rußmann, 2015; Araújo, 2019).

A visão computacional não é exatamente uma tecnologia nova. Ao longo do final da década de 1970 e início da década de 1980, os estudos acerca desse tema

se desenvolveram lentamente com contribuição constante da comunidade acadêmica, mas com pouca expressão no setor industrial. Já no final da década de 1980 e início da década de 1990, o interesse da indústria por essa tecnologia finalmente ganhou expressão, em grande parte devido ao progresso significativo dos setores de fabricação de *hardware* de processamento de imagem. Durante a primeira década do século XXI, o crescimento do mercado da tecnologia de visão de máquina se tornou implacável, impulsionado consideravelmente pelo desenvolvimento de tecnologias novas e mais baratas, especialmente os componentes ópticos de plástico, iluminação utilizando LEDs, câmeras de alta resolução e *hardware* de computadores mais velozes que garantiam mais poder computacional com preço mais acessível. No decorrer das últimas décadas, pesquisadores demonstraram a viabilidade dessa tecnologia numa vasta gama de produtos, representando todos os principais ramos da indústria de manufatura. Atualmente, as principais áreas de aplicação dos sistemas de visão industrial ocorrem na inspeção e medição automatizada e, em menor grau, na visão robótica (Batchelor, 2012).


Os sistemas de visão de máquina também estão completamente incorporados na filosofia da Indústria 4.0, no sentido de que as câmeras podem se comunicar entre si e com sensores que permitem comunicações do tipo M2M (*machine to machine*). A capacidade de medição da visão de máquina permite obter uma grande quantidade de dados sobre cada inspeção realizada, que podem ser alimentados em sistemas de *big data* e depois utilizados para facilitar o processo de tomada de decisão (Alonso, 2019).

Dentro da temática dos campos da visão artificial, motivado pela ausência de um consenso na área, os termos “visão computacional” e “visão de máquina” ainda hoje causam confusões em relação a seus significados. Ambos os termos se referem a formas de visão artificial que não necessariamente buscam replicar ou emular a visão biológica, mas que podem buscar inspirações nela (Scariot, 2017). Os sistemas de Visão de Máquina (VM) são conjuntos de equipamentos dedicados à solução de um problema de natureza visual, compostos tanto por *hardware* quanto por *software*, fazendo uso de técnicas de processamento de imagens e de visão computacional. Visão computacional (VC), por sua vez, é a extração de características importantes de imagens, as quais serão utilizadas para tomada de decisão (Oliveira, 2015). Para

uma discussão mais detalhada sobre o assunto, Batchelor (2012), no livro *Machine Vision Handbook*, dedica algumas passagens onde é possível compreender melhor as diferenças e conexões entre VM e VC, e ainda como dividem aspectos como processamento de imagens. No texto, o autor explica que enquanto a visão computacional preocupa-se com aspectos científicos de produção acadêmica, especialmente referentes ao desenvolvimento de programas e modelos matemáticos, a visão de máquina possui outras demandas, como custo, praticidade, aplicação e viabilidade. A visão computacional, para o autor, é uma ciência. Já a visão de máquina, uma engenharia.

O sucesso do desenvolvimento de um sistema de visão artificial depende da compreensão de todas as partes da cadeia de processamento de imagens ou vídeos digitais. A complexidade da visão de máquina reside na gama de áreas especializadas da engenharia nela envolvidas, nomeadamente: engenharia mecânica, engenharia elétrica, engenharia óptica e engenharia de *software*, cada uma das quais desempenha um papel primordial (Hornberg, 2006).

Figura 3 – Descrição esquemática das etapas de processamento de um sistema de VM.



Fonte: Ramos, 2021.

As principais etapas da análise de processamento de imagem associadas a visão de máquina são: (i) aquisição de imagens; (ii) pré-processamento; (iii)

segmentação de objetos; (iv) obtenção de características dos objetos por meio de metrificação e (v) computação das informações para geração dos dados de saída, esquematizado na [Figura 3](#). Na primeira etapa (i) é necessária a utilização de um bom sistema de iluminação e câmera com resolução adequada. A aplicação das técnicas de processamento de imagens começa na etapa (ii), com o pré-processamento, buscando aprimorar a qualidade da imagem, reduzindo ruídos inerentes ao processo de aquisição. O processo de segmentação (iii) é utilizado para separar as áreas de interesse, que consistem nos objetos a serem medidos na etapa seguinte (iv) (Feliciano; Souza; Leta, 2005; Ramos, 2021).

Na última etapa (v), as informações de saída são finalmente geradas e as decisões a respeito do procedimento podem ser tomadas. Nos sistemas em que essas estratégias são implementadas para caracterização de objetos em tempo real, o procedimento é realizado por meio da análise de quadros de vídeo, onde o algoritmo realiza análises quadro a quadro de acordo com a taxa de amostragem de frames (Ramos, 2021). Nas seções seguintes, cada uma das etapas será abordada e discutida.

1.5.1. AQUISIÇÃO DE IMAGENS

A aquisição de imagens digitais representa o ponto de partida para qualquer sistema de visão artificial. A eficácia do processo de aquisição de imagens depende de, no mínimo, um bom sistema de iluminação e um bom dispositivo para a captura da imagem. Cada aplicação de sistemas de visão de máquina requer uma fonte de luz específica e um arranjo óptico adequado para iluminação. Em alguns cenários, sombras ou penumbras podem ser utilizadas para verificar o alinhamento de objetos em cena. Em outras situações, há a necessidade de se obter uma imagem com iluminação planar e uniforme, sem a presença de sombras. Recursos de ampliação de uma imagem para detecção de objetos em escala microscópica, ou o uso de lentes macro para uma visão mais ampla de um objeto, também podem ser utilizados para aprimoramento da captura. A disposição dos elementos que irão constituir o sistema de aquisição de imagens deve ser cuidadosamente estudada para se obter uma imagem digital de fácil processamento digital (Beyerer; León, Frese, 2016; Batchelor, 2012; Ramos, 2021).

O princípio da captura eletrônica de imagens se baseia no fato de que a imagem de uma cena, ao passar por uma lente e ser projetada num sensor, representa bidimensionalmente algo que está no espaço tridimensional (Oliveira, 2015). O papel do sensor na câmera é converter um sinal luminoso em um sinal elétrico, e assim formando uma imagem por meio de uma matriz de pixels dispostos em formato retangular, também conhecido como *frame*. O termo pixel vem da junção das palavras figura (*picture*) e elemento (*element*) na língua inglesa, e é usado para se referir tanto um elemento individual da matriz dos sensores quanto aos componentes de uma imagem. Os sensores de imagem mais comuns no mercado e que normalmente constam nos dispositivos de captura são do tipo CCD (dispositivos de carga acoplada, do inglês “*charge coupled device*”) e CMOS (semicondutores de óxido de metal complementar, do inglês “*complementary metal oxide semiconductor*”), ambos desenvolvidos nas décadas de 1960 e 1970, respectivamente (Beyerer; León; Frese, 2016). Em ambos os casos, milhares ou até milhões de pixels (a depender da resolução) são dispostos em uma matriz retangular de duas dimensões e cada um desses elementos é responsável por transformar a luz de uma pequena parte da imagem em um sinal elétrico utilizando fotodiodos. Os sinais elétricos são, por fim, convertidos em informações ou sinais digitais (bits) via transdutores, e assim são capazes de ser processados por computador, gerando uma imagem digital.

Hoje, no mercado, há uma grande variedade de modelos de dispositivos de captura de imagem, que vão desde câmeras infravermelho a câmeras mais robustas de chão de fábrica e webcams simples. Como citado anteriormente, esses equipamentos utilizam, normalmente, sensores CCD ou CMOS. A diferença central entre esses dois tipos de sensores é o seu funcionamento. Nos sensores CCD, depois que a luz incide sobre os fotodiodos, o sinal elétrico é gerado e são coletados em um único ponto de leitura (geralmente fora do sensor). Já nos sensores CMOS, cada fotodiodo é associado a seu próprio circuito de leitura. Ou seja, quando a luz atinge o fotodiodo, o sinal digital é gerado individualmente.

Dito isso, depois da década de 1990, o sensor CMOS acabou superando e substituindo os sensores CCD em vários segmentos por apresentar algumas vantagens. Devido a sua estrutura de operação, sensores CCD tendem a consumir mais energia pela necessidade de transferir elétrons por toda matriz de forma serial.

