



ANÁLISE DE IMAGENS E SONS

COMO UMA PERSPECTIVA DE INOVAÇÃO
NA PÓS-COLHEITA DO LÚPULO



2026

Victor Crespo de Oliveira, Sergio Augusto Rodrigues, Leonardo França da Silva, José Rafael Franco, Valeria Cristina Rodrigues Sarnighausen, Arthur Carniato Sanches, Cristiano Marcio Alves de Souza

**Victor Crespo de Oliveira
Sergio Augusto Rodrigues
Leonardo França da Silva
José Rafael Franco
Valeria Cristina Rodrigues Sarnighausen
Arthur Carniato Sanches
Cristiano Marcio Alves de Souza**

Análise de imagens e sons como uma perspectiva de inovação na pós-colheita do lúpulo

1ª EDIÇÃO



SÃO LUÍS - 2026



EDITORA NOVUS

SÃO LUÍS - MA - 2026

 WWW.EDITORANOVUS.COM.BR  EDITORANOVUS@GMAIL.COM

Diagramação e Edição

Eduardo Mendonça Pinheiro

Edição de Arte

Romilson Carneiro Rodrigues

Normalização

José Marcelino Nascimento Veiga Júnior

Conteudista

Victor Crespo de Oliveira

Sergio Augusto Rodrigues

Leonardo França da Silva

José Rafael Franco

Valeria Cristina Rodrigues Sarnighausen

Arthur Carniato Sanches

Cristiano Marcio Alves de Souza

© 2026 Copyright – Direitos reservados. A Editora Novus é detentora dos direitos autorais relativos à edição, diagramação e ao projeto gráfico da presente obra. Os autores permanecem titulares dos direitos autorais de seus respectivos textos. Esta publicação está licenciada sob a Creative Commons Atribuição 4.0 Internacional (CC BY 4.0), permitindo a reprodução, o download e o compartilhamento total ou parcial do conteúdo, desde que a fonte seja devidamente citada, com atribuição obrigatória de autoria, e que a obra seja disponibilizada exclusivamente em Acesso Aberto (Open Access). Não é permitida qualquer forma de alteração, adaptação ou modificação do conteúdo, bem como sua disponibilização em plataformas de acesso restrito ou com finalidade comercial.



Dados Internacionais de Catalogação na Publicação (CIP)

O48a

Oliveira, Victor Crespo de

Análise de imagens e sons como uma perspectiva de inovação na pós-colheita do lúpulo. / Victor Crespo de Oliveira [et al.]. – São Luís: Editora Novus, 2026.

51 f.: il. color.

Publicação digital (e-book) no formato PDF

ISBN: 978-65-84364-36-3

DOI: 10.29327/5836845

1. Pós-colheita. 2. Lúpulo. 3. Secagem. 4. Análise de Imagens. 5. Aprendizado de Máquina. I. Rodrigues, Sergio Augusto. II. Silva, Leonardo França da. III. Franco, José Rafael. IV. Sarnighausen, Valeria Cristina Rodrigues. V. Sanches, Arthur Carniato. VI. Souza, Cristiano Marcio Alves de. VII. Título.

CDU: 631.56

Elaborado por José Marcelino Nascimento Veiga Júnior – CRB 13/320

CONSELHO EDITORIAL

Dr^a Anali Linhares Lima
M.Sc. Alan Jefferson Lima de Moraes
Dr. André Leonardo Demaison Medeiros Maia
Dr^a Anna Christina Sanazario de Oliveira
Dr^a Aurea Maria Barbosa de Sousa
Dr^a Camila Pinheiro Nobre
Dr. Claudio Alves Benassi
Dr. Cleiseano Emanuel da Silva Paniagua
Dr^a Claudiene Diniz da Silva
Dr. Diogo Guagliardo Neves
M.Sc. Eduardo Oliveira Pereira
Dr^a Elba Pereira Chaves
Dr. Elmo de Sena Ferreira Junior
M.Sc. Érica Mendonça Pinheiro
Dr. Fabio Antonio da Silva Arruda
M.Sc. Fernanda Tabita Barroso Zeidan
Dr. George Alberto da Silva Dias
Dr^a Gerbeli de Mattos Salgado Mochel
Dr^a Giselle Cutrim de Oliveira Santos
Dr^a Herlane de Olinda Vieira Barros
Dr^a Ivete Furtado Ribeiro Caldas
M.Sc. José Carlos Durans Pinheiro
M.Sc. Josiney Farias de Araújo

M.Sc. Julianno Pizzano Ayoub
M.Sc. Lucianna Serfaty de Holanda
Dr^a Luciara Bilhalva Corrêa
Dr^a Luana Martins Cantanhede
Dr^a Maria Raimunda Chagas Silva
Dr^a Marina Bezerra Figueiredo
M.Sc. Mayanne Camara Serra
Dr^a Michela Costa Batista
Dr. Moisés dos Santos Rocha
Dr^a Priscila Xavier de Araújo
M.Sc. Ramaiany Carneiro Mesquita
Dr^a Rita de Cássia Silva de Oliveira
M.Sc. Rosany Maria Cunha Aranha
Dr. Saulo José Figueiredo Mendes
Dr^a Samantha Ariadne Alves de Freitas
Dr^a Sandra Imaculada Moreira Neto
M.Sc. Shirley Ribeiro Carvalho
Dr^a Sinara de Fátima Freire dos Santos
M.Sc. Tatiana Mendes Bacellar
Dr^a Thais Roseli Corrêa
Dr^a Thalita Karolline de Queiroz Pereira
Dr. Wellington de Assunção
Dr. William de Jesus Ericeira Mochel Filho

Acesse www.editoranovus.com.br/corpo-editorial-2/ para conhecer os membros do Corpo Editorial

Parecer editorial e avaliação por pares

Os trabalhos que integram esta obra foram submetidos à apreciação do Conselho Editorial da Editora Novus e avaliados por pareceristas externos, por meio do sistema de revisão por pares (peer review), tendo sido considerados aptos para publicação.

Nota editorial: Trata-se de uma produção de caráter independente, na qual os direitos autorais permanecem sob a titularidade de seus respectivos autores. Eventualmente, alguns textos podem apresentar desdobramentos de pesquisas, comunicações ou trabalhos acadêmicos previamente apresentados ou defendidos, cabendo aos autores a observância rigorosa das boas práticas acadêmicas, especialmente no que se refere à prevenção do autoplágio. O conteúdo das obras é de responsabilidade exclusiva dos autores, não refletindo, necessariamente, o posicionamento da Editora Novus, dos organizadores, dos revisores ou dos membros do Conselho Editorial.

PREFÁCIO

A cadeia produtiva do lúpulo (*Humulus lupulus* L.) tem ganhado destaque no Brasil em função da expansão do setor cervejeiro e do crescente interesse pelo cultivo da cultura em regiões fora de seu ambiente tradicional. Nesse contexto, a etapa de pós-colheita, especialmente o processo de secagem dos cones, assume papel fundamental na preservação dos compostos aromáticos e óleos essenciais responsáveis pela qualidade sensorial do produto. O controle e o monitoramento desse processo, no entanto, ainda representam um desafio, uma vez que os métodos convencionais de avaliação da umidade são, em geral, demorados, pouco automatizáveis e limitados para aplicações em tempo real.

Diante desse cenário, este livro propõe uma abordagem conceitual voltada à discussão das possibilidades de aplicação da análise de imagens e do processamento de sinais sonoros na cadeia da pós-colheita do lúpulo. A obra se fundamenta em uma revisão da literatura, integrando conhecimentos das áreas de agronomia, engenharia agrícola, ciência de dados e engenharia de sinais, com o objetivo de apresentar os princípios, fundamentos e potenciais dessas tecnologias no contexto agrícola.

Ao longo dos tópicos, são discutidos os fundamentos do processamento e da análise digital de imagens, com ênfase nos principais atributos passíveis de extração, como características de cor, textura e forma, e suas relações com propriedades físicas e estruturais dos cones de lúpulo. O livro também apresenta à análise de dados sonoros, que emerge como uma das abordagens mais atrativas e promissoras no contexto da pós-colheita do lúpulo. Nesse sentido, são explorados os princípios da caracterização das ondas acústicas e a extração de atributos nos domínios do tempo, da frequência e do tempo-frequência. São discutidos exemplos e aplicações dessas técnicas em diferentes áreas da agricultura e da agroindústria, demonstrando como sinais sonoros podem ser utilizados para caracterizar produtos, monitorar processos e identificar padrões associados a propriedades físicas e estados de transformação da matéria-prima.

O texto também aborda, de maneira introdutória, o papel da modelagem estatística e do aprendizado de máquina como ferramentas de apoio à análise e integração dos atributos extraídos de imagens e, sobretudo, de sons. Ressalta-se que o objetivo da obra não é apresentar essas tecnologias de forma exaustiva, nem propor soluções prontas ou sistemas de aplicação imediata. Ao contrário, busca-se lançar luz sobre possibilidades reais de aplicação de técnicas já consolidadas, posicionando o livro como um elo entre diferentes áreas do conhecimento, como a agronomia, a engenharia agrícola, a ciência de dados e a engenharia de sinais, e oferecendo uma base conceitual que favoreça a reflexão, o diálogo interdisciplinar e o desenvolvimento de pesquisas futuras na cadeia produtiva do lúpulo.

Boa leitura!

SUMÁRIO

PREFÁCIO	5
CAPÍTULO 1	7
INTRODUÇÃO	
CAPÍTULO 2	10
LÚPULO E O PROCESSO DE SECAGEM	
2.1 Caracterização da cultura do lúpulo e dos efeitos do processo de secagem sobre a qualidade do produto.....	11
2.2 Influência das variáveis do processo de secagem na qualidade do lúpulo...	12
CAPÍTULO 3	17
CONTEXTUALIZAÇÃO SOBRE PROCESSAMENTO E ANÁLISE DIGITAL DE IMAGEM	
3.1 Definição e etapas do processamento digital de imagens	18
3.2 Extração de atributos da imagem.....	20
CAPÍTULO 4	22
ASPECTOS TEÓRICOS DO PROCESSAMENTO E DA ANÁLISE DE SINAIS SONOROS E CONSIDERAÇÕES SOBRE O COMPORTAMENTO DO LÚPULO AO LONGO DO PROCESSO DE SECAGEM	
4.1 Caracterização das ondas sonoras.....	23
4.2 Extração de atributos de sinais sonoros.....	24
4.3 Aplicações do processamento de sinais sonoros em diferentes áreas do conhecimento.....	28
CAPÍTULO 5	30
FUNDAMENTOS DE APRENDIZADO DE MÁQUINA APLICADOS À MODELAGEM PREDITIVA	
5.1 Modelos de previsão.....	31
5.2 <i>Overfitting</i> e <i>Underfitting</i> em modelagem	33
5.3 Técnicas de aprendizado de máquina.....	34
5.4 Métodos de Aprendizado em Conjunto (<i>Ensemble</i>).....	35
5.4.1 <i>Ensacamento (Bagging)</i>	35
5.4.2 <i>Impulsionamento (Boosting)</i>	36
CAPÍTULO 6	38
CONCLUSÕES	38
REFERÊNCIAS	40
AUTORES	44



Análise de imagens e sons como uma perspectiva de
inovação na pós-colheita do lúpulo

1

INTRODUÇÃO



O lúpulo (*Humulus lupulus* L.) é uma planta trepadeira, perene e dioica, amplamente reconhecida por sua relevância na indústria cervejeira, em função de suas inflorescências femininas, conhecidas como cones, que concentram a glândula lupulina. Nessa estrutura encontram-se os alfa-ácidos, beta-ácidos e óleos essenciais responsáveis pelas características sensoriais de aroma, amargor e sabor das cervejas (Chadwick *et al.*, 2006; Bocquet *et al.*, 2018). Além de sua importância industrial, o lúpulo também apresenta aplicações nas áreas farmacêutica e medicinal, em virtude de suas propriedades antibacterianas, antissépticas, ansiolíticas e sedativas, entre outras (Lin *et al.*, 2019).

O cultivo do lúpulo está historicamente associado a regiões de clima temperado, situadas entre as latitudes de 35° e 55°, onde fatores como fotoperíodo e temperatura favorecem o desenvolvimento da cultura (Dodds, 2017; Bauerle, 2019). No Brasil, a introdução do lúpulo ocorre em um contexto climático distinto, marcado predominantemente por condições tropicais, o que impõe desafios relacionados à adaptação fisiológica da planta, ao manejo agrônômico e à condução dos processos pós-colheita (Leite; Pandolfo, 2022). Apesar dessas limitações, avanços recentes indicam a viabilidade do cultivo em diferentes regiões do país, impulsionados pelo crescimento do setor cervejeiro nacional e pela demanda crescente por matéria-prima de qualidade (Chagas; Garcia, 2018; CERVBRAZIL, 2021).

Nesse cenário, a etapa de secagem dos cones de lúpulo assume papel central na cadeia produtiva, uma vez que é determinante para a preservação dos compostos aromáticos e óleos essenciais responsáveis pela qualidade final do produto (Eyres; Dufour, 2009; Raut *et al.*, 2021). A literatura aponta que variações inadequadas nas condições de secagem, especialmente relacionadas à temperatura e à dinâmica do processo, podem resultar em perdas qualitativas significativas, reduzindo o valor agregado do lúpulo destinado à indústria cervejeira (Hofmann *et al.*, 2013; Pinto *et al.*, 2023). Assim, o monitoramento do processo de secagem e, em particular, do teor de umidade dos cones, torna-se um aspecto fundamental para garantir a qualidade do produto final.

Entretanto, os métodos tradicionais utilizados para a determinação da umidade do lúpulo baseiam-se em procedimentos laboratoriais que demandam tempo, são pouco flexíveis e apresentam limitações quanto à automação e ao monitoramento contínuo (ASBC, 1958). Essas restrições evidenciam a necessidade de explorar abordagens alternativas, capazes de fornecer informações de forma não destrutiva, rápida e potencialmente integrável aos sistemas produtivos.

