



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO
SERTÃO PERNAMBUCANO
CAMPUS PETROLINA ZONA RURAL

CURSO DE TECNOLOGIA EM VITICULTURA E ENOLOGIA

**INTELIGÊNCIA ARTIFICIAL NA VITICULTURA: UMA REVISÃO
BIBLIOGRÁFICA SOBRE ADOÇÃO, PANORAMA ATUAL E
PERSPECTIVAS FUTURAS**

**MARIA LUCIANA PEREIRA DE
ARAÚJO**

PETROLINA – PE
2025

MARIA LUCIANA PEREIRA DE ARAÚJO

**INTELIGÊNCIA ARTIFICIAL NA VITICULTURA: UMA REVISÃO
BIBLIOGRÁFICA SOBRE ADOÇÃO, PANORAMA ATUAL E
PERSPECTIVAS FUTURAS**

Trabalho de Conclusão de Curso
apresentado ao Instituto Federal do Sertão
Pernambucano - Campus Petrolina Zona
Rural, exigido para a obtenção do título de
Tecnólogo em Viticultura e Enologia.

Orientador: Prof. Dr. Júlio César Sobreira Ferreira

PETROLINA – PE
2025

Dados Internacionais de Catalogação na Publicação (CIP)

A658 Araújo, Maria Luciana Pereira de.

Inteligência artificial na viticultura: uma revisão bibliográfica sobre adoção, panorama atual e perspectivas futuras / Maria Luciana Pereira de Araújo. - Petrolina, 2025.
75 f. : il.

Trabalho de Conclusão de Curso (Viticultura e Enologia) -Instituto Federal de Educação, Ciência e Tecnologia do Sertão Pernambucano, Campus Petrolina Zona Rural, 2025.
Orientação: Prof. Dr. Júlio César Sobreira Ferreira.

1. Viticultura. 2. Inteligência artificial. 3. Aprendizado de máquina. 4. Agricultura digital. 5. Enologia. I. Título.

CDD 634.8

MARIA LUCIANA PEREIRA DE ARAÚJO

**INTELIGÊNCIA ARTIFICIAL NA VITICULTURA: UMA REVISÃO
BIBLIOGRÁFICA SOBRE ADOÇÃO, PANORAMA ATUAL E
PERSPECTIVAS FUTURAS**

Trabalho de Conclusão do Curso
apresentado ao Instituto Federal do Sertão
Pernambucano - Campus Petrolina Zona
Rural, exigido para a obtenção de título de
Tecnólogo em Viticultura e Enologia

Aprovada em: 28 de novembro de 2025.

Prof. Dr. Júlio César Sobreira Ferreira
Instituto Federal do Sertão Pernambucano, Campus Petrolina Zona Rural

Prof^a Ma. Bruna Silva Costa
Instituto Federal do Sertão Pernambucano, Campus Petrolina Zona Rural

Prof^a Ma. Renata Gomes de Barros Santos
Instituto Federal do Sertão Pernambucano, Campus Petrolina Zona Rural

Agradecimentos

A Deus, pela força e sabedoria concedidas durante toda esta caminhada acadêmica.

À minha família, pelo apoio incondicional, paciência e incentivo em todos os momentos, especialmente nas etapas mais desafiadoras deste trabalho.

Ao meu orientador Prof. Dr. Júlio César Sobreira Ferreira, pela orientação técnica, pelas valiosas contribuições intelectuais e pela confiança depositada no desenvolvimento desta pesquisa.

Aos professores e colegas do curso, pelo compartilhamento de experiências e aprendizados que enriqueceram esta trajetória.

A todos os pesquisadores cujos estudos serviram de base para esta investigação e às instituições que fomentam o desenvolvimento da inteligência artificial e da viticultura de precisão, contribuindo para a inovação no setor agrícola.

Por fim, a todos que, de alguma forma, colaboraram para a concretização deste trabalho, deixo o meu sincero agradecimento.

EPÍGRAFE

“A mente que se abre a uma nova ideia jamais voltará ao seu tamanho original.”

– Albert Einstein

RESUMO

Este trabalho apresenta uma revisão bibliográfica sobre o uso da inteligência artificial (IA) na viticultura, abrangendo o período de 2009 a 2024. A pesquisa identificou as principais aplicações, desafios e perspectivas da IA no setor, considerando o contexto global e brasileiro. Os resultados mostram uma trajetória evolutiva dividida em três fases: aplicação exploratória (2009–2014), expansão experimental e validação de modelos (2015–2019) e consolidação da viticultura inteligente (2020–2024). Observa-se o avanço do uso de aprendizado de máquina, visão computacional, sensoriamento remoto e integração com Internet das Coisas, refletindo em ganhos de produtividade, sustentabilidade e qualidade. Conclui-se que a IA constitui um eixo estruturante para a Agricultura 5.0, promovendo uma viticultura mais eficiente e conectada.

Palavras-chave: Viticultura; inteligência artificial; aprendizado de máquina; agricultura digital; enologia.