Os sensores CMOS, por sua vez, consomem menos energia porque a eletrônica de leitura é distribuída entre os pixels, o que permite leituras seletivas e reduz o consumo de energia quando o pixel não está sendo utilizado. Outras vantagens dos sensores CMOS são: uma faixa mais alta de intensidades de luz detectadas (cerca de 4 ordens de magnitude), alta velocidade de leitura (cerca de 100 ns) e o acesso aleatório a pixels individuais. Sensores CMOS também costumam ser mais acessíveis em termos de custos de produção e podem ser mais compactos, tornando-os adequados para uma ampla gama de dispositivos. Em função do melhor desempenho, as aplicações industriais de visão de máquina empregam comumente sensores do tipo CMOS, mas, de forma geral, a escolha entre essas tecnologias dependerá da qualidade da sua fabricação e das necessidades específicas de aplicação (Beyerer; Léon; Frese, 2016; Ramos, 2021).

Do ponto de vista digital, a quantidade de valores possíveis para os níveis de cinza é quantizada e é proporcional a quantidade de informações (em bits) que cada pixel é capaz de armazenar. Na computação gráfica, a quantidade de bits dedicados a cada pixel que compõem a imagem é conhecida como profundidade de cor, ou ainda pela sigla bbbp, “bits por pixel”. Usualmente, uma profundidade de 8 bits é utilizada por cada pixel. Isto significa que 256 (2^8) combinações diferentes de 8 dígitos binários (0s e 1s) estão disponíveis para representar a quantidade de luz recebida por um pixel. Isso resulta em uma paleta de 256 níveis de cinza distintos, em que o 0 (zero) é o valor que representa o preto, quando nenhum fóton atinge o fotodiodo, e 255, o branco puro, valor em que o capacitor do sensor está no máximo da sua capacidade de comportar elétrons, levando à sua saturação (Cambridge in colour, 2005).

Uma das técnicas mais difundidas nas câmeras modernas para se obter uma imagem colorida é o uso de filtros de cor nos fotodiodos do sensor. As câmeras mais comuns utilizam os filtros de cor Bayer, que é baseado no espaço de cores RGB (R para vermelho, do inglês “red”; G para verde, do inglês “green”; e B para azul, do inglês “blue”). O filtro consiste num arranjo de quatro pixels com dois filtros verdes, um azul e um vermelho. Essa técnica se baseia no comportamento dos cones na visão humana, que são receptivos às cores primárias aditivas (vermelho, verde e azul). Dessa forma, as imagens digitais coloridas são formadas pela junção das três componentes (R, G e B) do espaço de cores RGB (Gonzalez; Woods, 2008).

A partir de uma imagem capturada utilizando o espaço de cores RGB, é possível obter os planos R, G e B separadamente, como pode ser observado na [Figura 4](#). Deste modo, cada um dos três planos será composto por uma matriz bidimensional contendo apenas informação de pixels de uma componente de cor, com profundidade variando entre os valores 0 e 255, quando utilizados 8 bits de informação. Desse modo, a seleção do plano de cor adequado pode, em algumas aplicações, ser fundamental para auxiliar o sistema de visão de máquina a reconhecer os objetos alvo em uma imagem, uma vez que cada plano de cor pode, em determinadas situações, ressaltar características diferentes de uma cena.

Figura 4 - Imagem colorida (a) decomposta em seus planos de cores R (b), G (c) e B (d).



Fonte: Gonzalez; Woods, 2008.

1.5.2. Pré-processamento de imagem/vídeo digital

As etapas de processamento de imagem, em visão de máquina, podem ser classificadas como de baixo, médio ou alto nível. No entanto, a despeito dessa classificação, os elementos tratados no processamento de imagens ou vídeos digitais são os pixels, e para que ocorra o processamento, as variações nos valores de intensidade ou níveis de cinza devem ser analisadas. Dessa forma, uma imagem digital pode ser compreendida como uma matriz $N \times M$ de valores inteiros positivos que indicam a intensidade de cor de cada posição (i,j) da imagem. Um dado pixel $(p(i,j))$ na posição (n,m) possui um valor numérico que representa o valor do brilho na área correspondente na imagem. (Feliciano, 2005). Para o processamento de vídeos o princípio é geralmente o mesmo, com esta avaliação sendo realizada quadro a quadro, de acordo com a taxa de amostragem de quadros (*frames*) requerida.

A respeito das classificações dadas aos diferentes níveis de processamento de imagens digitais, processamentos de nível médio envolvem tarefas como segmentação, descrição de forma e reconhecimento de um ou mais objetos individuais. Este nível é caracterizado por ter uma imagem digital como entrada e informações (dados) retiradas daquela imagem como saída. Já processamentos de alto nível possuem uma alta complexidade e envolvem a atribuição de sentido a um conjunto de objetos reconhecidos numa cena, simulando as funções cognitivas geralmente associadas à visão. Os pré-processamentos, sua vez, são processamentos de nível baixo e envolvem operações primitivas e mais simples, como redução de ruídos, aumento de contraste, aplicação de filtros de cor, seleção de regiões de interesse (ROI), transformação para escala de cinza, limiarização e variações de brilho. Esse tipo de processamento se caracteriza por possuir como entrada e saída uma imagem digital, passíveis de terem suas características contempladas e avaliadas por um observador humano (Gonzalez; Woods, 2008).

O pré-processamento deve ser realizado para aprimorar a qualidade da imagem, reduzindo ruídos inerentes ao processo de aquisição. O pré-processamento não aumenta o conteúdo de informações de uma imagem, mas auxilia a suprimir informações irrelevantes ou aprimorar alguns recursos importantes para os processos posteriores. Um ótimo exemplo disso é a utilização da técnica de redimensionamento da imagem para enquadrar apenas a região de interesse (ROI, do inglês “*region of*

interest”), que elimina o processamento desnecessário do restante da imagem (Ramos, 2021).

No caso do pré-processamento de imagens coloridas, a decomposição da imagem em seus canais de cor é uma técnica que pode realçar características importantes para as próximas etapas de processamento, principalmente quando é necessário manipular imagens de cenas complexas. Partindo de uma imagem capturada utilizando o espaço de cores RGB, é possível extrair informações dos canais R, G e B separadamente. Deste modo, cada um dos três planos será composto por uma matriz bidimensional contendo apenas informações de pixels de uma componente de cor.

Outra forma de pré-tratar a imagem é utilizando a técnica de limiarização, também conhecida como transformação em escala de cinza ou binarização. Essa ferramenta é simples de ser implementada e ocupa posição de destaque em trabalhos com imagens digitais, sendo considerada de suma importância para as etapas de processamento posteriores, especialmente para a segmentação, que será tratada na seção 2.3.3. De forma simples, pode-se dizer que, a partir da determinação prévia de um valor para o nível de cinza, a técnica atribui a todos os pixels com níveis de cinza mais baixos que este limiar o valor 0 (zero), e a todos os pixels com níveis de cinza maiores, a intensidade de brilho máxima (Oliveira, 2015).

Outro aspecto que favorece o uso da limiarização é a atenuação do esforço computacional, tanto de processamento, quanto de armazenamento. Isso acontece porque após a aplicação da limiarização, a imagem digital se torna binária, não contendo mais 256 níveis de cinza, mas apenas dois (0 ou 1). Por causa disso, essa técnica também é conhecida como binarização (Feliciano, 2005). A limiarização altera o brilho independentemente da posição do pixel na imagem, de forma que o valor do pixel de saída depende somente do valor do pixel de entrada. Processos que envolvem esse tipo de transformação na imagem recebem o nome de operadores de ponto, ou ainda, processos pontuais (Ramos, 2021).

Para a limiarização ser efetiva, é necessário que o objeto e o fundo tenham contraste suficiente e que se saiba os níveis de intensidade tanto dos objetos quanto do fundo, por isso, o valor apropriado para esse limiar depende da iluminação e das características reflexivas dos objetos. Há alguns algoritmos que são capazes de

estimar o valor ótimo do limiar baseado em alguns tratamentos matemáticos, no entanto, em uma imagem em que um alto contraste é obtido, essa estimativa pode ser feita por meio da avaliação do histograma dos níveis de cinza da imagem e da percepção das características de intensidade de brilho do objeto e do fundo da cena. De forma geral, essa técnica é muito útil em casos em que o contorno contém informações suficientes para o reconhecimento de um objeto e onde o ambiente pode ser controlado adequadamente, caso que se aplica a este trabalho e em boa parte das aplicações da visão de máquina na indústria (Feliciano, 2005).