Diante desse contexto, o avanço das tecnologias de aquisição de dados e das técnicas de análise computacional tem ampliado as possibilidades de aplicação da análise de imagem e do processamento de sinais sonoros na agricultura e na agroindústria. A literatura demonstra que atributos extraídos de imagens, como características de cor, textura e forma, bem como atributos acústicos relacionados aos domínios do tempo, da frequência e do tempo-frequência, podem carregar informações relevantes sobre propriedades físicas, estruturais e dinâmicas de produtos agrícolas (Stork *et al.*, 2010; Umbaugh, 2023; Knees; Schedl, 2016; Sueur, 2018). Esses atributos têm sido explorados em diferentes contextos, incluindo classificação, monitoramento de qualidade e avaliação de processos pós-colheita (Khalifa *et al.*, 2011; Kurtulmuş *et al.*, 2018; Sturm *et al.*, 2018).

No caso específico do lúpulo, a análise de dados de imagem e som surge como uma abordagem promissora para ampliar o entendimento sobre o com-

portamento dos cones ao longo do processo de secagem, permitindo identificar padrões associados às transformações físicas e estruturais que ocorrem durante a perda de umidade. Mais do que propor soluções operacionais imediatas, essas tecnologias oferecem um novo olhar analítico sobre a cadeia produtiva, possibilitando a construção de conhecimento a partir de dados multimodais e abrindo espaço para o desenvolvimento futuro de sistemas inteligentes e de apoio à tomada de decisão.

Nesse sentido, este livro tem como objetivo apresentar e discutir as possibilidades de aplicação da análise de dados de imagem e som na cadeia produtiva do lúpulo, com ênfase no processo de secagem. A obra não se propõe a aprofundar aspectos de implementação ou desenvolvimento de sistemas específicos, mas sim a contextualizar os fundamentos teóricos, os tipos de dados, os principais atributos extraíveis e as abordagens analíticas descritas na literatura. Ao estruturar-se a partir de uma revisão abrangente, o livro busca consolidar o estado da arte sobre o tema, fornecer subsídios conceituais para pesquisadores e profissionais da área e estimular novas investigações voltadas à integração entre agronomia, engenharia e ciência de dados no contexto da produção de lúpulo.



Análise de imagens e sons como uma perspectiva de
inovação na pós-colheita do lúpulo

2

LÚPULO E O PROCESSO DE SECAGEM



2.1 Caracterização da cultura do lúpulo e dos efeitos do processo de secagem sobre a qualidade do produto

Originária de regiões de clima temperado no hemisfério norte, o lúpulo (*Humulus lupulus*) é uma planta exótica que pertence à família *Cannabaceae*. Trata-se de uma trepadeira perene, notável por seu sistema radicular profundo e resiliente, adaptado para enfrentar diferentes condições de solo e clima. Sua intrínseca relação com o processo de produção de cerveja tem histórias profundamente enraizadas, remontando à Idade Média, quando o cultivo de lúpulo se tornou uma prática fundamental para a criação de cervejas (Spósito *et al.* 2019).

Avaliando a trajetória do lúpulo no contexto brasileiro, é possível observar um cenário em constante evolução (CERVBRASIL, 2021). A viabilidade do cultivo do lúpulo tem se tornado cada vez mais real nos últimos anos, marcando um novo capítulo na história da indústria cervejeira nacional (Texeira, 2022). Este progresso reflete os esforços incessantes de produtores e pesquisadores em adaptar e explorar as possibilidades da cultura do lúpulo em território brasileiro, considerando as particularidades do clima e do solo (Leite; Pandolfo, 2022; CERVBRASIL, 2021; Chagas; Garcia, 2018).

Os cones de lúpulo são dotados de uma composição intrincada, abrigando diversos componentes que desempenham papéis fundamentais para a produção da cerveja. Em seu conteúdo, encontram-se uma ampla gama de elementos, incluindo resinas, óleos essenciais, proteínas, polifenóis, lipídios, ceras, celulose e aminoácidos (Verzele, 1986; Ziegler; Hasan; Teodorov, 2022).

No tocante ao cone feminino da planta de lúpulo, as glândulas de lupulina são de extrema importância. Elas são as produtoras dos alfas e beta ácidos, assim como dos óleos essenciais. Segundo Schonberger e Kostelecky (2011), os betas ácidos contribuem com um toque de amargor à cerveja, porém são os alfas ácidos que acentuam o sabor amargo. Já os óleos essenciais conferem à cerveja o seu aroma distintivo e característico (Fagherazzi, 2020).

Uma análise mais profunda revela a presença de diversas classes químicas nos cones de lúpulo, como terpenos, álcoois, ésteres, aldeídos e cetonas (Dietz *et al.*, 2020). Notavelmente, os terpenos, especialmente os monoterpênicos como o miceno, limoneno e α -pineno, e os sesquiterpenos, dominam a composição dos óleos essenciais. No entanto, vale destacar que esses componentes são altamente voláteis e suscetíveis a polimerização e oxidação (Lorena; Juliano, 2017).

Neste sentido, o processo de secagem dos cones de lúpulo possui um impacto substancial na volatilização e oxidação desses componentes químicos. A exposição aos fatores envolvidos na secagem, como temperatura, umidade e fluxo de ar, pode levar à liberação volátil de compostos aromáticos, podendo ocorrer perdas de até 60% (Hofmann *et al.*, 2013). Essa volatilização pode resultar em mudanças nas características aromáticas dos cones de lúpulo, afetando sua qualidade final (Pinto *et al.*, 2023).

2.2 Influência das variáveis do processo de secagem na qualidade do lúpulo

Após a colheita, os cones precisam passar pelo processo de secagem. Este processo é uma etapa fundamental na cadeia de produção, podendo influenciar diretamente a qualidade e as características dos produtos derivados do lúpulo, como a cerveja. A secagem tem como objetivo principal a remoção da umidade presente nos cones de lúpulo, garantindo sua estabilidade, armazenamento adequado e preservação da quantidade de compostos aromáticos e óleos essenciais (Raut *et al.* 2021).

O teor de umidade do lúpulo recém-colhido varia entre 78% e 84% (base úmida). Para preservar sua qualidade e aumentar o prazo de validade, é essencial realizar o processo de secagem, reduzindo a umidade para aproximadamente 10% (Rybka *et al.*, 2017; Rybka *et al.*, 2021; Pinto *et al.*, 2023). A forma como essa secagem é conduzida assegura a manutenção das características desejáveis de aroma e sabor do lúpulo.

Pesquisas científicas recentes têm demonstrado que o uso de temperaturas mais baixas (cerca de 40°C) durante a secagem é essencial para preservar a qualidade do produto. De acordo com Pinto *et al.* (2023), temperaturas em torno de 40°C são mais adequadas para evitar a degradação dos compostos essenciais do lúpulo, garantindo sua excelência e potencial de uso na indústria cervejeira.

Por outro lado, temperaturas elevadas, acima de 65°C, podem comprometer significativamente a qualidade do lúpulo. Estudos demonstram que a exposição a temperaturas mais altas tende a reduzir o teor de alfa e beta ácidos, além de prejudicar a aparência dos cones, impactando diretamente suas propriedades e utilização na indústria cervejeira (Howard, 1958; Griesel, 1959; Henderson; Miller, 1972; Ziegler; Hasan; Teodorov, 2022; Pinto *et al.*, 2023).

Ao final do processo de secagem é necessário que o lúpulo seja mantido por pelo menos 24 horas em uma unidade de condicionamento para uniformização da umidade (Munsterer, 2006; Ziegler; Hasan; Teodorov, 2022), uma vez que a parte interna do cone permanece mais úmida do que a externa. É recomendado que a temperatura e umidade relativa do ar neste ambiente esteja entre 20-24°C e 58-65%, respectivamente (Munsterer, 2019).

Conforme listado na Tabela 1, o aumento da temperatura de secagem resulta na redução da qualidade do lúpulo, principalmente devido à diminuição da concentração de óleos essenciais. Assim, com base nos estudos apresentados (Tabela 1), a temperatura mais recomendada para o processo de secagem é de 50°C. Esses estudos indicam que a temperatura de 50 °C resulta em menores impactos na qualidade do lúpulo, além de proporcionar tempo de secagem viável para a produção, que pode variar entre 8 e 13 horas, dependendo do teor de umidade inicial, bem como da umidade relativa e velocidade do ar de secagem.

Vale ressaltar que temperaturas mais baixas (inferior a 50° C) podem afetar negativamente o processo de secagem, prolongando excessivamente o tempo necessário para a secagem, o que pode comprometer a eficiência e a viabilidade do processo. Por outro lado, não utilizar temperaturas maiores que 50°C no processo de secagem está relacionado principalmente à preservação da qualidade do lúpulo. Temperaturas muito altas podem acelerar o processo de secagem, no entanto, também causam danos à qualidade final do produto (Ziegler; Hasan;

Teodorov, 2022).

Sendo assim, a temperatura de 50°C para o processo de secagem é um valor que equilibra a preservação da qualidade do lúpulo e a eficiência operacional do processo de secagem.

Tabela 1. Avaliação entre temperatura de secagem e qualidade final do lúpulo

Autores [Local do estudo]	Cultivar do lúpulo	Tipo de secador	Características da secagem	Tempera- turas de secagem	Compostos Ava- liados	Redução da qualidade do lúpulo devido ao aumento da temperatura?	Observações
Pinto <i>et al.</i> (2023) [Brasil]	Mantiqueira	Forno secador (oven drier)	300 g massa úmi- da (100 g em cada prateleira); Velocidade do ar 6,6 m/s; Fluxo de ar 0,013 m ³ /s	40, 55 e 70°C	Xanthohumol, Co- lupulone, N+Adhu- mulone, Alfa ácido total, N+Adlupulo- ne, Cohumulone, Beta ácido total e óleo essencial total	Sim, foram registradas maiores perdas dos óleos essenciais à medida que a temperatura aumentou. Contudo, a temperatura não influenciou a composi- ção de Xanthohumol e Alfa e Beta ácidos.	Menores temperaturas podem aumentar até 20% o tempo de secagem. A secagem realizada a 70°C causou perda de 65,8% da concentração total de óleos essenciais.
Heřmánek <i>et al.</i> (2017) [República Tcheca]	Vital	Câmara secadora (chamber dryer)	23,8 kg massa úmida; Dimen- são da câmara de secagem (0,9x0,9x0,3m); Fluxo de ar 2500- 12,500 m ³ /h	40 e 55°C	Alfa e beta ácidos, Desme- thylxanthohumol e Hop Storage Index (HSI)	Sim, foi verificado drástica redução de Desmethylxan- thohumol (DMX) a medida que a temperatura amen- tou.	Umidade inicial 75% e final 12%. O aumento da tempera- tura de 40 para 55°C provo- cou aumento de 6% do HSI e redução de 33% de DMX
Rybka <i>et al.</i> (2018) [República Tcheca]	Saaz e Har- monie	Câmara secadora (chamber dryer)	25 kg massa úmida; Dimen- são da câmara de secagem (0,9x0,9x0,3m); Fluxo de ar 2500- 12,500 m ³ /h	40 e 55°C	β-Pinene, Myr- cene, Limonene, Linalool, Geraniol, 2-Undecanone, α-Caryophyllene, β-Farnesene, β-Hu- mulene, Selinenes, Caryophyllene epoxide, Humulene epoxide II	Sim, foram verificadas maiores perdas de óleos essenciais na maior tempe- ratura.	Umidade inicial 75% e final 10-9%. Em comparação com o lúpulo fresco, a quanti- dade de óleos de lúpulo diminuiu 10% quando seco a 40°C e 36% (cv. Saaz) e 43% (cv. Harmonie) quando seco a 55°C
Rybka <i>et al.</i> (2021) [República Tcheca]	Saaz, Sladek, Premiant, Agnus, Har- monie, Ru- bin, Kazbek e Vital	Câmara secadora (chamber dryer)	21 kg massa úmida; Dimen- são da câmara de secagem (0,9x0,9x0,3m); flu- xo de ar de 2500 a 12,500 m ³ /h	40 e 60°C	Óleo essencial total	Sim, foram verificadas maiores perdas de óleos essenciais na maior tempe- ratura.	Umidade final 10%. Ao redu- zir a temperatura o tempo de secagem aumentou em 20%. A secagem a 60 °C reduziu em 13,9% a concen- tração de óleos essencial quando comparada a tem- peratura de 40°C.

<p>Rubottom et al., (2023) [Estados Unidos]</p>	<p>Amarillo® e Simcoa® (Variedades populares americanas)</p>	<p>Forno comercial e de escala piloto</p>	<p>Dimensões do forno comercial (4,9x9,8 m - somente metade do forno foi utilizada) e de escala piloto (0,14x1,14x0,76 m)</p>	<p>49, 60, 71 e 82 °C</p>	<p>óleo essencial total, composição dos óleos, Alfa e beta ácidos, Hop Storage Index e análise sensorial</p>	<p>Sim, foram verificadas maiores perdas do volume de óleos essenciais e de notas sensoriais com maiores temperaturas de secagem. Contudo, os autores advogam que tais perdas não sacrificam a qualidade do aroma do lúpulo. Além disso, maiores temperaturas de secagem contribuem para o produtor, tendo em vista que o tempo desse processo é reduzido, o que permite processar maior quantidade de lúpulo, aumentando a capacidade produtiva.</p>	<p>Umidade final 10%. A secagem a 71°C demorou 5-6h, enquanto a 49°C demorou 10-13h. As temperaturas de 49 e 71°C que foram utilizadas para avaliação de todos os parâmetros.</p>
<p>Raut et al., (2020) [Alemanha]</p>	<p>Hallertauer Tradition</p>	<p>Secador em escala de planta piloto</p>	<p>Carregamento com diferentes volumes de lúpulo 15, 25 e 35 kg/m²</p>	<p>60 e 65°C</p>	<p>Óleos essenciais (Myrcene, linalool, β-caryophyllene e humulene)</p>	<p>Sim, o aumento de 60 °C para 65 °C causou as perdas de rendimento de óleo em cerca de 7% e perdas de 22%. de myrcene.</p>	<p>Umidade final 10 - 12%.</p>

Embora muito se saiba sobre a influência da secagem na qualidade do lúpulo, existem muitas lacunas de conhecimento que ainda precisam ser abordadas. Essas incluem, não apenas a determinação das condições ideais de operação da secagem, como temperatura de secagem e fluxo de ar, mas também o desenvolvimento de sistemas que produzam dados efetivos e possibilitem o controle inteligente do processo (Ziegler; Hasan; Teodorov, 2022).