ABSTRACT

This work presents a bibliographic review on the use of artificial intelligence (AI) in viticulture, covering the period from 2009 to 2024. The study identified the main applications, challenges, and perspectives of AI in the sector, considering global and Brazilian contexts. The results reveal an evolutionary trajectory divided into three phases: exploratory applications (2009–2014), experimental expansion and model validation (2015–2019), and consolidation of intelligent viticulture (2020–2024). Advances in machine learning, computer vision, remote sensing, and IoT integration have improved productivity, sustainability, and product quality. It is concluded that AI represents a key component of Agriculture 5.0, enabling a more efficient and connected viticulture.

Key words: viticulture; artificial intelligence; machine learning; digital agriculture; enology.

LISTA DE ILUSTRAÇÕES

Figura 1 – Fases da evolução da agricultura	19
Figura 2 – A agricultura digital na cadeia produtiva nas fases de pré-produção, produção e pós-produção	22

LISTA DE TABELAS

Tabela 1 – Comparativo entre estudos sobre IA na viticultura (2009–2014)	61
Tabela 2 – Comparativo entre estudos sobre IA na viticultura (2015–2019)	66
Tabela 3 – Comparativo entre estudos sobre IA na viticultura (2020–2024)	71

LISTA DE ABREVIATURAS E SIGLAS

IA – Inteligência Artificial

IoT – Internet das Coisas

OIV – Organização Internacional da Vinha e do Vinho

GPS – Sistema de Posicionamento Global

INPE – Instituto Nacional de Pesquisas Espaciais

TICs – Tecnologias da Informação e Comunicação

NIR – Infravermelho Próximo (Near Infrared)

CNN – Convolutional Neural Network (Rede Neural Convolucional)

MLP – Multilayer Perceptron (Perceptron de Múltiplas Camadas)

SVM – Support Vector Machine (Máquina de Vetores de Suporte)

GAN – Generative Adversarial Network (Rede Generativa Adversarial)

NDVI – Normalized Difference Vegetation Index (Índice de Vegetação por Diferença Normalizada)

SUMÁRIO

1	INTRODUÇÃO	13
2	OBJETIVOS	15
2.1	Objetivo geral	15
2.2	Objetivos específicos	15
3	REFERENCIAL TEÓRICO	16
3.1	Panorama Da Viticultura No Contexto Global.....	16
3.2	Panorama Da Viticultura No Brasil.....	17
3.3	Fatores Que Viabilizam A Adoção De Tecnologias Digitais Na Viticultura.....	18
3.4	Tecnologias Digitais Na Agricultura.....	19
3.4.1	Agricultura 4.0 E 5.0.....	20
3.4.2	Tecnologias Emergentes.....	22
4	MATERIAL E MÉTODOS	25
5	RESULTADOS E DISCUSSÕES	26
5.1	Primeiras aplicações exploratórias de IA na viticultura (2009–2014).....	26
5.1.1	Introdução histórica: O caso Enologix (EUA, 2001).....	26
5.1.2	Panorama global (2009–2014).....	27
5.1.3	Comparativo entre estudos (2009-2014).....	30
5.1.4	Implicações práticas, teóricas e setoriais (2009-2014).....	31
5.1.5	Lacunas identificadas (2009-2014).....	31
5.2	Expansão experimental e validação de modelos (2015–2019).....	32
5.2.1	Panorama global (2015–2019).....	32
5.2.2	Comparativo entre estudos (2015-2019).....	35
5.2.3	Implicações práticas, teóricas e setoriais (2015-2019).....	36
5.2.4	Lacunas identificadas (2015-2019).....	36

5.3	Consolidação e integração de sistemas inteligentes (2020–2024).....	37
5.3.1	Panorama global (2020–2024).....	38
5.3.2	Comparativo entre estudos (2020-2024).....	41
5.3.3	Implicações práticas, teóricas e setoriais (2020-2024).....	42
5.3.4	Lacunas identificadas (2020-2024).....	42
6	CONSIDERAÇÕES FINAIS	44
	REFERÊNCIAS	47
	ANEXOS	60

1 INTRODUÇÃO

A viticultura é uma prática milenar que combina conhecimento empírico e tradição, sendo responsável pela produção de uvas destinadas ao consumo in natura, à elaboração de sucos, vinhos e outros derivados. Com importância econômica, social e cultural em diversas regiões do mundo, essa atividade tem passado por transformações significativas impulsionadas pelas inovações tecnológicas do século XXI.

Historicamente fundamentada em práticas artesanais, a viticultura passou a incorporar soluções mecânicas, químicas e, mais recentemente, digitais, acompanhando o avanço das chamadas Revoluções Agrícolas. A transição da agricultura convencional para a Agricultura 4.0 — caracterizada pela integração da Internet das Coisas (IoT), Inteligência Artificial (IA), Big Data e computação em nuvem, com sistemas capazes de operar de forma integrada, inteligente e parcialmente autônoma — tem modificado profundamente os sistemas produtivos no campo (Zhai et al., 2020).

Em continuidade a esse processo, a chamada Agricultura 5.0, ainda em desenvolvimento, amplia essa transformação ao incorporar sistemas mais autônomos, adaptativos e intensivos em dados, como resposta aos desafios contemporâneos, incluindo a escassez de mão de obra, as mudanças climáticas e as exigências crescentes por sustentabilidade e rastreabilidade (Naikwade et al., 2021; Mendes et al., 2020; Liakos et al., 2018; Massruhá et al., 2017).