1.5.3. Segmentação de objetos

A segmentação de objetos em imagens digitais é considerada uma técnica de processamento de nível médio, tendo como entrada uma imagem digital e gerando como saída atributos extraídos dessa imagem, como bordas, contornos, identidade de objetos etc. A segmentação é uma das etapas mais importantes que compõem os sistemas de visão de máquina, visto que, de modo geral, a implementação de VM na indústria está associada ao reconhecimento de características, como detecção de rachaduras, leitura ou posição do rótulo de uma embalagem, dimensões de um objeto, entre outras aplicações similares (Ramos, 2021).

Independentemente da aplicação requerida, o objetivo principal da segmentação de imagens é ressaltar características relevantes da cena com base em aspectos relativos ao valor de intensidade de pixel, segregando a imagem em regiões específicas, como objeto e *background* (fundo), de forma que esta segmentação tenha forte correlação com a disposição desses elemento no mundo real. Após a segmentação, o objeto é descrito por características geométricas ou topológicas, como área, forma, textura e centroide (Araújo, 2019).

É por meio da segmentação que os objetos de uma imagem são isolados para que seja possível analisá-los individualmente. Os algoritmos de segmentação de imagens são, em geral, baseados em descontinuidades e similaridades, ambas propriedades são relacionadas à distribuição dos níveis de intensidade de cinza nos pixels que compõem a imagem.

Os métodos baseados em descontinuidades levam em consideração as mudanças abruptas nos níveis de intensidade dos pixels da imagem que podem

constituir pontos isolados, linhas ou bordas. A detecção de bordas, por exemplo, é uma das tarefas mais usuais no campo de processamento de imagens que se baseiam nessa proposta. Uma borda é o limite entre duas regiões que possuem propriedades relativamente distintas de nível de cinza. A detecção da borda de um objeto permite avaliar as suas arestas em busca de imperfeições e variações, e pode-se verificar, por exemplo, a concentricidade de um furo circular em uma peça (Gonzalez; Woods, 2008).

Enquanto os algoritmos baseados em descontinuidade buscam por diferenças abruptas nos níveis de cinza, os métodos de segmentação por similaridade subdividem a imagem em regiões de acordo com características similares de informações quantitativas delas. Uma importante característica obtida através dessa abordagem é possibilidade de conhecer a quantidade de pixels com características similares que formam uma região. Esta medida está relacionada diretamente com a área do objeto, e é extremamente útil para estudos de metrologia (Araújo, 2019).

Dos algoritmos baseados em similaridade, os que usam a limiarização da imagem são os mais comuns, sendo o limiar de nível de cinza (*threshold*) o processo de segmentação mais simples e recorrente nos sistemas de VM. Nessa operação, uma constante ou limite de brilho é definida pelo usuário para segmentar objetos e fundo da cena. A *thresholding* é uma técnica computacionalmente barata e rápida, se tornando ideal para a execução de tarefas em tempo real (Ramos, 2021).

De forma geral, a técnica threshold visa a transformação de uma imagem digital de entrada f em uma imagem binária de saída (segmentada) g com apenas dois níveis de intensidade, conforme descrito nas Equações 3 e 4:

$$g(i, j) = 1, \text{ para } f(i, j) > T \quad \text{Eq. 3}$$


$$g(i, j) = 0, \text{ para } f(i, j) \leq T \quad \text{Eq. 4}$$

onde T é o valor de limiar estabelecido (threshold), $g(i, j)$ o valor da intensidade da imagem binarizada e $f(i, j)$ é o valor da intensidade de cinza da imagem original para aquele determinado pixel. Após feita essa operação, o que irá determinar o que é objeto e o que é cena será se o algoritmo está orientado para o reconhecimento de objetos brilhantes ou escuros em relação. Em situações onde o objeto é mais claro

que o fundo, $g(i, j) = 1$ representará o objeto e $g(i, j) = 0$, a cena. Caso contrário, o inverso é verdadeiro.

O exemplo da [Figura 5](#) mostra uma cena com algumas moedas em um fundo cinza escuro. Aqui, foram aplicados três valores de *threshold*, sendo eles: 0,3, 0,4 e 0,5, que são valores normalizados em relação à escala de tons de cinza. O histograma resultante mostra duas regiões onde há uma maior concentração de pixels, uma mais clara e outra mais escura. A região escura encontra-se no início do histograma, com uma alta concentração de pixels entre os valores 50 e 80 de intensidade, aproximadamente. Essa região possui maior quantidade de pixels porque, neste caso, o fundo da imagem possui uma área maior que as dos objetos. Já a parte clara localiza-se nas regiões de maior brilho, com um pico do perfil num valor de intensidade de 185, aproximadamente. Uma característica importante que pode ser percebida é que seu perfil é mais largo, porque os objetos mais claros (moedas) possuem tonalidades mais variadas.

Figura 5 - Imagem original com algumas moedas, histograma da imagem e o resultado da operação de limiarização.



Fonte: Scariot, 2017.

Ainda no exemplo da [Figura 5](#), é possível notar a importância da escolha do valor *threshold* para uma boa segmentação. Um limiar muito baixo, como de 0,3 no exemplo, pode resultar em uma segmentação com muitos falsos positivos. Já um limiar muito alto pode não ser capaz de selecionar todos os pixels que são moedas, como na segmentação usando o valor de 0,5. Um resultado ideal pode ser alcançado ao tentar aumentar a quantidade de verdadeiros positivos e reduzir os falsos positivos. Algo próximo desse resultado pode ser observado utilizando o limiar de 0,4 (Scariot, 2017). É importante pontuar que para cenas em que há apenas um objeto a ser detectado, a área total do objeto é dada pelo somatório total de pixels da classe do objeto. Já para este tipo de cena, além da limiarização, outras técnicas de segmentação necessitariam ser empregadas.

Esse tipo de abordagem onde é selecionado apenas um valor de *threshold* para toda a imagem é denominada limiarização global. No caso de imagens que apresentam grandes variações entre os níveis de cinza do objeto e do fundo da imagem provocadas pela iluminação não uniforme, não é recomendado o uso de um *threshold* global. A alternativa mais apropriada nessas circunstâncias seria utilizar técnicas de limiarização local. De modo geral, nesta técnica são definidos diferentes valores de *threshold* para cada região da imagem, tornando o processo de segmentação mais flexível às condições não-uniformes de iluminação (Araújo, 2019).

Capítulo 2.


EXPERIMENTAL

2. EXPERIMENTAL

2.1. INSTRUMENTAÇÃO


Os filmes foram obtidos utilizando um analisador desenvolvido em laboratório, construído em impressora 3D, com suporte para um microtubo Eppendorf (2 mL) com amostra por vez. Para a captura dos filmes digitais foi utilizada uma webcam *Microsoft®*, modelo *Lifecam Studio Q2f-00013*, com captura de imagens em 5 MP e captura de vídeo em até 1080p (1.920 x 1.080). A comunicação com a webcam e alimentação dos LEDs do sistema do analisador foi estabelecida via conexão USB 2.0 com o computador. As Figuras 6 e 7 apresentam as vistas externa e interna, respectivamente, do dispositivo desenvolvido. Mais informações a respeito das dimensões do analisador podem ser encontradas no Material Suplementar, nas Figuras S1 e S2.

Figura 6 – Vista externa do analisador para determinação da concentração de biomassa baseado em visão de máquina. a – Porta e cabo USB; b – tampa do suporte para amostras; c – porta amostras; d – gabinete externo; e – potenciômetro.



Fonte: elaborado pelo autor.

Figura 7 - Vista interna do analisador para determinação da concentração de biomassa baseado em visão de máquina. a - Porta amostras; b – gabinete interno; c – LEDs ultrabrilhante; d – película para difusão da luz; e – webcam; f – gabinete externo.




Fonte: elaborado pelo autor.

Na [Figura 7](#), nota-se uma característica interessante na disposição dos elementos na parte interna do analisador, no que diz respeito à iluminação. O sistema de iluminação interno é constituído por três componentes principais, ilustrados com mais detalhes na [Figura 8](#), sendo estes: (i) um arranjo de LEDs brancos ultrabrilhantes (LED SMD, 3.0 x 2.0 x 1.3mm, modelo 703-1050, da Farnell, Inglaterra); (ii) Folha acrílica prismática (modelo JK-K12, da Kunxin New Material Technology, Guangdong – China); (III) uma película difusora de polimetilmetacrilato (com 60% de transmissão, modelo JJk-60, da Kunxin New Material Technology, Guangdong – China); com estes dois últimos elementos, juntos, compondo a película para difusão da luz observada na [Figura 7 \(d\)](#). Dessa forma, o feixe de luz proveniente do arranjo de LEDs chega à primeira barreira de difusão (folha acrílica prismática), que tem a função de multiplicar o número de pontos de espalhamento da luz. Nesta primeira barreira, o ângulo do feixe de luz do LED é alterado de 120° para a faixa de 160 ~ 176 °, “espalhando” a luz. A segunda barreira de difusão, a película difusora de polimetilmetacrilato, tem a

função de suavizar a luz que fora espalhada, promovendo a formação de um plano de fundo perfeitamente iluminado no vídeo capturado pela *webcam* durante as análises.