A otimização do processo de secagem do lúpulo depende do controle da temperatura e da velocidade do ar. Estudos demonstram que esses fatores influenciam diretamente a eficiência da secagem e a preservação das características do produto (Münsterer, 2006; Hermanek *et al.*, 2016; Orphanides *et al.*, 2017; Ashtiani *et al.*, 2018). Além disso, o monitoramento da temperatura do produto ao longo do processo tem se mostrado fundamental para identificar pontos críticos, permitindo ajustes operacionais e a definição das etapas de secagem (Fiorentini *et al.*, 2015; Sturm *et al.*, 2014).

Em estudos anteriores, o desenvolvimento de secadores tem se concentrado fortemente na aquisição de informações sobre o produto e o ambiente que está exposto durante a secagem. O objetivo destes estudos tem sido desenvolver sistemas inteligentes que determinem das informações de forma não invasiva e as utilizem como variáveis de entrada para o controle do processo (Münsterer, 2015; Sturm *et al.*, 2016; Sturm *et al.*, 2018; Rybka *et al.*, 2019; Martynenko; Misra, 2020; Martynenko; Sturm, 2019).

Com o aprimoramento dos métodos de aprendizado de máquina, o aumento rápido da capacidade de processamento e a redução dos preços, novas formas de lidar com os dados e desenvolver sistemas de secagem estão emergindo. Essas abordagens utilizam as características da matéria-prima e a dinâmica de mudanças como base para o desenvolvimento e execução do controle (Pu *et al.*, 2015; Crichton *et al.*, 2018; Sturm *et al.*, 2018; Pinto *et al.*, 2023).

Por exemplo, Sturm *et al.* (2018) exploram a viabilidade da espectroscopia Vis/NIR e análise de imagens como fundamentos para o desenvolvimento de tecnologias inteligentes de secagem, permitindo um monitoramento das propriedades do lúpulo ao longo do processo. Além disso, os autores Pinto *et al.* (2023) investigaram o uso de aprendizado de máquina para otimizar a eficiência da secagem, ajustando automaticamente os parâmetros operacionais em tempo real para melhorar a qualidade e reduzir o consumo energético dos secadores.

Nesse contexto, o processamento de imagem e som para fornecer dados para o desenvolvimento de modelos preditivos pode ser uma alternativa interessante visando a melhoria ou otimização do processo de secagem. Ressalta-se que muitos trabalhos têm utilizado análise de imagens e sons em plantas para a determinação de variáveis em processos de secagem (Gasso-Tortajada *et al.*, 2010; Khalifa *et al.*, 2011; Kurtulmuş *et al.* 2018; Sturm *et al.*, 2018; Devaraj *et al.*, 2019; Chen *et al.*, 2020; Naeem *et al.*, 2021; Castro *et al.*, 2021; Pinto *et al.*, 2023).



Análise de imagens e sons como uma perspectiva de
inovação na pós-colheita do lúpulo

3

CONTEXTUALIZAÇÃO SOBRE PROCESSAMENTO E ANÁLISE DIGITAL DE IMAGEM



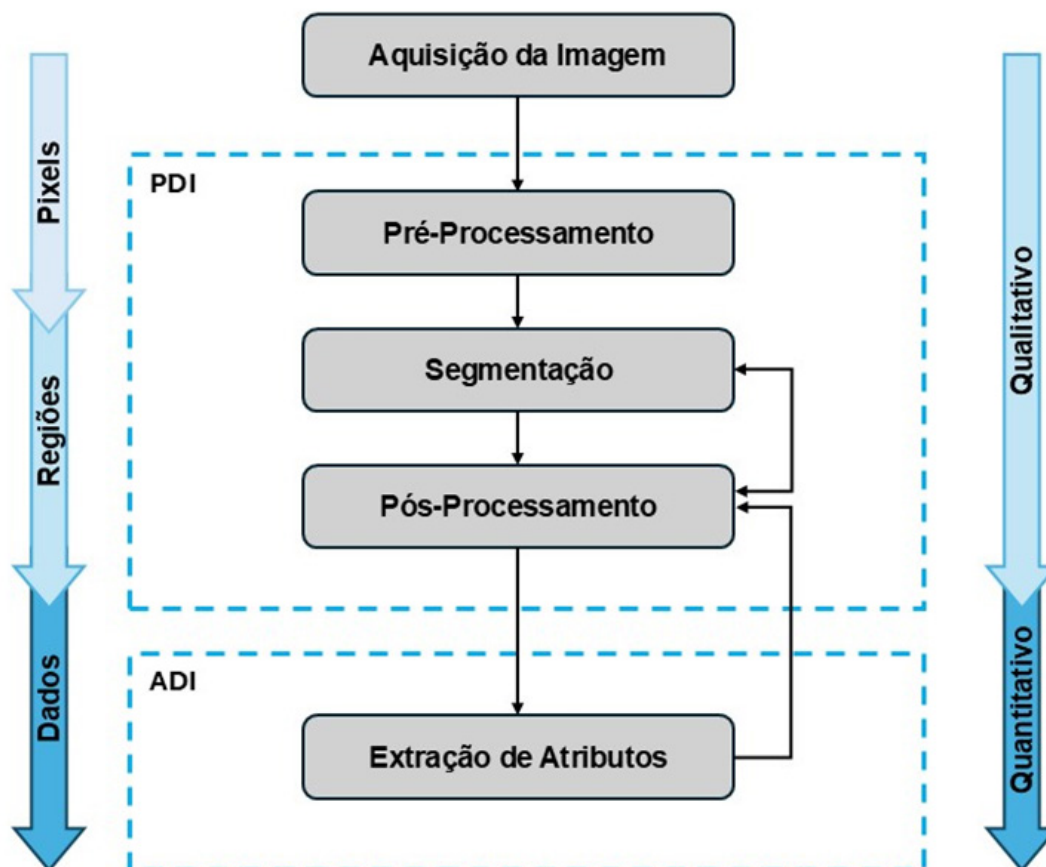
3.1 Definição e etapas do processamento digital de imagens

O processamento de imagens é uma área da ciência da computação que se dedica à manipulação e análise dados de visuais por computadores com o objetivo de melhorar a representação da imagem e/ou viabilizar análises quantitativas de atributos, utilizando o processamento computacional. As imagens passam por várias etapas, que vão desde o pré-processamento até a extração de atributos e reconhecimento de padrões (Stork *et al.*, 2010; Umbaugh, 2023).

Neste sentido, o processamento de imagens pode ser dividido em duas etapas, o Processamento Digital de Imagens (PDI) e Análise Digital de Imagens (ADI). O PDI envolve a preparação da imagem para análises futuras, incluindo a realização de operações matemáticas que alteram os valores dos elementos da imagem, como correções, realces, transformações e segmentações. A ADI está relacionada a análise quantitativa por meio da extração de atributos (características da imagem) (Umbaugh, 2023).

Nessa etapa, as regiões, partículas ou objetos previamente identificados na imagem são caracterizados por meio da extração de atributos (histograma de cor, característica de textura, dimensões etc.). O termo Processamento e Análise Digital de Imagens (PADI) engloba as duas etapas (PDI e ADI), ou seja, ele refere-se ao processo completo do processamento de imagem, abrangendo desde a interação inicial da imagem até a extração dos atributos quantitativos (Szeliski, 2022; Umbaugh, 2023). A sequência de etapas que geralmente são desenvolvidas no PADI está ilustrada na Figura 1.

Figura 1. Etapas que envolvem o Processamento e Análise Digital de Imagem



Fonte: Adaptado Gomes (2001).

Conforme ilustrado na Figura 1, a aquisição da imagem é uma etapa que antecede o PDI, tendo como objetivo a captura da imagem digital. Para isso, utiliza-se um instrumento formador de imagens (como a câmera de um celular), que é capaz de receber o sinal eletromagnético emitido pela luz, convertê-lo em sinal analógico e depois em sinal digital. Dessa forma, o dispositivo transforma os sinais analógicos provenientes do sensor em uma matriz digital composta por pixels, onde cada pixel representa um ponto da imagem e contém informações de intensidade ou cor em valores numéricos (Szeliski, 2022; Umbaugh, 2023).

A imagem digital é a representação visual formada por uma matriz de elementos, conhecidos como *pixels* (abreviação de “*picture elements*”, ou elementos de figura). Cada pixel corresponde a um ponto específico da imagem, identificado por suas coordenadas na matriz (linha e coluna). O valor associado a cada pixel representa a intensidade da luz (em imagens em escala de cinza) ou da cor (em imagens coloridas) naquele ponto. Esses valores são armazenados em formato numérico, permitindo que as imagens sejam processadas, analisadas e exibidas por dispositivos digitais (Szeliski, 2022; Umbaugh, 2023).

Desta forma, pode-se dizer que uma imagem digital em escala de cinza com resolução de 8 bits, os valores dos pixels variam entre 0 (preto) e 255 (branco), com tons intermediários (1 a 254) representando diferentes intensidades de cinza. Já em imagens coloridas, cada pixel contém informações para as componentes de cor, (geralmente vermelho, verde e azul, ou RGB, representando as iniciais dos nomes das cores em inglês), que se combinam para formar a cor final.

Após a aquisição da imagem, realiza-se o pré-processamento (Figura 1), cujo objetivo é melhorar sua qualidade. Essa etapa corrige problemas como ruídos, iluminação irregular ou baixo contraste, garantindo que as fases subsequentes sejam realizadas de forma eficiente. Técnicas comuns incluem ajustes de brilho e contraste para uniformizar tons, redução de ruídos para eliminar artefatos indesejados e realce de bordas para aumentar a nitidez entre regiões distintas (Stork *et al.*, 2010; Szeliski, 2022; Umbaugh, 2023).

A segmentação é a etapa subsequente ao pré-processamento (Figura 1). Esta é uma etapa fundamental no fluxograma do PADI, pois é a partir dela que se obtém a imagem processada para extração de informações. O principal objetivo da segmentação é dividir a imagem em regiões homogêneas ou objetos de interesse, agrupando pixels com características similares. Esse processo permite identificar e isolar elementos relevantes enquanto descarta o restante como fundo. A saída da segmentação geralmente é uma imagem binária, onde pixels brancos representam os objetos de interesse e pixels pretos indicam o fundo ou regiões que não possuem relevância, embora essa convenção possa variar conforme a aplicação (Gomes, 2001; Umbaugh, 2023).

Os algoritmos de segmentação podem ser classificados com base em duas propriedades fundamentais dos níveis de cinza: descontinuidade e similaridade. A abordagem de descontinuidade foca na detecção de mudanças bruscas nos níveis de intensidade, como a identificação de bordas, linhas ou pontos isolados, delimitando regiões distintas da imagem. Por outro lado, a abordagem de similaridade agrupa pixels com características comuns, utilizando métodos como limiarização (separação por valores de intensidade), crescimento de regiões (expansão a partir de sementes) e divisão e fusão de regiões (subdivisão e posterior combinação de segmentos similares) (Gomes, 2001; Szeliski, 2022; Umbaugh, 2023).

Por vezes, os resultados da segmentação não são ideais, exigindo a aplicação do pós-processamento, etapa posterior a segmentação (Figura 1). Essa etapa corrige defeitos residuais, como objetos conectados que precisam ser separados ou ruídos que precisam ser removidos. Técnicas como divisores de águas (*watersheds*) ajudam a segmentar objetos próximos, enquanto operações lógicas (como interseção ou complemento) e morfológicas (como erosão e dilatação) ajustam os detalhes da imagem (Szeliski, 2022; Umbaugh, 2023).

Ao final da etapa de pós-processamento a etapa de PDI é concluída (Figura 1) e a ADI é iniciada. É neste momento que se realiza a extração de atributos da imagem, onde serão geradas informações quantitativas. A imagem já processada é analisada para obter parâmetros como tamanho, forma, cor, textura, entre outros atributos.

3.2 Extração de atributos da imagem

A extração de características é uma etapa fundamental no processamento e análise de imagens, sendo responsável por transformar informações visuais em dados quantitativos que possam ser usados para análise (Figura 1). A seleção inicial de características é guiada pelos requisitos específicos da aplicação. Após a análise das características extraídas, podem surgir interpretações que levam a iterações adicionais de seleção, extração e análise, refinando continuamente o conjunto de características até que um conjunto satisfatório seja alcançado. Esse processo iterativo garante que as características selecionadas atendam às necessidades específicas da aplicação e otimizem os resultados (Umbaugh, 2023).

Segundo Umbaugh (2023), para garantir a qualidade das características extraídas das imagens, é essencial que elas possuam algumas propriedades. Uma boa característica deve ser:

- **Robusta:** Apresentar resultados consistentes mesmo sob diferentes condições, como variações na iluminação, tipos de câmeras ou lentes utilizadas;
- **Discriminativa:** Diferenciar efetivamente classes ou tipos de objetos de interesse, contribuindo para uma análise precisa.
- **Confiável:** Garantir medições consistentes para objetos pertencentes a uma mesma classe, promovendo precisão e estabilidade nos resultados.
- **Independente:** Não correlacionada com outras características, evitando redundância e proporcionando informações únicas e úteis para a análise.

Em aplicações que precisam lidar com variações de iluminação, características que dependem diretamente da luz não são consideradas robustas, pois podem gerar resultados inconsistentes em diferentes condições. Da mesma forma, características que apresentam valores muito parecidos para objetos de classes distintas não são discriminativas, tornando difícil a separação entre essas classes. Já uma característica que varia significativamente entre objetos semelhantes não pode ser considerada confiável, pois compromete a precisão do sistema. Além disso, características que estão altamente correlacionadas tendem a introduzir redundância, o que não apenas confunde o classificador, mas também aumenta desnecessariamente o tempo e os recursos computacionais (Umbaugh, 2023).