Nesse contexto, a viticultura tem apresentado diferentes graus de adaptação conforme as realidades regionais e o nível de modernização dos produtores. Embora existam barreiras ligadas à tradição, à variabilidade ambiental e à disponibilidade de recursos, observa-se uma crescente aceitação das tecnologias digitais. Entre elas, a inteligência artificial destaca-se por seu potencial de transformar a gestão agrícola, melhorar a tomada de decisão, otimizar recursos e agregar valor à produção (Stefenon, 2024; Liakos et al., 2018).

Apesar de sua adoção exigir tempo, investimentos e capacitação técnica, a inteligência artificial representa uma possibilidade real de transformação estrutural

da cadeia produtiva da viticultura. Mostra-se especialmente promissora em culturas sensíveis como a videira, cuja produtividade depende de diversos fatores interdependentes. Já é possível observar ganhos significativos desde o preparo do solo até a colheita, com maior rastreabilidade, transparência e qualidade final do produto (Stefenon, 2024; Liakos et al., 2018).

Diante disso, este estudo, por meio de uma revisão bibliográfica, tem como objetivo analisar a adoção da inteligência artificial na viticultura, reunindo evidências sobre seus benefícios, desafios e perspectivas. Ao discutir a aplicação dessa tecnologia no setor, pretende-se contribuir para o fortalecimento de uma viticultura mais eficiente, resiliente e alinhada às exigências atuais.

2 OBJETIVOS

2.1 Objetivo geral

Analisar a adoção da inteligência artificial na viticultura, com base em uma revisão bibliográfica da literatura científica publicada entre 2009 e 2024, destacando tendências, desafios e possibilidades de aplicação atuais ou futuras na cadeia produtiva da viticultura.

2.2 Objetivos específicos

- Levantar publicações científicas sobre o uso da inteligência artificial na agricultura entre 2009 e 2024.
- Identificar as principais ferramentas e aplicações de IA utilizadas no contexto agrícola.
- Apresentar o uso atual e as perspectivas futuras da IA na viticultura.
- Apontar os principais desafios e limitações identificados na literatura quanto à adoção da inteligência artificial nesse setor.

3 REFERENCIAL TEÓRICO

3.1 Panorama Da Viticultura No Contexto Global

De acordo com a Organização Internacional da Vinha e do Vinho (OIV), em 2024, a área global ocupada por vinhedos foi de aproximadamente 7,1 milhões de hectares. Entre os principais produtores de uvas destacam-se Espanha, França, China, Itália e Turquia, que concentram uma parcela significativa da produção mundial, seja para vinificação, consumo in natura ou outros fins.

Apesar dessa expressiva área cultivada, observa-se uma tendência de retração. Segundo a OIV (2024), houve uma redução de 0,6% na extensão total de vinhedos em comparação a 2023, marcando o quarto ano consecutivo de queda. Essa redução tem sido associada à remoção de vinhedos nas principais regiões produtoras dos dois hemisférios, afetando tanto as uvas viníferas quanto aquelas destinadas ao consumo in natura e à elaboração de outros derivados.

Diversos fatores explicam esse cenário: eventos climáticos extremos, aumento dos custos de produção, mudanças nos padrões de consumo e instabilidades econômicas e geopolíticas. Esses mesmos fatores influenciam a produção de vinhos, que atingiu, em 2024, o menor nível desde 1961, totalizando aproximadamente 225,8 milhões de hectolitros — uma queda de 4,8% em relação ao ano anterior. Na França, segundo maior produtor mundial, a colheita foi reduzida em 23,5% devido às condições meteorológicas adversas, atingindo 36,1 milhões de hectolitros (Brasil de Vinhos, 2024).

Ainda em 2024, o consumo global de vinhos foi estimado em 214,2 milhões de hectolitros, representando uma queda de 3,3% em relação a 2023. Apesar do recuo, o comércio internacional de vinhos manteve seu valor elevado, alcançando 35,9 bilhões de euros, o que evidencia a relevância econômica e cultural do setor vitivinícola em escala global (OIV, 2024).

3.2 Panorama Da Viticultura No Brasil

Segundo dados do Instituto Brasileiro de Geografia e Estatística (IBGE) em 2023, a produção nacional de uvas alcançou cerca de 1,75 milhão de toneladas, distribuídas em aproximadamente 77 mil hectares colhidos, com rendimento médio de 22,8 toneladas por hectare. A atividade está concentrada em mais de nove mil estabelecimentos, com destaque para o Rio Grande do Sul, principal estado produtor do país.

Em 2024, o Brasil contrariou a tendência de retração observada em outras regiões vitivinícolas do mundo, registrando um crescimento de 1,6% na área cultivada em relação ao ano anterior, totalizando 83 mil hectares (OIV, 2024)¹.

Apesar do avanço na área plantada, o ciclo 2023/2024 foi marcado por uma quebra de safra expressiva: a produção nacional de vinhos atingiu apenas 2,1 milhões de hectolitros, volume 25,2% inferior à média dos cinco anos anteriores. Esse cenário evidencia a vulnerabilidade do setor frente a eventos climáticos adversos (Brasil de Vinhos, 2024).