Figura 8 - Componentes principais do sistema de iluminação interna do analisador. (i) LED branco ultrabrilhante; (ii) Folha acrílica prismática; (iii) Película difusora de polimetilmetacrilato.




Fonte: elaborado pelo autor e colaboradores.

2.2. SOFTWARE DE CONTROLE

O *software* e a interface gráfica desenvolvida para a aquisição do filme digital foram desenvolvidos em ambiente de programação *LabView*® (versão SP1, 2021), uma interessante alternativa para aplicações que exigem medições e acesso rápido e simplificado a dados em tempo real, e com a possibilidade de criação de arquivos executáveis compatíveis em quaisquer sistemas operacionais *Windows* superior ao *Windows 7*. Originário da empresa *National Instruments*, o ambiente *LabView*® utiliza uma linguagem de programação gráfica, por blocos, a fim de facilitar a criação de interfaces até mesmo para os indivíduos que não possuem conhecimento avançado

na criação de programas. A Figura 9 apresenta a estrutura de *frontend* do software desenvolvido para essa aplicação.

Figura 9- Estrutura de *frontend* do software de processamento de vídeo e controle do analisador.



Fonte: elaborado pelo autor.

A interface foi organizada em três blocos visuais, um bloco à esquerda, outro na parte superior direita e o terceiro na parte inferior direita. A região superior esquerda, no primeiro bloco, apresenta um *textbox* para seleção da porta na qual a *webcam* está conectada. Abaixo, verifica-se um display com o vídeo capturado pela *webcam* em tempo real, exibindo um filme da amostra inserida na cela de detecção do analisador. No display de vídeo também é exibido, de forma automática, o resultado do reconhecimento de objetos do sistema de visão de máquina, destacado por um retângulo de cor vermelha. Esse recurso foi implementado para sinalizar ao usuário aonde está localizado o objeto reconhecido pelo sistema de VM, no entanto, nem todos os pixels compreendidos no interior do retângulo são utilizados para o cálculo automático da área de pixels referente ao objeto alvo. Logo abaixo do display pode ser observada uma caixa de ferramentas para edição da ROI em diferentes formas geométricas possíveis. Na Figura 9, por exemplo, a ROI (em verde) foi definida utilizando a forma geométrica circular.

No bloco superior direito da interface encontra-se, mais centralizados, os botões para seleção dos parâmetros de configuração do sistema de processamento de vídeo para otimização da análise. Na parte superior, há um *textbox* utilizado para selecionar se a busca do algoritmo será orientada a objetos escuros (*Dark*) ou brilhantes (*Bright*) e, ao lado direito, pode-se selecionar o valor de *threshold* ideal para a análise. Abaixo, existem sete outros parâmetros de configuração, como: ignorar objetos que tocam a borda da ROI; preencher os buracos de pixels nos objetos; definir o tamanho mínimo do objeto a ser buscado; definir o tamanho máximo do objeto a ser buscado; mostrar área do objeto reconhecido; indicar o centro de massa do objeto e indicar o índice do objeto (0-n). Já do lado direito do bloco superior direito, encontram-se valores relacionados ao resultado da busca pelo(s) objeto(s) são apresentados, como: área do objeto reconhecido; a orientação espacial (da maior distância entre dois pontos do objeto); a razão largura/altura e o número de buracos do objeto. Por fim, o bloco inferior exibe um histograma em tempo real do vídeo apresentado.

2.3. PROCESSAMENTO DE VÍDEO

No que diz respeito à rotina de aquisição e amostragem de vídeo, a comunicação entre o *software* e a *webcam* se deu utilizando o dispositivo *IMAQdx Open Camera VI*. Esse VI (*Virtual Instrument*) disponível na biblioteca do ambiente *LabView^(R)* (versão SP1, 2021), estabelece uma conexão para o recebimento de arquivos de vídeo em tempo real. Posteriormente, utiliza-se os dispositivos *IMAQdx Configure Grab VI* e *IMAQdx Grab VI*, respectivamente, para determinar a taxa de aquisição de quadros de vídeo (20 quadros por segundo) e obter o quadro mais recente disponível. Os filmes digitais foram originalmente gravados no espaço de cores RGB, devido à natureza do dispositivo usado na captura (*webcam*). No entanto, o dispositivo *IMAQ ExtractSingleColorPlane VI* foi adicionado ao *software* para garantir a possibilidade de extração de apenas um componente (R, G ou B). Para o estudo, entretanto, foi utilizado apenas a componente R do espaço de cores RGB, já que esta componente demonstrou melhor desempenho em trabalhos similares realizados anteriormente (Ramos, 2021).

Para que fosse possível a seleção da ROI diretamente por meio de comandos de clique/arraste do cursor do mouse diretamente no display de vídeo do *software*, recursos de cópia, corte e sobreposição foram incorporados utilizando os dispositivos

IMAQ Copy VI, *IMAQ ROIToMask 2 VI*, *IMAQ SetOffset VI* e *IMAQ Mask VI*, respectivamente. Para o sistema de visão de máquina, apenas os dados referentes a ROI foram enviados, de forma que o filme em tela inteira fosse exibido no display para facilitar o posicionamento da região de interesse. Para a realização deste procedimento, a ROI foi estimada com base no espaço visual onde os sinais analíticos estavam contidos (o sedimento formado no fundo do microtubo).

Após a realização desses passos, para reconhecer/metrificar objetos em cena, o dispositivo *IMAQ Count Objects 2 VI* foi utilizado. Esta ferramenta, disponível na biblioteca do ambiente *LabView^(R)*, é um algoritmo de visão de máquina que utiliza o método *threshold* para segmentar objetos de uma cena em tempo real. Este dispositivo permite a adoção de filtros opcionais que oferecem a possibilidade de: (i) ignorar objetos menores ou maiores do que os tamanhos especificados; (ii) ignorar objetos que tocam as bordas da região de interesse (ROI); (iii) ignorar as lacunas ou “buracos” que o processo de segmentação pode detectar nos objetos; (iv) pesquisar os limites da borda de um objeto a partir de um valor limite predefinido; e ainda (v) buscar por objetos escuros ou brilhantes. As análises de visão de máquina foram executadas em um loop de processamento a cada 50 ms, ou seja, os resultados médios de 20 medições são exibidos a cada segundo.

2.4. PROCEDIMENTOS ANALÍTICOS

Nos ensaios de determinação da concentração de biomassa, foram utilizados microtubos eppendorf de 2 mL como porta amostra. Após o microtubo ser inserido na cela de detecção, o algoritmo de visão de máquina identificou o sedimento no fundo do eppendorf como um objeto escuro. Portanto, as configurações utilizadas para o algoritmo de VM foram as seguintes: (i) detecção de objetos de cor escura; (ii) *threshold* na intensidade 75; (iii) ignorar as lacunas nos objetos; (iv) ignorar objetos que tocam a borda da região de interesse (ROI); (v) tamanho mínimo de objeto 300 (área em pixel²); (vi) sem determinação para tamanho máximo de objeto.

2.5. AMOSTRAS

Os ensaios de calibração foram realizados usando amostras de cerveja artesanal preparadas em fermentador caseiro utilizando leveduras da espécie *Saccharomyces Cerevisiae* e extrato de malte seco (DME, do inglês “Dry Malt

Extract”), em uma única batelada. Foi empregado o fermento comercial para produção de cerveja artesanal *Fermentis SafAle*® S-33, uma levedura usada para uma ampla variedade de cervejas especiais de alta fermentação, com características de floculação média e temperatura ideal para fermentação entre 15 °C e 26 °C. Já o extrato de malte seco 100% Pilsen (*DryBrew Liotécnica*®) foi utilizado com a intenção de facilitar o processo de produção da cerveja artesanal. Optou-se por não adicionar lúpulo ao mosto cervejeiro visto que esse ingrediente possui mais importância do ponto de vista sensorial, influenciando pouco na atividade fermentativa e na produção de biomassa. Ao todo, foram produzidos 5 L de malte utilizando 500 g de DME. Para a fermentação, utilizou-se 3 g de fermento polvilhado sobre o mosto a temperatura ambiente. As amostras foram colhidas do fermentador sem realizar agitação do mosto.