As características de uma imagem podem ser classificadas em diferentes tipos, cada uma representando aspectos específicos dos objetos presentes na imagem. Os principais tipos de características são:

- Características de Forma: Focam nas propriedades geométricas dos objetos, como área, perímetro, circularidade e razão de aspecto. Essas características são úteis em análises onde a morfologia dos objetos é relevante, como no reconhecimento de padrões estruturais (Umbaugh, 2023);
- Características de Histograma: Representam a distribuição dos níveis de intensidade dos pixels, fornecendo informações sobre brilho e contraste. Essas características são amplamente usadas para melhorar a segmentação e diferenciar regiões com tonalidades distintas. Com base no histograma pode-se calcular a média (reflete o brilho geral), o desvio padrão (mede o contraste), a assimetria (indica a distribuição em relação à média), a energia (avalia a concentração dos níveis de cinza), e a entropia (mede a complexidade da imagem) (Szeliski, 2022; Umbaugh, 2023);
- Características de Cor: Focam nas propriedades cromáticas das imagens, analisando os componentes de cor e suas relações. As imagens coloridas são frequentemente divididas em três canais principais (vermelho, verde e azul), permitindo que as métricas aplicadas a imagens em tons de cinza sejam expandidas para cada canal de cor individualmente ou entre eles. Transformações de cor, como HSI, HSV e Lab*, ajudam a separar componentes de brilho e cor, possibilitando a extração de características específicas, como tonalidade (hue), saturação e intensidade. Essas características são úteis em aplicações que dependem da análise de variações de cor, como segmentação e classificação de imagens, especialmente em cenários onde o contraste cromático entre objetos e o fundo é relevante (Umbaugh, 2023);
- Características Texturais: Avaliam padrões de repetição ou variação na superfície dos objetos, medindo parâmetros como contraste, homogeneidade, aspereza, rugosidade, entropia, dentre outras. Essas características refletem as variações de brilho causadas pela interação da luz com a superfície do objeto e podem ser medidas de diferentes maneiras, incluindo transformações espectrais (analisa a textura em termos de frequências espaciais) e matrizes de co-ocorrência (analisa a distribuição conjunta dos níveis de cinza de pares de pixels.) (Umbaugh, 2023);
- Características Espectrais: São derivadas da Transformada de Fourier, uma ferramenta matemática que decompõe sinais complexos em componentes senoidais de diferentes frequências. Essa técnica permite identificar frequências espaciais, que indicam a taxa de variação do brilho ao longo do espaço da imagem. Isso permite a extração de características importantes, como amplitudes e fases dos componentes de frequência, que podem ser aplicadas em tarefas como compressão, filtragem e reconhecimento de padrões estruturais em imagens (Umbaugh, 2023).

Essas características, quando combinadas e alinhadas ao objetivo da análise, formam vetores de dados que representam a imagem de maneira simplificada e eficaz, permitindo que sejam usadas em técnicas de reconhecimento de padrões, aprendizado de máquina etc.



Análise de imagens e sons como uma perspectiva de
inovação na pós-colheita do lúpulo

4


ASPECTOS TEÓRICOS DO PROCESSAMENTO E DA ANÁLISE DE SINAIS SONOROS E CONSIDERAÇÕES SOBRE O COMPORTAMENTO DO LÚPULO AO LONGO DO PROCESSO DE SECAGEM



4.1 Caracterização das ondas sonoras

O som é uma onda mecânica que se propaga a partir da vibração de um meio sólido ou fluido. Essa vibração causa deslocamentos e oscilações das moléculas do meio que o som se propaga, o que resulta em regiões alternadas de compressão e rarefação. Essas flutuações de pressão viajam pelo meio na forma de ondas, que se propagam desde a fonte sonora até atingirem um receptor, como o ouvido humano ou um microfone (Müller, 2015; Knees; Sched, 2016). As ondas sonoras podem ser caracterizadas em um gráfico de pressão-tempo. Este representa a variação da pressão do meio em relação ao tempo (Figura 2).

Figura 2. Representação do processo de produção, propagação e recepção de uma onda sonora produzida por um diapasão




Fonte: Adaptado de Müller (2015, p. 20).

A onda mecânica é uma oscilação que se propaga pelo espaço, transferindo energia de um ponto a outro. Durante essa propagação, o meio através do qual a onda se move é temporariamente deformado. No caso das ondas sonoras, essa propagação ocorre por meio da colisão de moléculas de ar (meio de propagação), que voltam à posição original devido a uma força restauradora. Sendo assim, a onda sonora começa na superfície da fonte e se propaga pelo meio até atingir um receptor ou ser completamente dissipada (Müller, 2015; Knees; Sched, 2016).

Quando o som é gravado em uma posição fixa no espaço (sem movimento) ele pode ser descrito por duas dimensões, tempo (t) e amplitude (a). Nesse caso, os principais parâmetros são o tempo, ou duração (t), a amplitude (a) e o período do ciclo (T). A duração refere-se ao tempo total em que uma onda ou som está presente, desde o início até o fim. A amplitude é medida do deslocamento máximo de uma partícula em relação à sua posição de equilíbrio, ela determina a intensidade ou volume, onde uma amplitude maior significa um som mais intenso. O período é o tempo necessário para que uma onda complete um ciclo, ou seja, a distância de tempo entre dois pontos idênticos e consecutivos na onda, como dois picos de compressão (Müller, 2021). Essas características da onda po-

dem ser observadas na Figura 3.

Figura 3. Caracterização da amplitude e período de uma onda senoidal transversal com frequência de 4 Hz



Fonte: Adaptado de Müller (2015, p. 21).

Outra característica importante da onda é a frequência, refere-se ao número de ciclos completos que uma onda realiza em um segundo, sendo medida em Hertz (Hz). A frequência está diretamente relacionada à percepção do som, onde frequências mais altas correspondem a sons mais agudos. A frequência é o inverso do período (Equação 1), ou seja, quanto menor o período, maior a frequência. Quanto maior a frequência de uma onda, mais alto ela soa (Sueur, 2018; Müller, 2021).

$$f = \frac{1}{T} \quad (1)$$

Sendo: f é a frequência (Hz); T é o período (s).

Uma onda senoidal transversal pode ser caracterizada pela Equação 2 (Halliday *et al.*, 2012)

$$y(x, t) = A \cdot \text{sen}(kx - \omega t + \phi) \quad (2)$$

Sendo: $y(x, t)$ é o deslocamento da onda no ponto x e instante t ; A é a amplitude da onda; k é o número de onda; x é a posição ao longo da onda; ω é a frequência angular; t é o tempo; ϕ é a fase da onda.

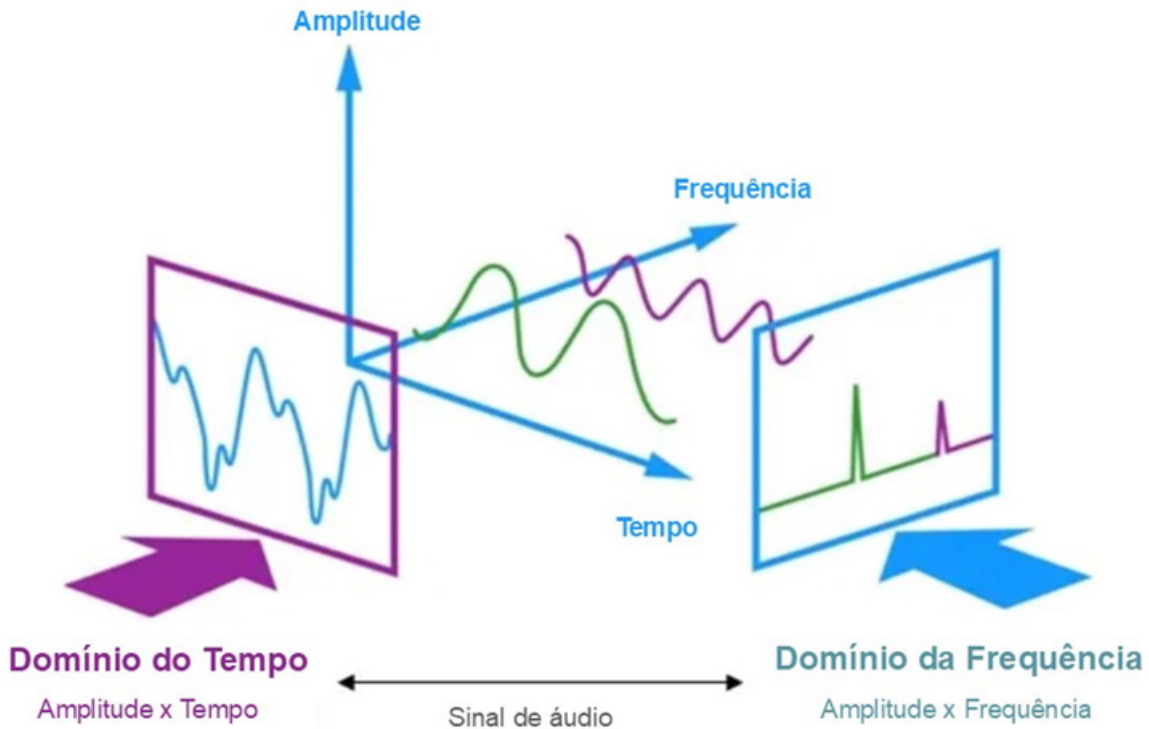
4.2 Extração de atributos de sinais sonoros

As características de sinais sonoros têm se mostrado essenciais para a modelagem e compreensão de diferentes comportamentos acústicos (Gasso-Tortajada *et al.*, 2010; Khalifa *et al.*, 2011; Kurtulmuş *et al.* 2018; Sueur, 2018; Müller, 2021; Huang *et al.*, 2023). Essas são agrupadas no domínio do tempo, da frequência e do tempo-frequência, como ilustrado na Figura 4.

No domínio do tempo, as características são extraídas diretamente do sinal captado pelo receptor (microfone, por exemplo), refletindo variações instantâneas do som ao longo do tempo (Amplitude x Tempo; SUEUR, 2018). Para caracterizar o sinal neste domínio, calcula-se o envelope do sinal (Figura 5), que é o contorno do sinal de áudio (descreve a variação da amplitude de um som ao longo


do tempo). A partir do envelope é possível determinar medidas como taxa de cruzamento zero (*Zero-Crossing Rate - ZCR*), raiz quadrada da média (*Root Mean Square - RMS*), assimetria (*skewness*), curtose (*kurtosis*), rugosidade (*roughness*) e entropia (*entropy*). Essas são medidas capazes de capturar a intensidade e a oscilação do sinal ao longo do tempo, possibilitando a caracterização do sinal (Sueur, 2018; Müller, 2021).

Figura 4. Caracterização do sinal no domínio do tempo e no domínio da frequência



Fonte: Adaptado de MED (2008).

Figura 5. Representação do envelope de um sinal sonoro




Fonte: Os autores.

No domínio da frequência, a análise se concentra na distribuição de energia ao longo das diferentes bandas de frequência. Neste domínio, o sinal de áudio pode ser definido por meio do espectro (Amplitude x Frequência), permitindo a

caracterização ao longo das diferentes frequências que o constitui (Sueur, 2018; Müller, 2021), conforme representado na Figura 6.

Figura 6. Representação do espectro de um sinal sonoro



Fonte: Os autores.

Para gerar o espectro de frequências de um sinal, aplica-se a Transformada de Fourier, que converte o sinal do domínio do tempo para o domínio da frequência. Essa técnica decompõe o sinal em suas componentes de frequência, revelando quais frequências estão presentes e qual sua intensidade (amplitude). A partir do espectro de frequências, diversas propriedades espectrais podem ser extraídas e elas fornecem caracterização detalhada do conteúdo de frequência do sinal (Sueur, 2018).

As propriedades que podem ser extraídas estão relacionadas a medidas estatísticas de tendência central (média, mediana, moda, entre outras), dispersão (desvio padrão, erro padrão, quartis) e formato (assimetria, curtose, achatamento, entropia). A frequência média e a frequência mediana são medidas centrais importantes: a primeira representa uma média das frequências ponderadas pela intensidade, enquanto a segunda identifica a frequência onde metade da energia do sinal está concentrada abaixo e metade acima. O desvio padrão e o erro padrão indicam a dispersão das frequências em torno da média, fornecendo informações sobre a variabilidade das intensidades ao longo do espectro. A moda do espectro representa a frequência mais recorrente, isto é, aquela que apresenta a maior intensidade no sinal (Sueur, 2018; Müller, 2021).

Outras características incluem os quartis, que dividem o espectro em partes com base na intensidade acumulada. O intervalo entre quartis (IQR) mede a amplitude dessa faixa central, oferecendo uma visão da distribuição das intensidades. O centroide, ou “centro de massa” espectral, representa uma frequência média ponderada pela intensidade e indica onde a maior parte da energia do sinal se concentra (frequências com maior amplitude têm maior influência na determinação do centroide) (Sueur, 2018; Müller, 2021).

A planicidade (*flatness*) mede a uniformidade das intensidades ao longo das frequências; valores altos indicam um espectro mais plano, com menor concentração de picos. Já a assimetria (*skewness*) avalia a simetria do espectro em torno da média, refletindo picos predominantes em frequências baixas ou altas, enquanto a curtose (*kurtosis*) descreve a “pontualidade” do espectro, ou seja, se ele possui picos mais acentuados ou é mais suave (Knees; Sched, 2016; Sueur, 2018; Müller, 2021).

A uniformidade ou entropia espectral mede a complexidade do espectro, com valores mais altos indicando uma distribuição de intensidade mais uniforme entre as frequências. Também pode-se determinar a rugosidade espectral, que quantifica a variação rápida das intensidades no espectro e pode indicar mudanças abruptas entre as frequências. O número de picos espectrais, reflete a diversidade de frequências no sinal. Essas propriedades fornecem uma descrição detalhada do sinal e permitem analisar seu conteúdo de frequência, textura e complexidade, sendo úteis para identificar padrões (Knees; Sched, 2016; Sueur, 2018; Müller, 2021).

No domínio tempo-frequência, a energia do sinal é mapeada simultaneamente em função do tempo e da frequência, utilizando o espectrograma (Frequência x Tempo). Essas características possibilitam a análise da mudança do comportamento da frequência ao longo do tempo. A integração de características desses três domínios possibilita uma representação detalhada do comportamento do sinal (Knees; Sched, 2016; Sueur, 2018).

No contexto de estudo do som emitido pelos cones de lúpulo, essas características podem ser empregadas para monitorar mudanças de comportamento no padrão sonoro em função de variações do teor de umidade.