Diante de um contexto marcado por instabilidade climática, volatilidade de mercado e pressão crescente por práticas mais sustentáveis, surgem questionamentos sobre como a viticultura poderá se manter competitiva nas próximas décadas.

¹ A diferença entre os dados do IBGE (77 mil ha) e da OIV (83 mil ha) pode decorrer de critérios distintos na delimitação das áreas vitícolas. O IBGE considera dados declarados por estabelecimentos agropecuários no território nacional, enquanto a OIV pode adotar estimativas baseadas em múltiplas fontes ou incluir áreas de dupla aptidão (mesa e vinho).

3.3 Fatores Que Viabilizam A Adoção De Tecnologias Digitais Na Viticultura

A adoção de tecnologias digitais na viticultura vai além de uma simples resposta às dificuldades climáticas e econômicas já discutidas. Sua expansão também tem sido favorecida por um conjunto de condições estruturais, técnicas e mercadológicas que criam um ambiente propício à modernização do setor. Ainda assim, diante das exigências específicas da cultura da videira — que requer um manejo altamente preciso e adaptativo —, e dos crescentes desafios ambientais, evidencia-se, portanto, a importância crescente de tecnologias que viabilizem o monitoramento em tempo real, a previsão precisa de variáveis críticas e ao suporte à tomada de decisão agronômica.

Além desses fatores técnicos e ambientais, a intensificação da digitalização também se relaciona à crescente complexidade e competitividade do setor vitivinícola, que, assim como outros segmentos do agronegócio, exige maior eficiência na coordenação estratégica, modernização tecnológica e infraestrutura de apoio. Ainda que os produtos derivados da uva não possam ser considerados commodities convencionais — pois dependem de variáveis como cultura, tradição, terroir e conhecimento técnico —, a inovação tem se mostrado essencial para converter essas especificidades em vantagens competitivas no mercado global (Protas; Lazzarotto; Machado, 2022).

Um dos elementos centrais dessa transformação é a capacidade de transformar dados gerados ao longo da cadeia produtiva em conhecimento acionável. Essa evolução tecnológica tem permitido que os sistemas digitais apoiem decisões cada vez mais complexas, tanto no nível da propriedade quanto na gestão da cadeia de valor, marcando a transição da agricultura de precisão para a agricultura digital — uma abordagem mais integrada, preditiva e orientada à ação estratégica (Shepherd, 2020).

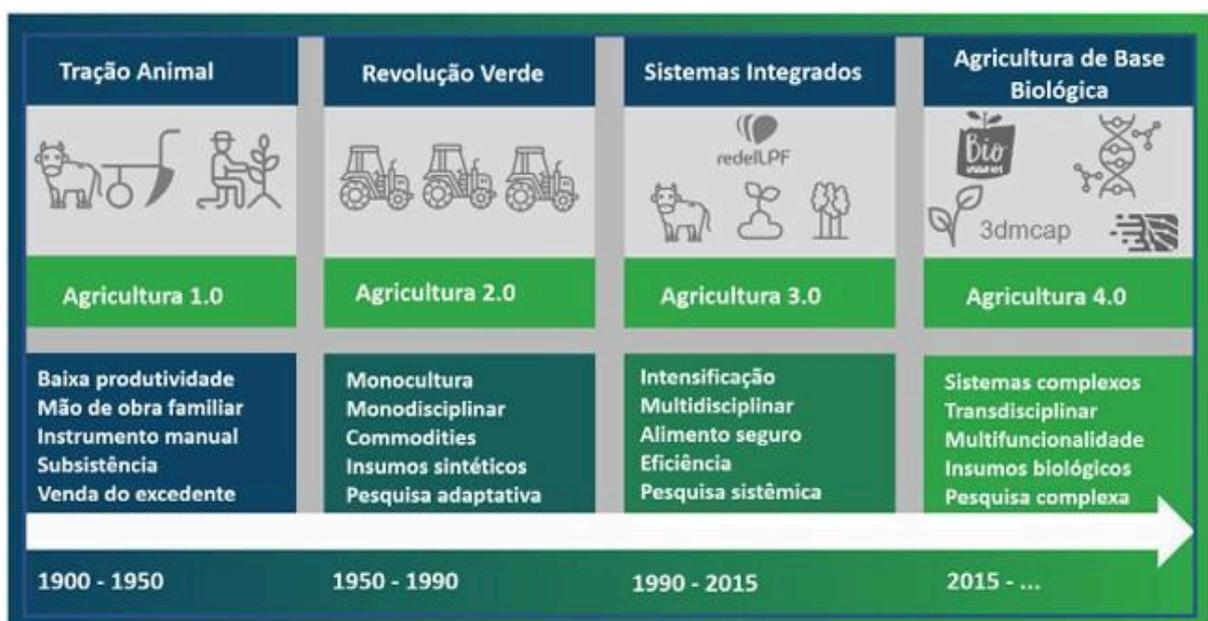
Diante desse cenário multifatorial, a Organização Internacional da Vinha e do Vinho reconhece que o setor vitivinícola enfrenta não apenas desafios estruturais, mas também oportunidades relevantes (OIV, 2024). Assim, a adoção de ferramentas

digitais, com destaque para a inteligência artificial, já não se limita a uma tendência emergente, mas consolida-se como uma condição necessária para o setor em escala global. Nesse contexto, a digitalização não apenas otimiza processos existentes, mas também prepara a viticultura para responder com inteligência aos desafios das próximas décadas.