Nos testes de predição, quatro amostras com concentrações diferentes foram analisadas em triplicata, resultando num total de 12 medições. Para a preparação dessas amostras, as alíquotas do mosto cervejeiro foram tomadas em momentos aleatórios da fermentação e foram congeladas para serem utilizadas após a construção do modelo de calibração. As amostras foram descongeladas e repousaram até chegar à temperatura ambiente. Após isso, ambos os métodos (o de referência e o proposto) foram aplicados, conforme serão descritos nas sessões 2.6 e 2.7.

2.6. MÉTODO DE REFERÊNCIA


As análises de referência foram realizadas empregando o método da massa seca, similar ao descrito por Sonogo (2016). Aqui, em diferentes intervalos de tempo após o início da fermentação, uma alíquota de aproximadamente 10 mL do mosto foi recolhida. Desse volume tomado, alíquotas de 2 mL são colhidas e depositadas em triplicata em microtubos eppendorf previamente secados em estufa por 24 h e pesados, e que foram posteriormente centrifugados em centrífuga para microtubos (*Nano Spin 8*) numa velocidade de 7000 rpm durante 15 min. Após a centrifugação, tais microtubos foram utilizados para a realização do método alternativo, antes do descarte do sobrenadante. Após a realização do método proposto neste trabalho, foi efetuado o descarte do sobrenadante e a lavagem dos microtubos com água destilada. Em seguida, foram levados à estufa por mais 24 h e foram pesados após resfriamento até a temperatura ambiente dentro de um dessecador. A concentração da biomassa é determinada pela razão entre a diferença entre a massa seca do

microtubo com amostra menos a massa seca do mesmo microtubo sem a amostra, pelo volume usado por amostra (2 mL), como indicam as [Equações 1 e 2](#).

2.7. MÉTODO PROPOSTO

Para a determinação da concentração de biomassa pelo método proposto, foram aproveitadas as mesmas amostras do método padrão. O procedimento realizado foi resumido na [Figura 10](#). Vale destacar que os tubos foram colocados na centrífuga sempre na mesma orientação, com a dobra do microtubo sempre apontada para o centro, a fim de garantir uma repetibilidade no padrão de acomodação do material sedimentado que, devido à inclinação da centrífuga, tende a apresentar uma inclinação. Esta estratégia será mais bem detalhada na seção 3.1. do capítulo seguinte. Aqui, após a etapa de centrifugação, os microtubos foram inseridos na cela de detecção sempre na mesma orientação. Partindo sempre desta mesma posição, os microtubos foram rotacionados aproximadamente 90° três vezes e o algoritmo de visão de máquina foi utilizado para identificar e medir a área do sedimento referente a essas quatro “faces” após centrifugação. Por fim, foi realizada a média aritmética da área dessas “faces”, obtendo o valor médio de área de pixel² para cada amostra. A amostra, portanto, fora lavada e o procedimento padrão descrito na seção 2.6 foi realizado. A curva analítica foi produzida empregando amostras com nove níveis de concentração (0,0014 - 0,0107 g mL⁻¹).

Figura 10 - Concentração de biomassa pelo método proposto. (i) Coleta do mosto; (ii) coleta das amostras; (iii) centrifugação; (iv) verificação da área do sedimento utilizando visão de máquina.



Fonte: elaborado pelo autor.

2.8. AVALIAÇÃO ESTATÍSTICA

Neste estudo, foram realizados testes de análise de variância (ANOVA) para validar os modelos lineares baseados no método dos mínimos quadrados construídos para determinação da concentração da biomassa. Após essa etapa, foram conduzidos testes F para avaliação da falta de ajuste e de significância estatística da regressão nos modelos lineares com base nos resultados da ANOVA.

O teste de falta de ajuste compara a média quadrática de falta de ajuste (MQ_{faj}) com a média quadrática oriunda do erro puro (MQ_{ep}) para os vários níveis de uma variável x (neste caso, concentração de biomassa). Assim, se a razão $(MQ_{faj})/(MQ_{ep})$ for inferior ao valor crítico do ponto de distribuição F , associado aos graus de liberdade de (MQ_{faj}) e (MQ_{ep}) e para um determinado nível de confiança, conclui-se que o modelo não apresenta falta de ajuste. Neste cenário, as duas médias quadráticas refletirão apenas os erros aleatórios associados aos dados do experimento. No entanto, se a razão $(MQ_{faj})/(MQ_{ep})$ for superior ao valor crítico, o modelo apresenta falta de ajuste e necessita ser reestimado e revalidado (Andrade, 2012).

No teste de significância da regressão, a razão entre a média quadrática devido à regressão (MQ_{reg}) e a média quadrática residual (MQ_r) é comparada com o valor do ponto de distribuição F referente aos graus de liberdade de MQ_{reg} e MQ_r a um determinado nível de confiança estatística. Se o resultado da razão MQ_{reg}/MQ_r for superior ao valor crítico de F , conclui-se que a regressão é estatisticamente significativa. Do contrário, não é possível admitir a existência de uma relação funcional (linear, quadrática etc.) entre as variáveis que possa ser descrita pelo modelo (Andrade, 2012) Tanto para testes de falta de ajuste, quanto para testes de regressão, normalmente o nível de 95% de confiança é utilizado.

A curva de calibração também foi submetida ao teste de Cochran para avaliar o desvio bilateral das variâncias a um nível de significância de 5%, ou seja, avaliar a homo e heterocedasticidade dos dados. O teste é realizado utilizando a [Equação 3](#):

$$C = \frac{S_{max}^2}{\sum_{i=1}^m S_j^2} \quad \text{Eq. 3}$$

Em que S_{max}^2 é o maior valor de variância (variância máxima) dentre as variâncias das concentrações usadas na construção da curva analítica e $\sum_{i=1}^m S_j^2$ é o somatório de todas as variâncias. O valor calculado de C é comparado, então, com o valor crítico para o teste de Cochran para um valor de m (replicata para cada nível de concentração). Quando o valor calculado é maior que o valor crítico tabelado, as variâncias não são estatisticamente iguais, ou seja, há um comportamento heterocedástico. Do contrário, se o valor calculado for menor que o crítico, as variâncias são significativamente iguais para todas as concentrações da curva, indicando um comportamento homocedásticos dos dados (Estrella, 2023; Guarieiro et al, 2008).

Testes pareado são comumente aplicados quando se tem interesse em comparar dois métodos de análise na intenção de verificar se os resultados produzidos por eles são estatisticamente diferentes. Neste estudo, o teste t pareado foi utilizado para avaliar os resultados preditivos dos dois métodos. Esse teste se baseia na diferença, d, entre cada par de resultados obtidos pelos métodos, podendo ser calculado para n medidas, pela [Equação 4](#):

$$t = \bar{d}\sqrt{n}/S_d \quad \text{Eq. 4}$$

Onde $\bar{d}$ e S_d são a média e o desvio padrão em relação a diferença, d, entre os valores pareados (Costa, 2013).

Idealmente, os valores previstos pela aplicação de um modelo de calibração relacionam-se com os valores reais por uma linha reta com inclinação 1 e intercepto 0. No entanto, a presença de erros aleatórios e/ou sistemáticos em um procedimento analítico produz desvios deste cenário ideal. Neste estudo, para detectar esses possíveis vieses e avaliar a acurácia do método proposto, o teste de Região Elíptica de Confiança Conjunta (EJCR, do inglês, “*Elliptical Joint Confidence Region*”) foi aplicado nos dados das amostras de predição. Neste teste, a inclinação e o intercepto do gráfico dos valores reais versus valores previstos ($\hat{a}$ e $\hat{b}$) são comparados com valores ideais ($a = 0$ e $b = 1$, respectivamente), onde o limite da elipse é determinado com base na magnitude dos erros experimentais e no nível de confiança escolhido. A equação que descreve a região conjunta é ([Equação 5](#)):

$$n(a - \hat{a})^2 + 2 \left(\sum c_i \right) (a - \hat{a})(b - \hat{b}) + \left(\sum c_i \right)^2 (b - \hat{b})^2 = 2s^2 F_{\alpha, 2, n-2} \quad \text{Eq. 5}$$

Onde n é o número de pontos de dados, c_i são as concentrações reais, s^2 é a variância da regressão e $F_{\alpha, 2, n-2}$ é o valor crítico de F com 2 e com $(n - 2)$ graus de liberdade a um certo nível de confiança. Se a elipse (EJCR) gerada contempla o ponto ideal (1,0), conclui-se que vieses constantes e proporcionais estão ausentes do modelo para o nível de confiança escolhido (Costa, 2013).