A extração de características acústicas é essencial para a análise de som. De acordo com a revisão de literatura realizada pelos autores Sharma *et al.* (2019) as mais utilizadas são:

- Frequência: Representa o tom ou a frequência fundamental do som, sendo um parâmetro essencial para distinguir tipos de materiais, produtos ou sinais clínicos.
- Amplitude: Refere-se à intensidade ou volume do som, utilizada para avaliar a força ou a energia associada ao sinal.
- Duração: Corresponde ao tempo de persistência do som, relevante em estudos temporais e de dinâmica acústica.
- Padrões espectrais: Envolvem a distribuição da energia sonora em diferentes bandas de frequência, sendo úteis para caracterizar propriedades específicas de materiais ou sinais biológicos.
- Padrões temporais: Representam a evolução do som ao longo do tempo, oferecendo informações sobre mudanças dinâmicas no sinal.

A extração das características nos diferentes domínios ao longo de todo os dados do sinal comumente é realizada por meio da técnica denominada de *Sliding Window*. Essa técnica realiza seleção de um trecho do sinal para o cálculo das características. Para isso, ela utiliza uma janela deslizante, que serve para delimitar o intervalo dos dados que serão considerados para o cálculo das características e quando o processo finaliza a janela se desloca, demarcando um novo trecho a ser analisado. Para sumarizar as características calculadas ao longo do sinal utiliza-se ferramentas da estatística descritiva, tais como: média, mediana, moda, desvio padrão, variância, assimetria e curtose (Müller, 2021).

4.3 Aplicações do processamento de sinais sonoros em diferentes áreas do conhecimento

A aplicação da análise de som mostra-se promissora para resolver desafios em diversas áreas, integrando conhecimentos da engenharia de áudio, da ciência de dados e da estatística. Essa técnica baseia-se na extração de características acústicas de sinais sonoros e na análise desses dados para compreender padrões, identificar propriedades e prever comportamentos em aplicações específicas.

Uma das áreas em que a análise de som tem sido aplicada é na agricultura, especialmente na caracterização e classificação de produtos agrícolas (Kurtulmuş *et al.* 2018; Khalifa *et al.*, 2011; Gasso-Tortajada *et al.*, 2010).

No estudo de Kurtulmuş *et al.* (2018), os pesquisadores analisaram o som de impacto produzido pela queda controlada de castanhas sobre uma superfície padronizada, com o objetivo de classificá-las quanto ao teor de umidade. Para isso, foram extraídas características acústicas, como frequência, amplitude e duração do sinal. Os dados acústicos extraídos foram aplicados em um modelo de aprendizado de máquina, especificamente uma máquina de vetores de suporte (SVM), que demonstrou alta eficácia na classificação. Este estudo destaca como a análise de som pode complementar métodos tradicionais de avaliação da qualidade de produtos agrícola, oferecendo uma abordagem não destrutiva e eficiente.

Os autores Khalifa *et al.*, (2011) desenvolveram estudo acústico voltado para avaliação de nozes. Neste estudo, os autores utilizaram a análise do som de impacto gerado pela queda controlada das nozes sobre uma superfície padronizada, a fim de extrair características acústicas como frequência, amplitude e duração do sinal. A partir desses parâmetros, foi desenvolvido um modelo de rede neural para classificar as nozes de acordo com o grau de maturidade.

Essa abordagem apresenta diversas vantagens em comparação a métodos tradicionais de avaliação, como a inspeção visual. A análise de som permite uma avaliação objetiva e automatizada, reduzindo a necessidade de intervenção humana e tornando o processo mais eficiente e escalável. A presente tecnologia pode ser aplicada em diversas áreas, como controle de qualidade, logística e processamento pós-colheita, contribuindo para a melhoria da eficiência e da sustentabilidade na agricultura (Khalifa *et al.*, 2011).

Já o estudo realizado por Gasso-Tortajada *et al.* (2010) empregou sensores acústicos para classificar diferentes tipos de sementes. Os pesquisadores mediram os espectros de absorção sonora de cada amostra e utilizaram métodos de análise estatística multivariada para identificar padrões específicos. Foi observado a viabilidade da análise de áudio em situações em que métodos visuais ou químicos não são aplicáveis.

Fora do campo agrícola, a análise de som também tem sido usada em aplicações na área da saúde. Em um estudo recente, Huang *et al.* (2023) explorou o uso de técnicas baseadas em aprendizado profundo para analisar sons pulmonares, com o objetivo de detectar doenças respiratórias. Os sons pulmonares, frequentemente utilizados como indicadores clínicos, foram analisados para identificar características acústicas relacionadas a patologias como pneumonia e asma. Esse estudo demonstrou potencial para auxiliar no diagnóstico precoce e no monitoramento de condições respiratórias, especialmente em áreas com

acesso limitado a médicos especializados.

Além disso, o uso de sons para monitoramento de saúde pode ser ampliado para incluir sistemas baseados em inteligência artificial que integrem análises acústicas em dispositivos vestíveis, permitindo o acompanhamento contínuo de pacientes e a detecção de anomalias em tempo real.

Na área da ciência dos materiais, a análise de som tem sido utilizada para caracterizar propriedades físicas e acústicas de diferentes materiais. Por exemplo, Rychtáriková *et al.* (2023) aplicaram o modelo de *Loudness de Zwicker* para avaliar a adequação de descritores de isolamento acústico em paredes divisórias de residências. Os pesquisadores demonstraram como as características sonoras, como frequência e amplitude, podem fornecer informações importantes para as características dos materiais de construção, garantindo melhor desempenho acústico.

Para a análise de característica ou atributos extraídos do som, técnicas estatísticas e de aprendizado de máquina são amplamente empregadas. Métodos como Análise de Componentes Principais (ACP) e aprendizado profundo permitem reduzir a dimensionalidade dos dados, identificar padrões ocultos e construir modelos preditivos com grande base de dados (Gasso-Tortajada *et al.*, 2010; Sharma *et al.*, 2019).

A análise de som tem demonstrado um potencial significativo em diversas áreas, desde a classificação de produtos agrícolas até a detecção de doenças e o desenvolvimento de materiais avançados. As inovações na tecnologia de sensores e no processamento de dados acústicos têm ampliado as possibilidades de aplicação, permitindo maior precisão e eficiência. No futuro, espera-se que essas técnicas sejam cada vez mais integradas em sistemas automatizados e dispositivos inteligentes, promovendo soluções sustentáveis e acessíveis para desafios complexos. A colaboração interdisciplinar entre engenheiros e cientistas de dados será basilar para explorar plenamente o potencial da análise de som e suas aplicações.



Análise de imagens e sons como uma perspectiva de
inovação na pós-colheita do lúpulo

5

FUNDAMENTOS DE APRENDIZADO DE MÁQUINA APLICADOS À MODELAGEM PREDITIVA



5.1 Modelos de previsão

Os avanços no campo da ciência da computação e da análise de dados têm popularizado termos como Inteligência Artificial (*Artificial Intelligence* - AI), Aprendizado de Máquina (*Machine Learning* - ML) e Aprendizado Profundo (*Deep Learning* - DL). Embora frequentemente usados de forma intercambiável, esses conceitos possuem definições distintas e estão organizados em uma hierarquia que reflete diferentes níveis de complexidade e aplicação. Entender essa distinção é fundamental para contextualizar o papel de cada tecnologia nas diversas áreas do conhecimento e suas aplicações práticas (Mendonça *et al.*, 2023; Lantz, 2023; Lange, 2024).

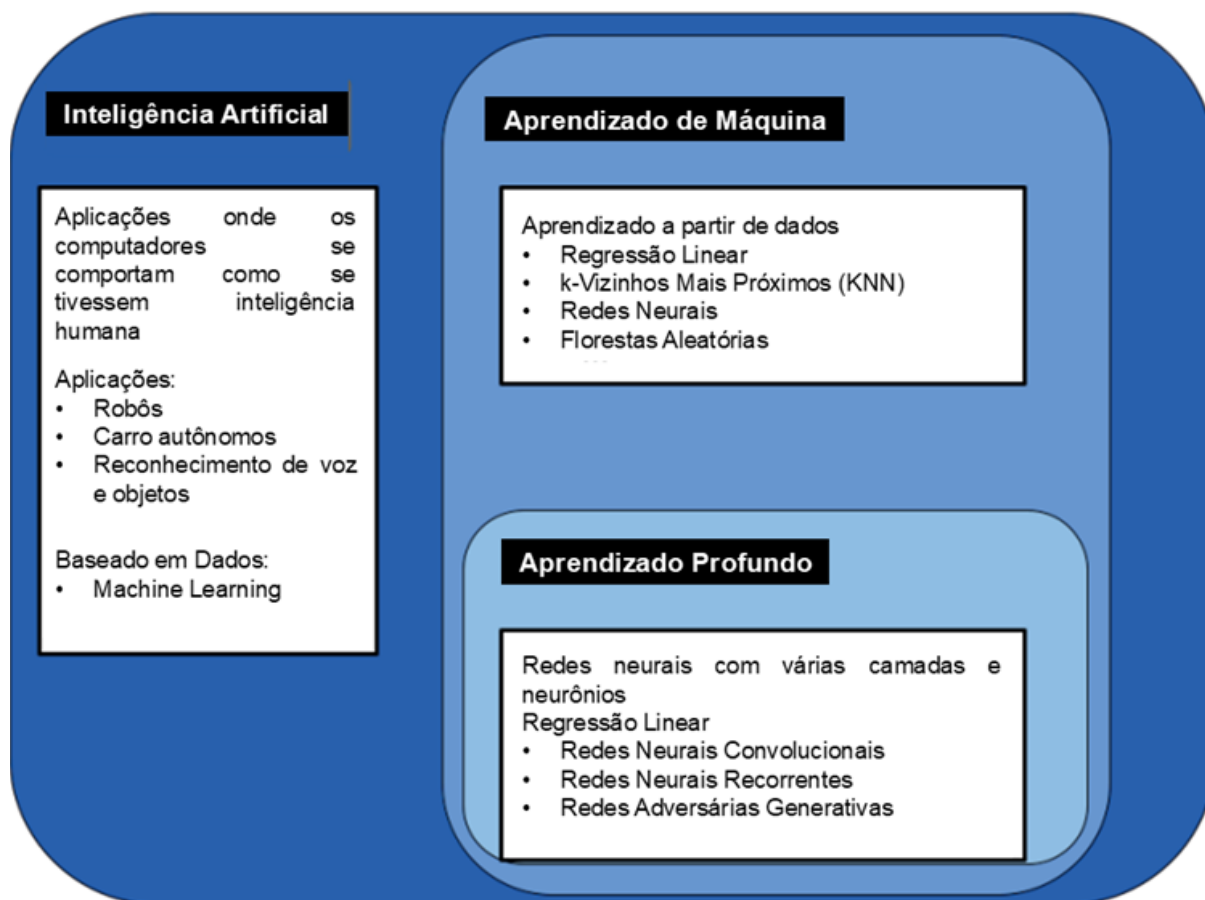
A AI representa o nível mais amplo dentro dessa hierarquia. Ela refere-se ao desenvolvimento de sistemas computacionais capazes de executar tarefas que normalmente exigiriam inteligência humana, como tomada de decisões complexas, resolução de problemas e aprendizado. Essas aplicações podem ser baseadas em regras, onde especialistas humanos definem explicitamente as instruções que o sistema deve seguir, ou baseadas em dados, nas quais o sistema aprende a partir de grandes volumes de informações. Exemplos comuns de tarefas que AI pode ser empregada é em sistemas de veículos autônomos, sistemas de reconhecimento de voz, sistemas de reconhecimento de objetos, e sistemas que produzem imagens (Lantz, 2023; Lange, 2024).

Dentro da área de AI, destaca-se o *Machine Learning* ou aprendizado de máquina, uma subárea que se diferencia pela sua abordagem baseada em dados. O aprendizado de máquina envolve a construção de modelos que não dependem de regras explícitas, mas sim de padrões aprendidos a partir de um conjunto de dados de treinamento. Durante o processo de aprendizado, o algoritmo analisa as informações fornecidas, identifica correlações e padrões, e desenvolve um modelo que pode ser utilizado para realizar previsões (Lantz, 2023; Fávero *et al.*, 2023; Lange, 2024).

No nível mais especializado da hierarquia, encontra-se o DL uma subárea do aprendizado de máquina que utiliza redes neurais profundas, formadas por múltiplas camadas de neurônios artificiais interconectados. Essas redes são capazes de processar grandes volumes de dados de forma altamente eficiente, permitindo o aprendizado de padrões complexos e a execução de tarefas sofisticadas. As redes neurais profundas são amplamente utilizadas em aplicações que exigem alto desempenho e precisão, como o processamento de linguagem natural e o reconhecimento avançado de sinais (Lantz, 2023; Lange, 2024). Na Figura 7 está ilustrado como essas tecnologias estão relacionadas.

Vale destacar que os algoritmos de aprendizado de máquina podem ser classificados com base nas tarefas que desempenham, sendo as principais categorias regressão, classificação e agrupamento (Fávero *et al.*, 2023; Lange, 2024). A regressão tem como objetivo prever uma variável contínua, estimando o valor de um determinado resultado com base no conhecimento de outras variáveis (preditores). Esse tipo de análise pode ser linear ou não-linear. O foco principal da regressão é a magnitude do valor predito, como prever o preço de uma casa ou a temperatura em determinado dia ou prever a umidade de cones de lúpulo a partir de preditores preestabelecidos (Lantz, 2023; Lange, 2024).

Figura 7. Relação Hierárquica entre Inteligência Artificial, Aprendizado de Máquina e Aprendizado



Fonte: Adaptado de Lange (2024, p.23).

Já a classificação busca prever categorias discretas, ou seja, associar observações a grupos predefinidos. Frequentemente, esses grupos consistem em dois valores binários, como Sim/Não ou Verdadeiro/Falso. No entanto, as categorias podem ser também múltiplas, ordenadas, como classificações de qualidade (Bom/Regular/Ruim), ou não ordenadas, como cores (Vermelho/Azul/Verde) ou estado civil (Solteiro/Casado/Viúvo). Técnicas e/ou Algoritmos de classificação populares incluem Regressão Logística (*Logistic Regression*), Análise Discriminante (*Discriminant Analysis*), k-Vizinhos Mais Próximos (*k-Nearest Neighbors* – KNN), Floresta Aleatória (*Random Forest*) e Redes Neurais (*Neural Networks*), entre outros, cada um adequado para diferentes tipos de problemas categóricos. (Mendonça *et al.*, 2023; Lantz, 2023; Lange, 2024).