3.4 Tecnologias Digitais Na Agricultura

Após a análise das condições que favorecem a adoção de tecnologias digitais na viticultura, é oportuno compreender o panorama mais amplo da transformação digital no setor agrícola como um todo. Segundo Shepherd (2020), o uso de tecnologias digitais na agricultura remonta à chamada Agricultura de Precisão, que emergiu no final da década de 1980. Inicialmente centrada na integração de sistemas de posicionamento global (GPS) a tratores e no mapeamento de produtividade, essa abordagem evoluiu significativamente ao longo do tempo, e permanece em constante desenvolvimento, como demonstra a linha do tempo apresentada na Figura 1, que retrata fases da evolução da agricultura.

Figura 1: Fases da evolução da agricultura.



Fonte: MASSRUHÁ; LEITE; LUCHIARI JUNIOR; EVANGELISTA (2021, p. 28).

Ainda de acordo com Shepherd (2020), há uma percepção generalizada de que essas tecnologias possuem um potencial transformador profundo, o que tem mobilizado esforços em escala global. A União Europeia, por exemplo, busca incorporar a digitalização em sua Política Agrícola Comum, enquanto países como a Índia já observam impactos positivos sobre a renda e a qualidade de vida dos produtores. Contudo, o autor destaca que a adoção plena desses recursos demanda a superação de barreiras técnicas, econômicas e sociais, sobretudo em contextos de agricultura familiar e pequenas propriedades, onde o processo tende a ser mais gradual.

No Brasil, uma pesquisa realizada em parceria entre a Embrapa, o Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (Sebrae) e o Instituto Nacional de Pesquisas Espaciais (INPE) revelou que 84,1% dos produtores rurais utilizam ao menos uma tecnologia digital em seus processos produtivos. As principais finalidades estão relacionadas ao planejamento das atividades (66,1%), à gestão da propriedade (43,3%), à comercialização de insumos e produtos (40,5%), ao mapeamento e ao uso da terra (32,7%) e à previsão de eventos climáticos extremos, como geadas, veranicos e chuvas intensas (30,2%) (SANTIN, 2020, apud MASSRUHÁ et al., 2020).

Tais dados reforçam que a agricultura digital é uma realidade em expansão, embora apresente diferentes graus de maturidade entre os produtores. Contudo, sua plena consolidação ainda depende da superação de desafios estruturais, especialmente entre pequenos e médios agricultores, que enfrentam limitações relacionadas à conectividade, à capacitação técnica e ao acesso a crédito e infraestrutura.

3.4.1 Agricultura 4.0 E 5.0

A transformação digital tem sido impulsionada pela Agricultura Inteligente, que, segundo Pivoto et al. (2018), baseia-se na incorporação de tecnologias da informação e comunicação (TICs) em máquinas, sensores e equipamentos agrícolas. Essa integração viabiliza a geração, transmissão e análise de grandes volumes de dados, tornando os processos produtivos mais precisos e eficientes. Tal


prática depende fortemente da conectividade, da Internet das Coisas (IoT) e de sistemas de armazenamento em nuvem, configurando-se como uma resposta não apenas às demandas tecnológicas, mas também aos desafios demográficos — como o envelhecimento da população rural e a migração urbana —, além das pressões impostas pelas mudanças climáticas.

Nesse contexto, emerge a Agricultura 4.0, que, conforme Saiz-Rubio;Rovira-Más (2020), representa uma evolução da Agricultura de Precisão, agora aliada à telemática e à gestão avançada de dados. Essa fase permite que os produtores tomem decisões mais assertivas, tanto no âmbito estratégico quanto operacional, a partir da análise contínua das informações geradas nas propriedades.

Com o avanço das tecnologias, o setor caminha para a Agricultura 5.0, que incorpora sistemas autônomos, inteligência artificial e robótica, oferecendo respostas aos desafios contemporâneos — especialmente à crescente escassez de mão de obra no campo. Diferentemente da etapa anterior, essa nova fase não se limita a ganhos de produtividade, mas prioriza também a sustentabilidade, a automação e a eficiência em toda a cadeia produtiva.

Nessa mesma linha, Massruhá (2020) ressalta que a Agricultura Digital fundamenta-se na geração e utilização de dados em todas as etapas da cadeia — da pré-produção à pós-produção, como ilustra a Figura 2. Na fase de pré-produção, ferramentas como mineração de dados, bioinformática e modelagem auxiliam na identificação de características genéticas de interesse em plantas e animais. Durante a produção, tecnologias como sensoriamento remoto, agricultura de precisão, robótica e análise de dados permitem o monitoramento detalhado de solos, plantas, animais e equipamentos, otimizando práticas como irrigação, controle de pragas e uso racional de insumos. Por fim, na pós-produção, os dados gerados proporcionam maior eficiência logística, rastreabilidade, previsão de safras e segurança alimentar, além de impulsionar a automação e a integração dos processos agroindustriais e agroalimentares.