Capítulo 3.


RESULTADOS E DISCUSSÃO

3. RESULTADOS E DISCUSSÕES

3.1. AQUISIÇÃO DE VÍDEO/IMAGEM NA CELA DE DETECÇÃO

A [Figura 11](#) apresenta as imagens obtidas durante o ensaio de calibração para determinação da concentração de biomassa empregando o algoritmo de visão de máquina com o plano de cor *Red* (R) do espaço de cores RGB. A região circular mostrada na Figura marca os limites da ROI que foi estabelecida para todas as análises. O retângulo vermelho em torno da região escura no fundo do microtubo (biomassa sedimentada) indica a área do sedimento que foi identificada e determinada pelo algoritmo.

Figura 11 - Imagens das amostras usadas na construção da curva de calibração para determinação da concentração de biomassa utilizando VM para quantificar a área do sedimento. Concentrações, em gmL^{-1} , foram: a) 0,0014; b) 0,0016; c) 0,0022; d) 0,0026; e) 0,0057; f) 0,0061; g) 0,0080; h) 0,0083; i) 0,0107.



Fonte: elaborado pelo autor.


Como pode ser observado na [Figura 11](#), o algoritmo de visão de máquina reconheceu adequadamente o volume de sedimento formado no fundo dos microtubos, mesmo nas concentrações mais baixas. Essa afirmação se baseia na percepção do aumento da região retangular vermelha que contorna a biomassa (região escura) no campo visual do analisador. Durante as medidas, a altura dos microtubos em relação ao campo visual da ROI não interferiu na capacidade de reconhecimento do algoritmo. A distância entre o microtubo e a *webcam*, no entanto, permaneceu a mesma durante toda a análise visto que esta posição é fixa, garantida pela estrutura do analisador. Independentemente da conformação geométrica formada pelo sedimento, a área total (pixel^2), parâmetro registrado pelo analisador, sempre foi diretamente proporcional ao volume dos sedimentos, como será apresentado mais adiante neste capítulo.

A [Figura 11](#), porém, apresenta apenas uma das quatro faces do microtubo que foram investigadas, visto que, neste estudo, para cada amostra, quatro registros foram

tomados variando a posição do microtubo em 90° de uma posição para outra, partindo sempre da mesma posição e girando sempre no mesmo sentido (horário), como está ilustrado na [Figura 12](#). O resultado da área de pixels² de cada replicata foi, portanto, calculado utilizando a média aritmética dos valores das áreas referentes a cada uma das quatro faces. O mesmo procedimento foi feito em triplicata para todas as amostras.

A necessidade de trabalhar registrando as quatro faces de cada eppendorf veio da observação, em estudos prévios, de que a biomassa decantada no fundo dos microtubos após centrifugação compactava-se sempre de forma inclinada. Isso acontecia em decorrência da posição inclinada que os tubos adotavam ao serem alocados nos compartimentos da centrífuga disponível para realização do trabalho. Portanto, como a biomassa no fundo do microtubo não apresentava homogeneidade na sua sedimentação, as soluções encontradas serão explicadas a seguir.

Figura 12 - Posição dos microtubos no analisador para a aquisição dos dados, tomando como referência a dobra da tampa. a) Posição 1; b) Posição 2; c) Posição 3; e d) Posição 4.




Fonte: elaborado pelo autor.

A estratégia para superar o problema da falta de homogeneidade na sedimentação da biomassa passou, primeiramente, pela padronização da posição dos microtubos quando alocados nos compartimentos da centrífuga. Todos os microtubos foram alocados na centrífuga com a dobra da tampa do eppendorf voltada para o centro do equipamento, como ilustrado na [Figura 13](#).

Esse simples ajuste fez com que a força centrífuga atuasse sempre no mesmo sentido (para “fora” do centro) em relação a todos os microtubos, especificamente no sentido oposto às dobras das tampas. Dessa forma, o perfil de inclinação adquirido pela biomassa após a centrifugação foi padronizado e sempre esteve orientado em direção à parede oposta à dobra da tampa dos tubos. Além do ajuste fixo de suas posições na centrífuga, os microtubos também foram alocados em posições específicas dentro do analisador para a aquisição dos dados da imagem, como já foi comentado e ilustrado na [Figura 12](#).


Figura 13 - Posicionamento dos microtubos na centrífuga destacando a dobra das tampas dos microtubos (em verde) voltadas para o eixo do equipamento.



Fonte: elaborado pelo autor.

A adoção dessa proposta metodológica gerou resultados bastante positivos, apesar de ter tornado o processo ligeiramente mais custoso. Na [Figura 14](#) são apresentadas imagens referentes a realização da análise de uma das três replicatas de uma das amostras utilizadas na predição ($7,646 \times 10^{-3}$ g/ml).

Figura 14 - As faces do microtubo vistas pelo analisador após centrifugação em quatro posições ortogonais entre si. a) Posição 1 inicial; b) Posição 2; c) Posição 3 e; d) Posição 4.



Fonte: elaborado pelo autor.

Ainda na [Figura 14](#), nas posições 1 (a) e 3 (c) é possível perceber a biomassa sedimentada inclinada na parede do microtubo após centrifugação. Já nas posições 2 (b) e 4 (d) o registro foi tomado sempre de frente (e de trás) para a inclinação do sedimento, impossibilitando a visualização da inclinação. Feito isso, uma média aritmética com os valores de área das quatro faces foi realizada, gerando uma área de pixels² média daquela replicata. O mesmo procedimento foi feito para todas as amostras e soluções padrão.


Feitas essas considerações, é válido salientar alguns aspectos que podem ser observados nas [Figuras 11 e 14](#), onde as imagens registradas pelo analisador são apresentadas. O primeiro ponto a se destacar é que o sistema de iluminação projetado para o analisador evitou a formação de sombras no plano de fundo da imagem, que poderia ser um interferente para este tipo de análise. A distribuição da iluminação no interior do analisador colaborou para que a câmera registrasse um vídeo com um contraste adequado entre o objeto a ser detectado e o fundo, livre de ruídos, favorecendo uma boa segmentação.

3.2. CONSTRUÇÃO DA CURVA E VALIDAÇÃO

As amostras utilizadas para a construção da curva de calibração foram coletadas do mosto cervejeiro nos seguintes intervalos de tempo após o início da fermentação: 3; 8; 21; 28; 34; 45; 56; 70 e; 78 horas. Estas foram submetidas tanto ao método da massa seca quanto ao método proposto. O perfil da concentração da biomassa obtido ao longo do tempo traçado pelo método da massa seca está apresentado na [Figura 15a](#). Para comparação visual, a [Figura 15b](#) apresenta o perfil de crescimento da área de pixels² média dos mesmos pontos.

Aqui é possível notar que o crescimento da área de pixels² média do sedimento possui um perfil bastante similar e proporcional ao perfil de crescimento da concentração da biomassa, sendo, portanto, perfis sobreponíveis. Essa observação é interessante visto que o perfil de crescimento da biomassa ao longo do tempo de fermentação é um dos principais indicativos das fases de desenvolvimento da levedura (*lag*, *log*, estacionária e morte). Tal similaridade entre as técnicas indica, portanto, que o método proposto pode ser utilizado para esse tipo de monitoramento em tempo real, sem a necessidade da aplicação do método da massa seca. Para confirmar essa hipótese, no entanto, estudos posteriores ainda devem ser realizados.

Figura 15 - (a) Perfil da concentração de biomassa ao longo do tempo utilizando o método da massa seca e o (b) perfil da área de pixels² registrada ao longo pelo método alternativo após o início da fermentação.



Fonte: elaborado pelo autor.

A [Tabela 1](#) apresenta um resumo estatístico dos resultados obtidos na validação do modelo por Análise de Variância, onde estão colocados os valores das somas e das médias quadráticas da regressão, dos resíduos, da falta de ajuste e do erro puro.

Tabela 1- Resultados obtidos pela aplicação da ANOVA.