Por fim, a análise de agrupamento (*cluster analysis*) tem como objetivo agrupar observações com base em suas características, buscando formar grupos que sejam mais homogêneos internamente e distintos entre si. Ao contrário das tarefas de regressão e classificação, a análise de agrupamento é exploratória por natureza e, em muitos casos, não requer categorias predefinidas, como é o caso do agrupamento hierárquico. No entanto, alguns algoritmos, como o *k-Means*, exigem a definição prévia do número de grupos a serem formados (Mendonça *et al.*, 2023; Lange, 2024).

5.2 *Overfitting* e *Underfitting* em modelagem

O processo de ajuste de modelos de predição ou classificação busca encontrar um equilíbrio entre a capacidade de representação do modelo e sua capacidade de generalização para novos dados. No entanto, dois problemas fundamentais podem surgir durante o treinamento: *overfitting* e *underfitting*, ambos relacionados ao desempenho do modelo em relação aos dados de treinamento e de teste (Mendonça *et al.*, 2023; Lange, 2024).

Overfitting, ou sobreajuste, ocorre quando o modelo se adapta excessivamente às particularidades e ruídos do conjunto de dados de treinamento, ajustando-se a padrões espúrios que não possuem relação direta com o processo subjacente real. Esse excesso de ajuste faz com que o modelo tenha uma performance excelente nos dados de treinamento, mas apresente uma capacidade de generalização deficiente ao ser exposto a novos dados (Mendonça *et al.*, 2023; Lange, 2024). De acordo com Mendonça *et al.* (2023), as principais causas do *overfitting* incluem:

- Presença de ruído estocástico nos dados medidos, que introduz variabilidade aleatória irrelevante para a tarefa de aprendizado;
- Ausência de amostras de dados devido a falhas temporárias de sensores, resultando em lacunas que o modelo tenta preencher inadequadamente;
- Complexidade excessiva do modelo em relação ao número de dados, quando há muitos parâmetros para poucos exemplos, fazendo com que o modelo memorize o treinamento em vez de aprender padrões gerais.

Por outro lado, o *underfitting*, ou subajuste, ocorre quando o modelo é incapaz de capturar a complexidade do processo subjacente. Nesse cenário, o modelo é inadequado tanto para o conjunto de treinamento quanto para novos dados, resultando em um desempenho insatisfatório em ambos os contextos (Mendonça *et al.*, 2023; Lange, 2024). Conforme relatado por Mendonça *et al.* (2023), o *underfitting* geralmente surge devido a:

- Insuficiência de dados de treinamento, que limita a capacidade do modelo de aprender as características relevantes do processo;
- Complexidade insuficiente do modelo, que não permite uma representação adequada do comportamento dos dados, resultando em uma estimativa subótima.

Enquanto o *overfitting* está relacionado à alta variância, o *underfitting* está associado à alta tendência. O objetivo em projetos de aprendizado de máquina é encontrar um equilíbrio que minimize tanto o vício (*bias*) quanto a variância, garantindo que o modelo capture adequadamente o processo subjacente aos dados sem comprometer sua capacidade de generalização. Técnicas como validação cruzada, regularização, ajuste de hiperparâmetros e uso de conjuntos de dados maiores e mais representativos são fundamentais para mitigar esses problemas e melhorar o desempenho geral dos modelos.

5.3 Técnicas de aprendizado de máquina

Na área de aprendizado de máquina, os algoritmos são categorizados em três tipos principais: aprendizado supervisionado, aprendizado não supervisionado e aprendizado em conjunto (*Ensemble*) (Fávero et al., 2023; Lange, 2024). Cada abordagem tem suas características e aplicações específicas, permitindo que sejam adaptadas conforme os objetivos do estudo e o tipo de dados disponível.

O Aprendizado supervisionado é uma abordagem onde o modelo é treinado usando um conjunto de dados rotulados, ou seja, um conjunto em que as entradas são associadas a saídas conhecidas. Durante o treinamento, o modelo aprende a mapear as relações entre as variáveis preditoras (ou características) e as variáveis-alvo (ou resposta). Este processo permite ao modelo realizar previsões para novos dados com um grau de precisão, que vai depender da qualidade do modelo que foi treinado. Algumas técnicas de aprendizado supervisionado comumente utilizadas são Regressão linear, Regressão Logística, Máquinas de Vetores de Suporte (*Support Vector Machine - SVM*), Redes Neurais e Árvore de Decisão (*Decision Tree - DF*) (Lantz, 2023; Fávero et al., 2023; Lange, 2024).

Aprendizado não supervisionado, por outro lado, trabalha com dados não rotulados, ou seja, dados onde as saídas desejadas não são fornecidas. Nesse tipo de aprendizado, o modelo busca padrões e estruturas subjacentes nos dados, como agrupamentos ou correlações, sem supervisão explícita. Técnicas não supervisionadas comumente utilizadas são Análise de Agrupamento (*Clustering*) e Análise de Componentes Principais (*Principal Component Analysis - PCA*): reduz a dimensionalidade dos dados, destacando as variáveis mais influentes (Lantz, 2023; Lange, 2024).


O Aprendizado em Conjunto (*Ensemble*) é uma estratégia avançada no campo do aprendizado de máquina, cujo objetivo é otimizar o desempenho preditivo por meio da combinação de múltiplos modelos. Em vez de confiar em um único modelo para realizar previsões, o *Ensemble* reúne vários modelos independentes ou complementares, agregando suas previsões para produzir um resultado mais preciso. Essa abordagem se fundamenta na ideia de que a diversidade entre os modelos pode reduzir os erros individuais, resultando em uma previsão mais confiável. As técnicas mais populares de *Ensemble* são Empilhamento (*Stacking*), Ensacamento (*Bagging*) e Impulsioneamento (*Boosting*), (Mendonça et al., 2023; Lantz, 2023; Fávero et al., 2023; Lange, 2024).

Na Figura 8 está representado o fluxograma para gerar um modelo *Ensemble*. O fluxograma começa com a entrada de dados de treinamento, que é distribuída para múltiplos modelos (M1, M2, M3) por meio de uma função de alocação. Essa função determina como os dados serão particionados entre os modelos, atribuindo a cada um o conjunto completo de dados ou subconjuntos específicos, tanto em termos de amostras quanto de características. O objetivo dessa etapa é garantir diversidade entre os modelos, fator fundamental para que o modelo *Ensemble* seja eficaz. A diversidade pode ser obtida por meio de diferentes algoritmos de aprendizado, variações nos hiperparâmetros, ou técnicas de manipulação dos dados de entrada (Fávero et al., 2023; Lange, 2024).

Após o treinamento dos modelos individuais, suas previsões são reunidas e processadas pela função de combinação. Essa etapa é responsável por consolidar as diversas previsões em uma única saída final. A combinação pode ser fei-

ta por meio de métodos simples, como votação majoritária, ou estratégias mais avançadas que ponderam as previsões de acordo com o desempenho histórico de cada modelo. Esse processo garante que o *ensemble* aproveite a força coletiva dos modelos, gerando uma previsão mais robusta e precisa do que qualquer modelo individual isolado (Lantz, 2023). Todas essas etapas estão mais detalhadas em Lantz (2023; p.610-613).

Figura 8. Fluxograma para de um modelo gerado por aprendizado em conjunto (*Ensemble*)



Fonte: Adaptado de Lantz (2023, p.610).

Nos tópicos seguintes são apresentados brevemente alguns algoritmos de aprendizado em conjunto. Essas técnicas foram utilizadas para a construção dos modelos apresentados na tese e o conhecimento da estrutura básica é importante para o entendimento dos resultados.

5.4 Métodos de Aprendizado em Conjunto (Ensemble)

Entre os vários métodos do Aprendizado em Conjunto, destacam-se os métodos Ensacamento (*Bagging*) e Impulsionamento (*Boosting*), dado que esses métodos são os mais utilizados pelos algoritmos que serão utilizados no desenvolvimento dos modelos estudados neste estudo.

5.4.1 Ensacamento (*Bagging*)

O *bagging*, abreviação de *Bootstrap Aggregating*, é um método que utiliza o conceito de amostragem com reposição (*bootstrapping*), onde múltiplos subconjuntos do conjunto de treinamento são gerados aleatoriamente. Cada subconjunto é usado para treinar uma instância do mesmo algoritmo de aprendizado, resultando em uma série de ajuste distintos de modelos (Lantz, 2023).

O principal objetivo do *bagging* é reduzir a variância dos modelos, aumentando sua capacidade de generalização. Para tarefas de classificação, as previsões dos modelos são combinadas por meio de votação majoritária, enquanto, para tarefas de regressão, as previsões são combinadas pela média das saídas individuais (Lantz, 2023).


O *bagging* é eficaz quando aplicado a modelos instáveis, ou seja, aqueles que exibem grande sensibilidade a pequenas alterações nos dados de entrada. Modelos como árvores de decisão se beneficiam amplamente do *bagging*, pois pequenas mudanças nos dados de treinamento podem resultar em árvores consideravelmente diferentes. O *Random Forest* é um algoritmo que utiliza o *ba-*

gging com árvores de decisão, combinando a saída de múltiplas árvores para obter melhores previsões (Lantz, 2023; Fávero *et al.*, 2023; Lange, 2024).

O processo de *bagging* está ilustrado na Figura 9 e de acordo com Lantz (2023) pode ser resumido nas seguintes etapas:

- Gerar múltiplos subconjuntos do conjunto de treinamento por meio de amostragem com reposição;
- Treinar um modelo independente em cada subconjunto;
- Combinar as previsões individuais dos modelos ajustados em cada subconjunto para formar a previsão final do ensemble.

Figura 9. Fluxograma do processo de Ensacamento (*Bagging*)



Fonte: Adaptado de Grando (2022).

5.4.2 Impulsionamento (*Boosting*)

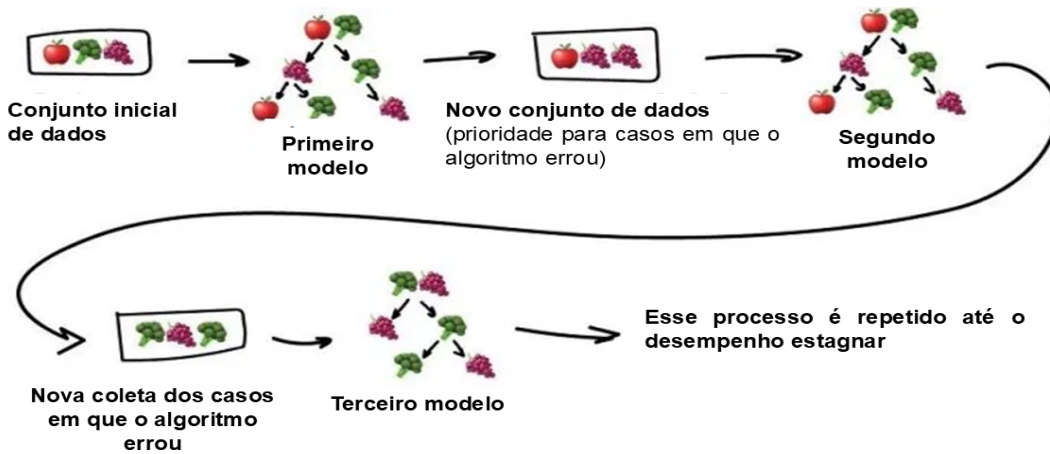
O *boosting* funciona treinando uma sequência de modelos, onde cada novo modelo é ajustado para corrigir os erros cometidos pelos modelos anteriores. Diferentemente do *bagging*, o *boosting* não gera modelos independentes, mas sim complementares, de modo que cada etapa do processo depende dos resultados anteriores (Lantz, 2023; Lange, 2024).

O processo de *boosting* começa com a construção de um modelo inicial a partir do conjunto de dados de treinamento original. Após essa etapa, as instâncias que foram classificadas incorretamente recebem um peso maior, aumentando a probabilidade de serem incluídas no treinamento do próximo modelo. Esse ciclo de ajuste (novos modelos focam em exemplos mais difíceis) permite que o *ensemble* aprenda progressivamente a lidar com casos desafiadores, melhorando sua capacidade preditiva global. Ao final, as previsões individuais dos modelos (aprendizes) são combinadas por meio de votação ponderada (em modelos de classificação) ou média ponderada (em modelos de regressão), onde modelos com melhor desempenho têm maior influência na decisão final (Lantz, 2023; Mendonça *et al.*, 2023).

Esse método é utilizado em algoritmos muito utilizados atualmente, tais como AdaBoost (*Adaptive Boosting*), *Gradient Boosting Machines* (GBM), e

XGBoost (*Extreme Gradient Boosting*) e *LightGBM*. A Figura 10 ilustra o processo de *boosting*, destacando a construção sequencial dos modelos, a reponderação dos exemplos difíceis e a combinação ponderada das previsões para formar uma decisão final robusta (Lantz, 2023).

Figura 10. Fluxograma do processo de Impulsionamento (*Boosting*)



Fonte: Adaptado de Grandó (2022).

De forma geral, de acordo com Lantz (2023) o processo de *boosting* pode ser resumido nas seguintes etapas:

- Inicializar pesos iguais para todas as instâncias do conjunto de treinamento.
- Treinar o primeiro modelo (aprendiz fraco) nos dados de treinamento.
- Avaliar o desempenho do modelo e atualizar os pesos das instâncias.
- Treinar novos modelos sequenciais, ajustando-os aos dados ponderados.
- Combinar as previsões dos modelos através de votação ponderada (classificação) ou média ponderada (regressão).



Análise de imagens e sons como uma perspectiva de
inovação na pós-colheita do lúpulo

6

CONCLUSÕES



Ao longo deste livro, buscou-se construir uma visão integrada sobre o uso da análise de imagens e, de forma central, da análise de dados sonoros na cadeia da pós-colheita do lúpulo, com ênfase no processo de secagem dos cones. A discussão dos fundamentos do processamento e da análise digital de imagens permitiu compreender como atributos visuais, como cor, textura e forma, podem refletir alterações estruturais e físicas associadas à perda de umidade ao longo do processo. Esses elementos visuais contribuem para a caracterização do produto e para a compreensão das transformações físicas envolvidas. No entanto, é na análise de dados sonoros que o livro concentra seu principal foco e contribuição conceitual, ao evidenciar o potencial do som como uma fonte de informação sensível às mudanças dinâmicas do material, com possibilidade de aplicação em ambientes produtivos reais, tornando-se particularmente atrativa para a agricultura e a agroindústria.