Figura 2. A agricultura digital na cadeia produtiva nas fases de pré-produção, produção e pós-produção.



Fonte: MASSRUHÁ; LEITE; LUCHIARI JUNIOR; EVANGELISTA (2021, p. 29).

3.4.2 Tecnologias Emergentes

Diante desse cenário de transformação digital e da evolução para os modelos de Agricultura 4.0 e 5.0, torna-se indispensável compreender as tecnologias emergentes que sustentam essa revolução no setor agropecuário. Essas tecnologias não apenas viabilizam a coleta, o processamento e a análise de dados, mas também impulsionam uma agricultura mais inteligente e eficiente.

Segundo Souza et al. (2020), as tecnologias digitais aplicadas à agricultura podem ser organizadas em cinco grupos principais, que se inter-relacionam para compor o ecossistema da agricultura digital. O primeiro grupo refere-se às ferramentas voltadas à organização, representação e acesso à informação — aspecto fundamental diante do crescente volume, diversidade e heterogeneidade dos dados agrícolas. Dados genéticos, imagens de satélite e registros de sensores, por

exemplo, precisam ser anotados, estruturados e classificados para que possam ser reutilizados de forma eficiente no futuro, o que exige estratégias robustas de gestão da informação.

O segundo grupo contempla técnicas de modelagem matemática e estatística, utilizadas para representar e compreender fenômenos biológicos, sociais e ambientais. Essa modelagem é parte essencial do método científico, pois permite simular comportamentos, prever cenários e apoiar a tomada de decisões baseadas em dados. Nessa perspectiva, a Ciência de Dados ganha protagonismo como campo interdisciplinar, integrando estatística, computação e conhecimento setorial, possibilitando a extração de insights valiosos a partir de grandes volumes de dados.

Já o terceiro grupo diz respeito ao uso da inteligência artificial na agricultura. Tecnologias de aprendizado de máquina, deep learning e reconhecimento de padrões permitem que sistemas processem informações complexas e realizem tarefas como a identificação de objetos em imagens, detecção de anomalias, previsão de produtividade e antecipação de riscos fitossanitários. Esses recursos, que sustentam soluções como veículos autônomos e assistentes de voz, estão cada vez mais aplicados em sistemas agrícolas inteligentes. Quando se busca representar diretamente regras que envolvem graus de incerteza, emprega-se também a lógica nebulosa como abordagem complementar.

O quarto grupo engloba sensores e robótica, pilares da automação no campo. Sensores orbitais, como satélites, e sensores proximais, instalados diretamente nas propriedades rurais, são integrados a dispositivos conectados via Internet das Coisas (IoT). Esses elementos possibilitam o monitoramento em tempo real de variáveis ambientais e operacionais, além da execução automática de respostas por meio de atuadores inteligentes. Quando a computação se distribui no ambiente e opera de forma invisível ao usuário, surge o paradigma da computação ubíqua, que viabiliza aplicações como pulverização de precisão, irrigação inteligente, colheita automatizada e mapeamento de solo.

Por fim, o quinto grupo é formado por tecnologias inicialmente desenvolvidas para outros setores, como blockchain e computação em nuvem, mas que hoje convergem para atender às necessidades do agronegócio. Enquanto a nuvem oferece

escalabilidade, segurança e resiliência no armazenamento e no processamento de dados, o blockchain atende às demandas crescentes por rastreabilidade, segurança e transparência em cadeias produtivas cada vez mais complexas e exigentes.

Dessa forma, as tecnologias emergentes não operam de forma isolada, mas se complementam e se integram, fornecendo a base técnica e conceitual para uma agricultura orientada por dados, altamente conectada e responsiva aos desafios contemporâneos — desde a escassez de recursos até as exigências de sustentabilidade e segurança alimentar.

4 MATERIAL E MÉTODOS

Realizou-se uma revisão bibliográfica com abordagem qualitativa, cujo caráter exploratório buscou compreender as principais aplicações e desafios da inteligência artificial na viticultura. A abordagem metodológica adotada possibilitou a reunião, interpretação e categorização de informações provenientes de publicações acadêmicas, documentos técnicos e fontes institucionais de relevância nacional e internacional.

A busca por materiais foi realizada entre os meses de abril e junho de 2025, utilizando como fontes principais o Google Acadêmico, documentos da Embrapa Uva e Vinho, relatórios da Organização Internacional da Vinha e do Vinho (OIV), além de notícias atualizadas sobre inovações tecnológicas no setor vitivinícola, além de notícias atualizadas sobre inovações tecnológicas no setor vitivinícola, a inclusão de notícias e relatórios justifica-se visto que o tema da Inteligência Artificial é de rápida evolução, e muitas das aplicações mais recentes (como a enologia digital) são primeiramente reportadas nestes meios antes de serem consolidadas na literatura científica. Foram selecionadas publicações divulgadas entre 2009 e 2024, a fim de abarcar a evolução tecnológica e o amadurecimento das aplicações de IA na agricultura, abrangendo artigos científicos, teses, dissertações e trabalhos de conclusão de curso, nos idiomas português, inglês e espanhol.