Fonte	Soma Quadrática	GL	Média Quadrática
Regressão	$2,020 \times 10^8$	1	$2,020 \times 10^8$
Resíduos	$3,087 \times 10^6$	25	$1,230 \times 10^5$
Falta de ajuste	$1,381 \times 10^6$	7	$1,973 \times 10^5$
Erro puro	$1,706 \times 10^6$	18	$9,478 \times 10^4$
Total	$2,051 \times 10^8$	26	$7,887 \times 10^6$

Na [Tabela 2](#), são apresentadas a equação e o coeficiente de determinação (R^2) calculados para o modelo, e os resultados dos testes de regressão, falta de ajuste e homoscedasticidade.

Tabela 2 – Equação do modelo de calibração construído e os resultados dos testes de regressão, falta de ajuste e homoscedasticidade para a curva analítica.


Modelo de Calibração	Regressão		Falta de Ajuste	Homoscedasticidade	
$y = 857893x - 286,88$	Fcal	1635,89	2,08	Ccal	0,440
$R^2 = 0,9849$	Fcrit	4,24	2,58	Ccrit	0,478

A análise dos resultados indica que o modelo de calibração obtido foi estatisticamente significativo e sem falta de ajuste, de acordo com os valores de F calculados pela ANOVA, indicando que a diferença média nas respostas entre esses modelos não foi significativa a um nível de confiança de 95%. O coeficiente de determinação (R^2) para o modelo obteve um resultado próximo da variância máxima explicável (0,9917), indicando que os dados estão bem próximos da linha de regressão ajustada. Neste caso, esse bom resultado para o coeficiente de determinação indica um modelo de regressão bem ajustado, em que 98,49% da variação total em torno da média é explicada pela regressão, deixando apenas 1,51% para os resíduos.

O teste de homoscedasticidade (Teste de Cochran) também foi utilizado para avaliar se os erros possuem uma variância homogênea ao longo da curva. O valor calculado (Ccal) deve ser comparado ao valor crítico (Ccrit) ao nível de significância de 5% levando em conta o número de pontos e o número de réplicas. Caso $Ccal < Ccrit$, aceita-se a hipótese nula e os dados podem ser considerados homocedásticos. Neste caso, como pode ser observado na [Tabela 2](#), a hipótese de que os dados são de fato, homocedásticos foi confirmada. Isto também pode ser observado analisando o gráfico dos resíduos apresentado a seguir.

Na [Figura 16](#) é apresentada a curva de calibração obtida por regressão linear entre as concentrações de biomassa e as suas respectivas áreas de sedimento (pixels²) ([Figura 16a](#)) e o gráfico dos resíduos do modelo ([Figura 16b](#)). Observando a curva, pode-se perceber o bom ajuste obtido na etapa de calibração, já abordado anteriormente. Ao lado, é possível notar, no gráfico de resíduos uma distribuição aleatória dos valores em torno do zero, como bem indicou o teste de homoscedasticidade realizado aqui.

Figura 16 - Curva analítica e gráfico dos resíduos para determinação de concentração de biomassa empregando o algoritmo de visão de máquina. a) curva analítica; b) gráfico dos resíduos.




Fonte: elaborado pelo autor.

Para o teste de predição foram utilizadas quatro amostras de concentração 4,308, 4,504, 7,646 e 6,417 ($\times 10^{-3}$ g/ml). Para validação, um teste t-pareado foi realizado, onde foi obtido um valor de t calculado ($t_{cal} = 2,0464$), com t crítico ($t_{crit} = 2,353$) para um nível de significância de 5%. O critério para aceitação da hipótese nula ($t_{cal} < t_{crit}$) foi aceito, indicando que não há diferença estatística real entre os valores preditos pelo modelo e os valores das reais de concentrações da amostra.

A [Figura 17](#) resume a acurácia das predições do modelo com o teste de região elíptica de confiança conjunta (EJCR). Aqui, é possível notar que a elipse de confiança do modelo contém o ponto teórico ideal em um nível de confiança de 95%, indicando que o modelo é preciso e exato, sem a presença de vieses.

Figura 17 - Teste de região elíptica de confiança conjunta (EJCR) do modelo para determinação da concentração de biomassa utilizando algoritmo de visão de máquina.



Fonte: elaborado pelo autor.

De forma geral, a faixa de trabalho experimentada neste trabalho vai de 0,0014 g/mL a 0,0107 g/mL, com RMSE de 0,0006 g/mL para a etapa de calibração. Isso significa que, em média, o modelo está cometendo um erro de apenas 0,0006 g/mL em relação aos valores reais. É possível que o limite superior da faixa de trabalho possa ser expandido sem grandes problemas, visto que a sedimentação de mais biomassa nos microtubos poderia ser visualizada e analisada ajustando a ROI. Para o limite inferior, no entanto, quantidades menores de biomassa nos microtubos podem acabar gerando problemas de segmentação devido à possibilidade de haver uma confusão na leitura do algoritmo de visão de máquina, visto que na extremidade do fundo do próprio microtubo há algumas regiões escuras que podem interferir na análise, sendo de suma importância que novos estudos com esse viés sejam realizados.

O tempo total de análise para a determinação da concentração de biomassa foi medido durante a etapa de predição, adotando as medidas em triplicata de cada amostra. A primeira etapa foi a coleta das amostras do mosto cervejeiro. O processo de coleta de uma parte do mosto, pipetagem dos 2 mL para cada replicata e

distribuição dos microtubos na centrífuga, somados ao próprio tempo de centrifugação leva aproximadamente 15 min e 30 s. O tempo médio para a leitura do sinal analítico das quatro faces dos três microtubos foi de aproximadamente 70s.

Em suma, o método proposto reduziu o tempo de análise de mais de 24 horas para 16 minutos e 40 segundos. O volume amostral permaneceu o mesmo, de 2 mL por amostra, que já configura uma quantidade pouco problemática. Nessa perspectiva, o método proposto utilizando um analisador baseado em visão de máquina tem potencial para ser uma solução relevante para a determinação da concentração de biomassa em mostos cervejeiros e em outras matrizes.

Capítulo 4.

CONCLUSÕES

4. CONCLUSÕES

Neste estudo, foi apresentado um método analítico baseado na tecnologia de visão de máquina para a determinação de concentração de biomassa durante o processo de fermentação cervejeira. Para isso, foi desenvolvido um analisador que incorpora sistemas de controle de iluminação e captura de filmes digitais, um *software* de controle com interface didática contando com sistema de amostragem de frames de vídeo.

A utilização do algoritmo de visão de máquina apresentou resultados promissores, permitindo a construção de um modelo estatístico de regressão linear bem ajustado. O modelo construído foi avaliado e comprovou-se que não há diferenças estatísticas entre o método proposto e o método de referência. O método proposto reduziu o tempo de análise de mais de 24 horas do método de referência para aproximadamente 17 min, além de extinguir a necessidade da realização de diversas etapas laboriosas, principalmente as mais demoradas, como os processos de secagem das amostras.

Dessa forma, a instrumentação e o método desenvolvidos podem ser considerados uma alternativa importante para a determinação da concentração de células no decorrer do processo de produção cervejeira, além de abrir portas para a implementação dessa mesma metodologia voltada para outros tipos de bebidas que empregam o processo de fermentação, destacando-se na velocidade de análise e no baixo custo de implementação e explorando recursos da indústria 4.0, como processamento inteligente, miniaturização de processos e visão de máquina.

Estas perspectivas representam um caminho promissor e abrem novas possibilidades de aplicações para a tecnologia desenvolvida neste estudo, indo além da produção cervejeira, mas com o potencial de abraçar todo um nicho de produção de bebidas que necessitam desse tipo controle. Para além disso, também é possível vislumbrar essa proposta metodológica se estendendo ao controle da reprodução de outros microorganismos, como bactérias, nas áreas de fronteira da química analítica.

REFERÊNCIAS BIBLIOGRÁFICAS

Alonso, V. et al. **Industry 4.0 implications in machine vision metrology: An overview.** Procedia Manufacturing, v. 41, p. 359–366, 2019.

Andrade, S. I. E. **Um analisador fluxo-batelada baseado em imagem digital para determinação de Al(III) e Cr(VI) em águas.** Dissertação (Mestrado). Programa de Pós-Graduação em Química, Universidade Federal da Paraíba. João Pessoa, 2012.

Andrés-Toro, B. et al. **A kinetic model for beer production under industrial operational conditions.** Mathematics and Computers in Simulation, v. 48, n. 1, p. 65–74, 1998.

Araújo, B. G. F. **Sistema de visão de máquina para detecção e localização de peças utilizando Raspberry Pi.** Dissertação (Mestrado em Engenharia Elétrica). Programa de Pós-graduação em Engenharia Elétrica, Instituto Federal da Paraíba. João Pessoa, p. 106. 2019.