Ao abordar de maneira introdutória a modelagem estatística e o aprendizado de máquina, a obra não se propôs a aprofundar técnicas específicas nem a apresentar soluções prontas ou sistemas finalizados. O objetivo foi contextualizar o papel dessas ferramentas como instrumentos capazes de organizar, integrar e explorar os atributos extraídos de imagens e, sobretudo, de sons, reforçando a importância da interpretação dos dados em detrimento da complexidade dos métodos.

Dessa forma, a principal contribuição deste livro reside na construção de uma ponte entre diferentes áreas do conhecimento, como a agronomia, a engenharia agrícola, a ciência de dados e a engenharia de sinais. Ao iluminar possibilidades de aplicação de tecnologias já existentes, a obra convida o leitor a refletir sobre novos caminhos de pesquisa e desenvolvimento, estimulando abordagens interdisciplinares e abrindo espaço para soluções futuras mais eficientes, acessíveis e alinhadas às demandas reais da cadeia produtiva do lúpulo e outros produtos.

REFERÊNCIAS

- ASBC. **Technical Committe, A.: Hops - 4: Moisture**, ASBC Methods of Analysis, p. 1-2, 2011.
- ASHTIANI, S.H.M.; STURM, B.; NASIRAHMADI, A. Effect of hot-air and hybrid air-microwave srying on drying kinetics and textural quality of nectarine slices. **Heat Mass Transfer**, vol. 54 (4), p. 915–927. 2018.
- BAUERLE, W. L. Disentangling photoperiod from hop vernalization and dormancy for global production and speed breeding. *Scientific reports*, v. 9, n. 1, p. 1-8, 2019.
- BOCQUET, L.; SAHPAZ, S.; RIVIÈRE, C. An overview of the antimicrobial properties of hop. *Natural antimicrobial agents*, p. 31-54, 2018.
- CASTRO, P. H. N.; MOREIRA, G. J. P.; SILVA, E. J. L. An End-to-End Deep Learning System for Hop Classification. *IEEE Latin America Transactions*, v. 20, n. 3, p. 430-442, 2021.
- CERVBRASIL. **Dados do Setor Cervejeiro Nacional**, (2021). Disponível em: <http://www.cervbrasil.org.br/novo_site/dados-do-setor/>. Acesso em: 15 de Ago. 2023.
- CHADWICK, L. R.; PAULI, G. F.; FARNSWORTH, N. R. The pharmacognosy of *Humulus lupulus* L.(hops) with an emphasis on estrogenic properties. **Phytomedicine**, v. 13, n. 1-2, p. 119-131, 2006.
- CHAGAS, E., GARCIA, L. Lúpulo em pleno crescimento no Brasil. **Revista da Cerveja**, v. 36, p. 52-56, 2018.
- CHEN, J.; CHEN, J.; ZHANG, D.; SUN, Y.; NANEHKARAN, Y. A. Using deep transfer learning for image-based plant disease identification. **Computers and Electronics in Agriculture**, v. 173, p. 105393, 2020.
- CRICHTON, S.O.J.; SHRESTHA, L.; HURLBERT, A.; STURM, B. Prediction of moisture content and chromaticity of raw and pre-treated apple slices during convection drying using hyperspectral imaging. **Drying Technol**, Vol. 36, p. 804–816. 2018.
- DEVARAJ, A.; RATHAN, K.; JAAHNAVI, S.; INDIRA, K. Identification of plant disease using image processing technique. In: **2019 International Conference on Communication and Signal Processing (ICCSP)**. IEEE, 2019. p. 0749-0753.
- DIETZ, C.; COOK, D.; HUISMANN, M.; WILSON, M.; FORD, R. The multisensory perception of hop essential oil: a review. **Journal of the Institute Brewing**, vol. 126, p. 320–342, 2020.
- DODDS, K. Hops: **A guide for new growers**. NSW Government, Department of Primary Industries, (2017). Disponível em:<<https://www.wildabout hops.nz/assets/files/hops-guide-for-new-growers.pdf>>. Acesso em: 15 de Ago. 2024.
- EYRES, G; DUFOUR, J.P. Hop essential oil: Analysis, chemical composition and odor characteristics. In: **Beer in health and disease prevention**. Academic Press, 2009. p. 239-254.
- FAGHERAZZI, M. M. **Adaptabilidade de cultivares de lúpulos na região do Planalto do Sul Catarinense**. 2020. 116 p. Tese (Doutorado em Produção Vegetal) - Universidade do Estado de Santa Catarina, Centro de Ciências Agroveterinárias, 2020.
- FÁVERO, L. P.; BELFIORE, P.; SOUZA, R. F. **Data Science, Analytics and machine learning with R**. Academic Press, 2023.
- FIORENTINI, C.; DEMARCHI, S.M.; QUINTERO RUIZ, N.A.; TORREZ IRIGOYEN, R.M.; GINER, S.A. Arrhenius activation energy for water diffusion during drying of tomato leathers: The concept of characteristic product temperature. **Biosystems Engineering**, v. 132, p. 39-46, 2015.
- GOMES, O. F. M. Processamento e análise de imagens aplicados à caracterização auto-

- mática de materiais. **Departamento de Ciência de Materiais e Metalurgia Pontifícia Universidade Católica do Rio de Janeiro**, 2001.
- GRANDO, N. 2022. **A Essência do Aprendizado de Máquina**. Disponível em: <https://neigrando.com/tag/machine-learning/>. Acesso em: 27 nov. 2024.
- GRIESEL, A. Die Hopfentrocknung. *Deutsche Agrartechnik*, vol. 9, p. 217–219, 1959.
- HALLIDAY, D.; RESNICK, R.; WALKER, J. **Fundamentos de física**. 9. ed. Rio de Janeiro: LTC, 2012. v. 2.
- HARALICK, R. M. 18 Image texture survey. **Handbook of Statistics**, v. 2, p. 399–415, 1982.
- HENDERSON, S. M.; MILLER, G. E. Hop Drying Unique Problems and Some Solutions. **J. Agric. Eng. Res**, vol. 17, p. 281–287, 1972.
- HEŘMÁNEK, P. *et al.* Experimental chamber dryer for drying hops at low temperatures. **Agronomy Research**, v. 15, n. 3, p. 713–719, 2017.
- HERMANEK, P.; RYBKA, A.; HONZIK, I. Determination of moisture ratio in parts of the hop cone during the drying process in belt dryer. **Agronomy Research**. vol. 16 (3), p. 723–727, 2018.
- HERMANEK, P.; RYBKA, A.; HONZIK, I.; HOFFMANN, D.; JOST, B.; PODSEDNIK, J. Construction and Verification of an Experimental Chamber Dryer for Drying Hops. Proceedings of the 6th Int. **Conference on Trends in Agricultural Engineering (TAE 2016)**, Prague, Sep 7-9, 2016; Herak, D., Ed.; Czech University of Life Sciences Prague, Faculty of Engineering: Prague, p. 179–185, 2016.
- HOFMANN, R.; WEBER, S.; RETTBERG, N.; THÖRNER, S.; GARBE, L. A.; FOLZ, R. Optimization of the hop kilning process to improve energy efficiency and recover hop oils. **Brewing Science**, v. 66, p. 23–30, 2013.
- HUANG, D. M.; HUANG, J.; QIAO, K.; ZHONG, N. S.; LU, H. Z.; WANG, W. J. Deep learning-based lung sound analysis for intelligent stethoscope. **Military Medical Research**, v. 10, n. 1, p. 44, 2023.
- HUANG, P.; YANG, P.; XU, L.; WANG, Y.; YUAN, J.; KANG, Z. Moisture content detection of Tibetan tea based on hyperspectral technology, machine vision and machine learning. **Journal of Food Measurement and Characterization**, v. 19, n. 2, p. 1167–1185, 2024.
- KHALIFA, S.; KOMARIZADEH, M. H.; TOUSI, B.; NIKBAKHT, A. M. An intelligent system for grading walnuts based on acoustic emission and neural networks. **Journal of Food, Agriculture & Environment**, v. 9, n. 1, p. 109–112, 2011.
- KNEES, P.; SCHEDL, M. **Music similarity and retrieval: an introduction to audio-and web-based strategies**. Heidelberg: Springer, 2016.
- KURTULMUŞ, F.; ÖZTÜFEKÇİ, S.; KAVDIR, İ. Classification of chestnuts according to moisture levels using impact sound analysis and machine learning. **Journal of Food Measurement and Characterization**, v. 12, n. 4, p. 2819–2834, 2018.
- LANGE, C. **Practical Machine Learning with R: Tutorials and Case Studies**. CRC Press, 2024.
- LANTZ, B. **Machine learning with R: learn techniques for building and improving machine learning models, from data preparation to model tuning, evaluation, and working with big data**. Packt Publishing Ltd, 2023.
- LÊ, S.; JOSSE, J.; HUSSON, F. FactoMineR: an R package for multivariate analysis. **Journal of Statistical Software**, v. 25, p. 1–18, 2008.
- LEITE, G. B., PANDOLFO, C. Requerimentos agroclimáticos para a cultura do lúpulo. **Agropecuária Catarinense**, v. 35, n. 2, p. 3–86, 2022.
- LI, M.; YAN, Y. Comparative Analysis of Machine-Learning Models for Soil Moisture Esti-

- mation Using High-Resolution Remote-Sensing Data. **Land**, v. 13, n. 8, p. 1331, 2024.
- LIN, M.; XIANG, D.; CHEN, X.; HUO, H. Role of characteristic components of *Humulus lupulus* in promoting human health. **Journal of agricultural and food chemistry**, v. 67, n. 30, p. 8291-8302, 2019.
- LORENA, F. O.; JULIANO, B. L. **Terpenos, aromas e a química dos compostos naturais**. Química nova escola. São Paulo, v. 39, n. 2, maio 2017, p. 120-130, 2017.
- MARTYNENKO, A., STURM, B., 2019. The shift of paradigm from steady-state to intelligent drying, **Eurodrying'2019**, Torino, Italy, 10–12. July 2019.
- MARTYNENKO, A.; MISRA, N. N. Machine learning in drying. **Drying Technology**, v. 38, n. 5-6, p. 596-609, 2020.
- MENDONÇA, M. O. K.; NETTO, S. L.; DINIZ, P. S. R.; THEODORIDIS, S. **Machine learning**. In: **Signal processing and machine learning theory**. London: Elsevier, p. 869–961, 2023.
- MÜLLER, M. **Fundamentals of music processing: audio, analysis, algorithms, applications**. Cham: Springer, 2015.
- MÜLLER, M. **Fundamentals of music processing: using Python and Jupyter notebooks**. Berlin: Springer, 2021.
- MÜNSTERER, J. Neueste Erkenntnisse zur Leistungssteigerung und Energieeffizienz bei der Trocknung von Hopfen. In: **Proceedings of the 5th Congress of the International Hopgrowers' Convention IHGC, Bad Gögging, Germany**. 2015.
- MÜNSTERER, J. **Optimale Trocknung und Konditionierung von Hopfen**. Bayerische Landesanstalt für Landwirtschaft (LfL), Ed.: Freising-Weihenstephan, 2006.
- MÜNSTERER, J. Retaining Hop Quality through Optimum Drying / Erhalt der Hopfenqualität durch optimale Trocknung!. **Hopfen-Rundschau International**, p. 26–30, 2018.
- MUNSTERER, J. The Right Ventilation Air Ensures e Hop Quality / Sichern der Hopfenqualität durch richtige Belüftungsluft!. **Hopfen-Rundschau International**, p.48–52, 2019.
- NAEEM, S.; ALI, A.; CHESNEAU, C.; TAHIR, M. H.; JAMAL, F.; SHERWANI, R. A. K.; UL HASAN, M. The classification of medicinal plant leaves based on multispectral and texture feature using machine learning approach. **Agronomy**, v. 11, n. 2, p. 263, 2021.
- ORPHANIDES, A.; GOULAS, V.; BOTSARIS, G.; GEKAS, V. Influence of Air-Drying on the Quality Characteristics of Spearmint: Effects of Air Temperature and Velocity. **Journal of Food Processing and Preservation**, v. 41, n. 2, p. e12817, 2017.
- PINTO, M. B. C.; GHION, R. A. C.; SCHMIDT, F. L. Machine Learning Approach to Enhancing Drying Efficiency of Hop (*Humulus lupulus* L.). **Brewing Science**, v. 76, 2023.
- PU, Y.Y.; FENG, Y.Z; SUN, D.W. Recent progress of hyperspectral imaging on quality and safety inspection of fruits and vegetables: a review. **Comprehensive Reviews in Food Science and Food Safety**, v. 14, n. 2, p. 176-188, 2015.
- RAUT, S.; GERSDORFF, G. J. V.; MÜNSTERER, J.; KAMMHUBER, K.; HENSEL, O.; STURM, B. Impact of process parameters and bulk properties on quality of dried hops. **Processes**, v. 8, n. 11, p. 1507, 2020. DOI: 10.3390/pr8111507.
- RAUT, S.; VON GERSDORFF, G. J.; MÜNSTERER, J.; KAMMHUBER, K., HENSEL, O.; STURM, B. Influence of pre-drying storage time on essential oil components in dried hops (*Humulus lupulus* L.). **Journal of the Science of Food and Agriculture**, v. 101, n. 6, p. 2247-2255, 2021.
- RUBOTTOM, L. N.; LAFONTAINE, S. R.; SHELLHAMMER, T. H. Evaluating the impact of killing temperature on hop quality in American deep bed dryers. **Brewing Science**, p. 98, 2023.
- RYBKA, A.; HEŘMÁNEK, P.; HONZÍK, I. Effect of drying temperature in hop dryer on hop