As palavras-chave utilizadas nas buscas incluíram combinações como: “inteligência artificial”, “viticultura”, “agricultura digital”, “machine learning”, “agricultura de precisão”, “vinhedo inteligente”, entre outras relacionadas. Os critérios de inclusão consideraram a relevância temática, a aplicabilidade prática e a vinculação direta ou indireta com o setor vitivinícola.

A análise do conteúdo foi conduzida de forma qualitativa, com base na leitura interpretativa dos textos, identificação de padrões e síntese das principais contribuições teóricas e práticas. Os estudos foram organizados segundo marcos temporais (2009–2014, 2015–2019 e 2020–2024), de modo a evidenciar a evolução do uso da inteligência artificial no agronegócio ao longo dos últimos 15 anos. Essa estrutura permitiu observar tendências, avanços tecnológicos, desafios relatados na

literatura e oportunidades de aplicação na viticultura, que foram compilados e analisados neste trabalho.

5 RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados da revisão bibliográfica sobre o uso da inteligência artificial (IA) na viticultura, abrangendo publicações científicas compreendidas entre 2009 e 2024. Os estudos foram analisados conforme marcos temporais definidos, com o objetivo de identificar a evolução das aplicações, os contextos em que foram inseridas, os tipos de ferramentas utilizadas e os impactos observados. A discussão está estruturada em três fases: 2009–2014, 2015–2019 e 2020–2024, correspondentes, respectivamente, aos períodos de exploração inicial, expansão experimental e validação de modelos e consolidação e integração de sistemas inteligentes na viticultura.

5.1 – Primeiras aplicações exploratórias de IA na viticultura (2009–2014)

5.1.1 Introdução histórica: O caso Enologix (EUA, 2001)

Embora o uso da inteligência artificial (IA) na viticultura tenha se intensificado a partir da segunda década dos anos 2000, experiências pioneiras já apontavam, no início do século XXI, para o potencial disruptivo da aplicação de métodos computacionais na produção de vinhos. Um dos casos mais emblemáticos foi o da empresa norte-americana Enologix, fundada por Leo McCloskey na Califórnia. Seu trabalho destacou-se por propor uma abordagem científica e baseada em dados para avaliação e predição da qualidade dos vinhos, articulando análises químicas, modelos estatísticos e algoritmos preditivos.

De acordo com reportagem publicada na revista *Wired*, McCloskey desenvolveu um banco de dados com perfis químicos detalhados de centenas de rótulos que obtiveram altas pontuações por críticos renomados, como Robert Parker. Com base nesses dados, elaborou algoritmos capazes de correlacionar compostos químicos específicos com atributos sensoriais valorizados no mercado (NEUMAN, 2001).

Assim, passou a oferecer aos viticultores uma ferramenta analítica que simulava a performance sensorial de um vinho ainda em desenvolvimento, orientando decisões desde o manejo do vinhedo até o corte final para engarrafamento.

A metodologia fundamentava-se na identificação de 84 compostos-chave relacionados ao sabor, aroma, estrutura e cor dos vinhos. Com o suporte de softwares especializados, era possível decompor vinhos armazenados em diferentes barris e realizar simulações digitais para alcançar misturas otimizadas, com alto potencial de aceitação crítica e comercial. Em um dos episódios mais notórios descritos pela revista, McCloskey foi capaz de prever com precisão os resultados de uma degustação às cegas utilizando exclusivamente dados químicos um feito que reforçou a credibilidade de sua abordagem.

Essa experiência pioneira representou um marco na transição da viticultura empírica para uma viticultura orientada por dados, sinalizando o papel emergente da inteligência artificial como catalisadora de inovação no setor. A proposta de McCloskey antecipou diversas tendências que hoje caracterizam a viticultura de precisão, incluindo o uso de sensores, modelagem preditiva, visão computacional e sistemas inteligentes de apoio à decisão.

5.1.2 Panorama global (2009–2014)

Entre 2009 e 2014, a viticultura passou por uma transição do manejo predominantemente empírico para uma abordagem digital e orientada por dados, marcada pela introdução de sensores, algoritmos de aprendizado de máquina, visão computacional e técnicas de análise multivariada. Esse período representou a consolidação inicial da IA como ferramenta aplicada à viticultura de precisão, abrangendo desde a previsão climática até o controle de qualidade e a automação agrícola.