Batchelor, B. G. **Machine vision handbook.** Londres: Springer, 2012. DOI: 10.1007/978-1-84996-169-1.

Beyerer, J.; Léon, F. P.; Frese, C. **Machine Vision. Automated visual inspection: Theory, practice and applications.** Heidelberg: Springer-Verlag, 2016. DOI: 10.1007/978-3-662-47794-6.

Brasil. **Ministério da Agricultura, Pecuária e Abastecimento. Anuário da cerveja: 2021.** MAPA/SDA, Brasília, 2022.

Cambridge in colour. **Profundidade de bits.** Cambridge in colour: a learning community for photographers, 2005. Disponível em: <<https://www.cambridgeincolour.com/pt-br/tutoriais/bit-depth.htm#:~:text=A%20profundidade%20de%20bits%20é,utilizados%20para%20especificar%20cada%20cor.>> Acesso em: 08 de nov. de 2023.

Cernuda, C. et al. **Improved quantification of important beer quality parameters based on nonlinear calibration methods applied to FT-MIR spectra.** Analytical and Bioanalytical Chemistry, v. 409, n. 3, p. 841–857, 2017.

CERVBRASIL. **Dados do setor cervejeiro nacional.** Disponível em:

<http://www.cervbrasil.org.br/novo_site/dados-do-setor/>. Acesso em: 24 maio. 2023.

Chapman, J. et al. **Spectroscopic approaches for rapid beer and wine analysis**. Current Opinion in Food Science, v. 28, p. 67–73, 2019.

Costa, R. C. **Determinação de parâmetros (sólidos solúveis, pH e acidez titulável) em ameixas intactas usando espectroscopia no infravermelho próximo e seleção de comprimento de onda**. Dissertação (mestrado). Programa de Pós-Graduação em Química. Instituto de Química. Universidade Federal do Rio Grande do Norte. Natal, 2013.

Dias, M. **Heineken Brewing Industry in Brazil**. International Journal of Management, Technology And Engineering, v. 8, n. November, p. 1304–1310, 2018.

Dias, M. O.; Falconi, D. The Evolution of Craft Beer Industry in Brazil. **Journal of Economics and Business**, v. 1, n. 4, 2018.

Emmer, C.; Glaesner, K.; Pfouga, A.; Stjepandić, J. **Advances in 3D Measurement Data Management for Industry 4.0**, Procedia Manufacturing, Volume 11, 2017, 1335-1342, doi: 10.1016/j.promfg.2017.07.262.

Estrella, B. C. L. **Estudo de casos de aplicabilidade do teste t-pareado e da regressão linear pelo método dos mínimos quadrados: uma abordagem estatística aplicada à Química Analítica**. Trabalho de conclusão de curso (graduação). Instituto de Química, Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2023.

Feliciano, F. F.; Souza, I. L.; Leta, F. R. **Visão computacional aplicada à metrologia dimensional automatizada: considerações sobre sua exatidão**. Engevista, Rio de Janeiro, v. 7, n. 2, p-38-50, 2005.

Gee, D. A. **Modeling, optimal control, state estimation, and parameter identification applied to a batch fermentation process**. [s.l.] University of Colorado, 1990.

Gee, D. A.; Ramirez, W. F. **A FLAVOUR MODEL FOR BEER FERMENTATION**.

Journal of the Institute of Brewing, v. 100, n. 5, p. 321–329, 10 set. 1994.

Gianezini, M. et al. **An Overview on the Production and Quality of Craft Beer in Brazil: Strategic Planning, Perspectives and Market Trends.** International Multilingual Journal Of Contemporary Research, v. 6, n. 2, p. 1–10, 2018.

Gonzalez, R. C.; Woods, R. E. **Digital Image Processing.** 3ª edição. New Jersey: Prentice Hall, 2008.

Groover, M. P. **Automation, Production Systems, and Computer-Integrated Manufacturing.** 3º ed. Pearson-Prentice Hall, 2008.

Guarieiro, L. L. N., Pinto, A. C., Aguiar, P. F. de., & Ribeiro, N. M. **Metodologia analítica para quantificar o teor de biodiesel na mistura biodiesel: diesel utilizando espectroscopia na região do infravermelho.** Química Nova, 31(2), 421–426, 2008.

Hornberg, A. **Handbook of machine vision.** Weinheim: WILEY-VCH Verlag GmbH & Co KGaA, 2006. ISBN-10: 3-527-40484-8.

Instituto Adolf Lutz. **Métodos físico-químicos para análise de alimentos.** 4. ed. São Paulo: Instituto Adolf Lutz, 2008.

Klein, O. et al. The good vibrations of beer. The use of infrared and UV/Vis spectroscopy and chemometry for the quantitative analysis of beverages. **Zeitschrift fur Naturforschung - Section B Journal of Chemical Sciences**, v. 67, n. 10, p. 1005–1015, 2012.

Marc, I. et al. **Kinetics of Yeast Growth and Metabolism in Beer Fermentation.** p. 489–500, 1983.

Newman, T. S.; Jain, A. K. **A survey of automated visual inspection.** Computer vision and image understanding, Elsevier, v. 61, n. 2, p. 231-262, 1995.

Nogueira, A.;Filho, W. **Aguardente De Cana.** [s.l.] UNIVERSIDADE ESTADUAL PAULISTA - CAMPUS DE BOTUCATU, 2005.

Oliveira, B. C. F. **Desenvolvimento de sistemas de visão computacional para medição e inspeção de estatores**. Dissertação (mestrado). Programa de pós-graduação em engenharia mecânica. Universidade Federal de Santa Catarina, Florianópolis, p. 175, 2015.

Ramos, R O. et al. A video processing and machine vision-based automatic analyzer to determine sequentially total suspended and settleable solids in wastewater. **Analytica Chimica Acta**, v. 1206, 2022.

Ramos, R. O. **Desenvolvimento de um multianalisador automático baseado em visão de máquina e processamento de vídeo para determinação sequencial do teor de sólidos suspensos totais e sedimentáveis em águas residuárias**. Tese (doutorado em química analítica). Programa de pós-graduação em química analítica. Universidade Federal da Paraíba. João Pessoa, 2021.

Rußmann, M.; Lorenz, M.; Gerbert, P.; Waldner, M.; Engel, P.; Harnisch, M.; Justus, J. Industry 4.0: **The future of productivity and growth in manufacturing industries**. Abril 2015. Disponível em: <https://www.bcg.com/publications/2015/engineered_products_project_business_industry_4_future_productivity_growth_manufacturing_in_dustries>. Acesso em: 3 de novembro de 2023.

Salanta, L. C. et al. **Non-Alcoholic and Craft Beer Production and Challenges**. p. 1–23, 2020.

Santos, F. C. **Métodos de Monitoramento de Fermentação Alcoólica**. Orientadora: Thais Suzane Milessi Esteves. 2022. 98 f. TCC (Graduação). Curso de Engenharia Química, Departamento de Engenharia Química, Universidade Federal de São Carlos, São Carlos, 2022.

Scariot, W. K. **Desenvolvimento de sistema de visão de máquina baseado em técnicas de segmentação para inspeção automatizada de motores elétricos**. Dissertação (mestrado). Programa de pós-graduação em Engenharia Mecânica, UFSC, Florianópolis, 2017.

SEBRAE. **1º Censo das Cervejarias Independentes Brasileiras**. Disponível em:

<<https://conteudo.abracerva.com.br//ZypGd2ABF1173>>. Acesso em: 7 jun. 2023.


Silva, C. G. **Otimização da fabricação da aguardente de algaroba e aproveitamento de resíduos sólidos em produtos alimentares**. Tese (doutorado). Universidade Federal da Paraíba, João Pessoa, 2009.

Sonego, J. L. S. **Estudo da produção de etanol de sacarose por fermentação extrativa utilizando arraste com dióxido de carbono**. Tese (doutorado) em Engenharia Química, Universidade Federal de São Carlos, São Carlos, 2016.

Veloso, I. I. K. **Uso de diferentes técnicas de medida da concentração celular de *Saccharomyces cerevisiae* em meio fermentativo**. Trabalho de graduação em Engenharia Química – Universidade Federal de São Carlos, São Carlos, 2017.


MATERIAL SUPLEMENTAR

Figura S1 – Desenho técnico indicando as dimensões da parte interna do analisador desenvolvido no projeto.



Fonte: elaborado por autor e colaboradores.

Figura S2 – Desenho técnico indicando as dimensões da parte externa (tampa) do analisador desenvolvido no projeto.



Fonte: elaborado por autor e colaboradores.