- quality. **Research in Agricultural Engineering**, v. 67, n. 1, p. 1-7, 2021.
- RYBKA, A.; HEŘMÁNEK, P.; HONZÍK, I. Theoretical analysis of the technological process of hop drying. **Agronomy Research**. v. 15, n. 3, p. 859-865, 2017.
- RYBKA, A.; KROFTA, K.; HEŘMÁNEK, P.; HONZÍK, I.; POKORNÝ, J. Effect of drying temperature on the content and composition of hop oils. **Plant, Soil and Environment**, v. 64, n. 10, p. 512-516, 2018.
- SHARMA, G.; UMAPATHY, K.; KRISHNAN, S. Trends in audio signal feature extraction methods. **Applied Acoustics**, v. 158, p. 107020, 2020.
- SPÓSITO, M. B.; ISMAEL, R. V.; BARBOSA, C. D. A.; TAGLIAFERRO, A. L. A cultura do lúpulo. **Piracicaba, SP: Esalq-Divisão de Biblioteca**, 2019.
- STORK, D. G.; CODDINGTON, J.; BENTKOWSKA-KAFEL, A. **Computer vision and image analysis of art**. SPIE, v. 7531, 2010.
- STURM, B. **Systemic optimisation and design approach for thermal food processes: Increase of quality, process- and resource efficiency in dried agricultural products manufacturing**. Habilitationsschrift. Witzenhausen: Universität Kassel. 2018.
- STURM, B.; MOSCETTI, R.; CRICHTON, S. O. J.; RAUT, S.; BANTLE, M.; MASSANTINI, R. Feasibility of Vis/NIR spectroscopy and image analysis as basis of the development of smart-drying technologies. In: **Proceedings of the IDS 2018, 21st International Drying Symposium**, September 11-14, 2018, Valencia, Spain. 2018.
- SUEUR, J. **Sound analysis and synthesis with R**. Cham: Springer, 2018. 637 p.
- SUEUR, J.; AUBIN, T.; SIMONIS, C.; LELLOUCH, L.; AUMOND, P. **seewave: sound analysis and synthesis**. Versão 2.2.3. 2023. Disponível em: <https://cran.r-project.org/web/packages/seewave/seewave.pdf>. Acesso em: 21 out. 2024.
- SZELISKI, R. **Computer vision: algorithms and applications**. 2. ed. Switzerland: Springer, 2022.
- UMBAUGH, S. E. **Digital image processing and analysis: computer vision and image analysis**. CRC Press, 2023.
- VERZELE, M. 100 Years of Hop Chemistry and Its Relevance to Brewing. **J. Inst. Brew**, vol. 92, p. 32-48, 1986.
- ZIEGLER, T.; HASAN, J.; TEODOROV, T. Bottlenecks in continuous hops drying with conveyor-belt dryer, **Drying Technology**, vol. 40:13, p. 2598-2616, 2022.

AUTORES

Victor Crespo de Oliveira



Professor Assistente no Centro de Ciências da Natureza (CCN) da Universidade Federal de São Carlos (UFSCar). Doutor em Engenharia Agrícola pela Universidade Estadual Paulista (Unesp/FCA, 2025) na linha de pesquisa de Engenharia Agrícola de Precisão. É mestre em Engenharia Agrícola pela Universidade Federal de Viçosa (UFV, 2023), com ênfase em Construções Rurais e Ambiente, e Engenheiro Agrícola formado pela Universidade Federal de Lavras (UFLA, 2020). Pós-doutor em Engenharia Agrícola pela Universidade Federal da Grande Dourados (UFGD, 2026). Possui experiência e colaborações com instituições nacionais e internacionais em projetos de pesquisa científica. Atua nas áreas de Construções Rurais e Ambiente, Instrumentação, Análise de Dados, Prototipagem e Desenvolvimento Tecnológico, com forte integração entre a pesquisa científica e a aplicação prática no campo. Desenvolve tecnologias voltadas ao setor agropecuário, abrangendo o projeto de equipamentos, desenvolvimento de softwares e aplicação de técnicas avançadas de análise e modelagem de dados, como machine learning, análise multivariada, e processamento de sinais.

Sergio Augusto Rodrigues




Possui bacharelado (1997) e mestrado em Estatística (2003) pela Universidade Federal de São Carlos (UFSCar). É pós-graduado em Administração com ênfase em Marketing pela Universidade São Francisco - campus São Paulo (2000) e doutor pelo programa de Energia na Agricultura da Faculdade de Ciências Agrônomicas - Universidade Estadual Paulista (UNESP Botucatu). Tem experiência na área de Probabilidade e Estatística com ênfase em Estatística Aplicada, atuando principalmente nos seguintes temas: Amostragem e Delineamentos de Experimentos; Estatística Multivariada; Modelagem estatística e Computacional; Ciências de dados com linguagem R aplicada à Engenharia Agrícola; Desenvolvimento de sistemas inteligentes com soluções computacionais nas ciências agrárias e Aplicação métodos estatísticos em bioprocessos para tratamento de resíduos e geração de energia. Membro do grupo de pesquisa Agromet FCA (CNPq), atuando em linhas de pesquisa da engenharia agrícola de precisão, gestão dos recursos hídricos na agricultura e aplicações em Agrometeorologia. É Professor Dr. MS 3-2 da Faculdade de Ciências Agrônomicas - Unesp Botucatu-SP (Departamento de Bioprocessos e Biotecnologia).

Leonardo França da Silva



Engenheiro Agrônomo formado pela Universidade Federal de Minas Gerais (UFMG), com especializações em Engenharia de Segurança do Trabalho e Engenharia de Produção. Mestre em Agronomia pela Universidade Estadual Paulista (UNESP) e Doutor em Engenharia Agrícola, com ênfase em Construções Rurais e Ambiência, pela Universidade Federal de Viçosa (UFV). Pós-doutor em Engenharia Agrícola pela Universidade Federal da Grande Dourados (UFGD), com foco em Modelagem Matemática de Sistemas Agrícolas. Atualmente, é Professor Adjunto I da Faculdade de Agronomia e Medicina Veterinária da Universidade de Brasília (UnB), campus Brasília. Atua como pesquisador colaborador em diversos grupos de pesquisa vinculados ao CNPq: AMBIAGRO/UFV (Ambiência e Engenharia de Sistemas Agroindustriais), Engenharia de Sistemas Agrícolas Mecanizados (UFGD), LABOERGO/UFV (Ergonomia e Segurança Industrial, Segurança e Saúde do Trabalho, Ergonomia Florestal) e Núcleo PPJ/UFMG (Pesquisa e Apoio à Agricultura Familiar). Possui experiência nas áreas de Engenharia Agrícola, com ênfase em Construções Rurais e Ambiência, atuando também nos temas de Sustentabilidade em Sistemas de Produção Agropecuária, Ergonomia, Experimentação Agrícola, bem como no desenvolvimento de modelos e na simulação matemática aplicada à agricultura.

José Rafael Franco



Tecnólogo em Análise e Desenvolvimento de Sistemas pela Faculdade de Tecnologia de Botucatu (2017). Especialização em Banco de Dados na UNICESUMAR em Botucatu (2019), Mestrado em Irrigação e Drenagem na Faculdade de Ciências Agrônomicas (UNESP) de Botucatu (2021). Graduando em Ciência de Dados pela Faculdade Univesp. Doutor em Engenharia Agrícola na Faculdade de Ciências Agrônomicas (UNESP) de Botucatu. Possui experiências nas áreas de Telecomunicações, Redes de Computadores, Desenvolvimento de Softwares, Banco de Dados, Agrometeorologia, Instrumentos Meteorológica, Microcontroladores e Aplicações de baixo custo no meio agrícola. Professor no Centro universitário Uneduvale desde 2023.

Valeria Cristina Rodrigues Sarnighausen



Bacharel em Física Teórico-Experimental pelo Instituto de Física de São Carlos (IFSC/USP/2002). Mestre em Agronomia pela Escola Superior de Agricultura Luiz de Queiroz (ESALQ/USP/NUPEA - Núcleo de Pesquisa em Ambiente/2007). Doutora em Ciências, área de concentração: Física do Ambiente Agrícola, também pela ESALQ, (2011). Atualmente é Professora Doutora da Faculdade de Ciências Agrônômicas da Universidade Estadual Paulista Júlio de Mesquita Filho, UNESP, Campus de Botucatu, Departamento de Bioprocessos e Biotecnologia e Líder do Grupo de Pesquisa (CNPq): Agromet-FCA. É docente cadastrada no Programa de Pós-Graduação em Engenharia Agrícola da mesma unidade, atuando nas linhas de pesquisa: Manejo e Gestão dos Recursos Hídricos na Agricultura e Engenharia Agrícola de Precisão, com ênfase nos temas: Agrometeorologia das culturas, impacto das mudanças climáticas na agropecuária; Sensoriamento, automação e modelagem aplicada à agrometeorologia e Biometeorologia Animal e Vegetal.

Arthur Carniato Sanches



Professor Doutor da Universidade Federal da Grande Dourados, Dourados/MS. Foi professor substituto da Universidade Federal da Fronteira Sul, lecionando as disciplinas de Irrigação e Drenagem, Máquinas e Mecanização Agrícola, Campus Chapecó-SC. Possui graduação em Agronomia pela Universidade Estadual de Maringá (2009), onde desempenhou atividades extracurriculares com soja e milho, e extensão rural. Atuou como Assistente Técnico de Mercado pela Bayer CropScience na safra 2010/2011 em Campo Novo do Parecis-MT. Mestre em Engenharia Agrícola pela Universidade Federal da Grande Dourados, área Engenharia de Água e Solos, onde atuou com Manejo e Conservação da Água e Solo, Culturas Irrigadas e Sistemas Pressurizados de Irrigação. Doutor pelo programa de Engenharia de Sistemas Agrícolas pela Escola Superior de Agricultura “Luiz de Queiroz” -ESALQ/USP com ênfase em estudos de evapotranspiração e coeficiente de culturas em pastagens irrigadas. Tem experiência na área de Engenharia Agrícola e Agronomia, com ênfase em manejo de culturas irrigadas, hidráulica, Irrigação, Hidrologia e Drenagem.

Cristiano Marcio Alves de Souza



Professor Titular da Universidade Federal da Grande Dourados. Engenheiro Agrícola pela Universidade Federal de Viçosa (1999) e Doutor em Engenharia Agrícola pela Universidade Federal de Viçosa (2004). Orientador nos Programas de Pós-graduação em Engenharia Agrícola (Mestrado em Engenharia de Sistemas Agrícolas) e Agronomia (Doutorado em Produção Vegetal) da UFGD. Áreas pesquisadas: projeto de máquinas agrícolas e pós-colheita de produtos agrícolas - atuando nos seguintes temas: agricultura digital e de precisão, colheita, semeadura, compactação do solo, tecnologia de aplicação de defensivos agrícolas, secagem e aeração de grãos, modelagem, simulação e otimização de sistemas agrícolas, energia na agricultura.

ÍNDICE REMISSIVO

A

Amostragem de dados sonoros, 24–27

Análise de imagens, 7–9, 17–21

→ *atributos de cor*, 20–21

→ *atributos de forma*, 20–21

→ *atributos de textura*, 20–21

→ *segmentação*, 19

→ *pré-processamento*, 18–19

Análise de sinais sonoros, 7–9, 22–28

→ *domínio da frequência*, 25–27

→ *domínio do tempo*, 24–25

→ *domínio tempo-frequência*, 27

Aprendizado de máquina, 30–36

→ *aplicações na secagem*, 16

→ *fundamentos*, 30–31

→ *técnicas*, 34

Atributos (features)

→ *de imagem*, 20–21

→ *acústicos*, 24–27

B

Bagging (ver Ensacamento)

C

Cadeia produtiva do lúpulo, 5–6, 7–9

Classificação (machine learning), 32

Cones de lúpulo, 8–9, 11–13

→ *composição química*, 11

→ *comportamento na secagem*, 9

Controle de secagem, 16

D

Dados multimodais, 9

Desempenho de modelos, 33

→ *overfitting*, 33

→ *underfitting*, 33

E

Ensemble (ver Métodos de aprendizado em conjunto)
Ensacamento (Bagging), 35
Espectro de frequência, 25–26
Extração de atributos, 20–21, 24–27

F

Frequência (som), 24–25

I

Imagem digital, 18–19
→ *pixels*, 19
→ *representação numérica*, 19
Inteligência artificial, 30–32

L

Lúpulo (*Humulus lupulus*), 8, 11–13
→ *composição química*, 11
→ *cultivo no Brasil*, 8
→ *importância industrial*, 8
→ *propriedades sensoriais*, 8

M

Modelagem preditiva, 30–31
Modelos de previsão, 31
Monitoramento de processos, 9, 16

O

Ondas sonoras, 23–24
→ *amplitude*, 23–24
→ *frequência*, 24
→ *período*, 23
→ *propagação*, 23

P

Pós-colheita do lúpulo, 5–6, 7–9

Processamento de imagens (PDI), 18–19
Processamento de sinais, 22–28
→ *Transformada de Fourier*, 25–26

Q

Qualidade do lúpulo, 11–13
→ *compostos aromáticos*, 11–12
→ *influência da secagem*, 12–13

S

Secagem do lúpulo, 10–16
→ *controle de temperatura*, 12–13
→ *influência da umidade*, 12
→ *tempo de secagem*, 12–13
→ *variáveis do processo*, 12–16
Segmentação de imagens, 19
Sinais acústicos, 24–27
Sistemas inteligentes, 9, 16

T

Temperatura de secagem, 12–13
→ *efeitos na qualidade*, 12–13
Transformada de Fourier, 25–26

U

Umidade do lúpulo, 12
→ *métodos de determinação*, 8–9

V

Variáveis de secagem, 12–16

A obra apresenta uma abordagem interdisciplinar sobre o uso da análise de imagens e sinais sonoros na pós-colheita do lúpulo, com foco no processo de secagem. Fundamentado em revisão da literatura, o livro discute atributos visuais e acústicos capazes de refletir transformações físicas do produto. Integra conceitos de agronomia, engenharia e ciência de dados, destacando o potencial de técnicas não destrutivas e automatizáveis. Também introduz fundamentos de aprendizado de máquina aplicados à modelagem preditiva. A proposta central é ampliar o entendimento do processo e estimular o desenvolvimento de sistemas inteligentes.

ISBN 978-65-84364-36-3



9 786584 364363 >