2009: Na Nova Zelândia, Sallis et al. (2009) aplicaram redes neurais supervisionadas e não supervisionadas para prever a ocorrência de geadas em vinhedos, destacando o papel da IA como ferramenta de adaptação climática em regiões vitícolas suscetíveis a eventos extremos. Em Portugal, Cortez et al. (2009) utilizaram técnicas de mineração de dados e máquinas de vetor de suporte (SVM)

para prever preferências sensoriais de vinhos a partir de variáveis físico-químicas, aproximando a análise computacional da enologia aplicada ao consumidor. Na Alemanha, Hall e Louis (2009) desenvolveram o algoritmo *VineClipper*, projetado para corrigir imprecisões de GPS em imagens aéreas, permitindo estimativas mais precisas da composição do dossel e melhorando a acurácia do mapeamento de vinhedos. Já na Itália, Morari et al. (2009) demonstraram como sensores geoeletricos, combinados à lógica fuzzy e à estatística multivariada, poderiam identificar zonas de manejo em solos pedregosos, oferecendo suporte direto à agricultura de precisão. Na Austrália, Berna et al. (2009) aplicaram espectrometria de massas associada a narizes eletrônicos baseados em óxidos metálicos para prever a origem geográfica de vinhos *Sauvignon Blanc* com alta acurácia, contribuindo para a rastreabilidade e autenticidade de produtos vitivinícolas. Por fim, Mateo et al. (2009), na Espanha, exploraram redes neurais *Multilayer Perceptron* (MLP) e funções de base radial (RBF) para prever a concentração de ocratoxina A em sucos de uva contaminados por *Aspergillus carbonarius*, sob diferentes condições ambientais e de manejo. O estudo destacou o papel da IA também na segurança alimentar e no controle de micotoxinas, ampliando o escopo de aplicação para além da viticultura de precisão.

2010–2011: O biênio seguinte consolidou aplicações de maior sofisticação em visão computacional, espectroscopia e biotecnologia. Em Israel, Berenstein et al. (2010) desenvolveram quatro algoritmos de visão computacional para pulverização seletiva em vinhedos, atingindo 90% de precisão na detecção de cachos e reduzindo em até 30% o uso de pesticidas. Na África do Sul, Vaudour et al. (2010) realizaram o mapeamento digital de *terroirs* em Stellenbosch com árvores de decisão e imagens SPOT multitemporais, alcançando 78% de acurácia na classificação de zonas homogêneas de *Sauvignon Blanc*. Na Espanha, Gago, Landín e Gallego (2010) aplicaram redes neurais artificiais para modelar a rizogênese *in vitro* e a aclimação de cultivares *Albariño* e *Mencía*, demonstrando o potencial da IA para otimizar processos de biotecnologia vegetal. Em paralelo, Qin et al. (2010), na China, construíram modelos não lineares para estimar antocianinas em folhas de videira a partir de dados hiperespectrais, avançando no monitoramento não destrutivo de parâmetros fisiológicos. Na França, Decourselle et al. (2010) empregaram visão

computacional integrada à computação em nuvem para caracterizar a rugosidade foliar, com foco na otimização da pulverização de precisão. Ainda na Espanha, Astray et al. (2010) exploraram redes neurais artificiais para autenticação de vinhos, ampliando as possibilidades da IA no controle de qualidade enológica. Em 2011, os avanços se diversificaram. Nos Estados Unidos, Nuske et al. (2011) integraram visão computacional e robótica embarcada em veículos autônomos para estimar a produtividade de vinhedos por meio da contagem visual de bagos, atingindo margens de erro inferiores a 10% em relação ao peso real da colheita. Na Espanha, Fernández-Martínez et al. (2011) aplicaram métodos de seleção de atributos (*wrapper methods*) para identificar variáveis ambientais determinantes na maturação da uva, reduzindo significativamente os erros em modelos preditivos. Já na China, Li, Ma e Wang (2011) desenvolveram sistemas de reconhecimento de imagens baseados em SVM para diagnosticar míldio e oídio, obtendo taxas de acerto superiores a 90%, o que representou um marco no monitoramento automatizado de doenças. Na Itália, Versari et al. (2011) aplicaram espectroscopia no infravermelho associada à regressão para prever a estabilidade coloidal em vinhos brancos, alcançando R^2 de até 0,85 em amostras de *Chardonnay*.

2012–2014: A partir de 2012, houve uma expansão significativa das pesquisas em diferentes países, com ênfase em visão computacional, aprendizado de máquina e sensoriamento remoto. Em Portugal, Reis et al. (2012) desenvolveram um sistema de visão computacional para detecção automática de cachos em imagens naturais, obtendo acurácia de 97% em uvas tintas e 91% em brancas. Na Argentina, Bromberg e Pérez (2012) aplicaram algoritmos SVM e LSVM para interpolação espacial de variáveis vitícolas em Mendoza, superando os métodos tradicionais de krigagem e IDW. No mesmo ano, Pérez e Bromberg (2012) testaram técnicas de segmentação de imagens para medir automaticamente o diâmetro de troncos de videiras em campo, utilizando algoritmos como *K-means*, *Gaussian Mixture* e SVM. Na Espanha, Tardáguila et al. (2012) consolidaram o uso da visão computacional em análises fenotípicas, avaliando características da copa, morfologia de cachos e tamanho de bagas com maior objetividade e escalabilidade. Na França, Coulon et al. (2012) desenvolveram sistemas de inferência fuzzy para previsão de vigor e precocidade da videira, criando indicadores quantitativos para manejo adaptativo. Na

Itália, Menesatti et al. (2013) apresentaram um modelo multivariado que reduziu em quase 50% o uso de fungicidas à base de cobre contra o míldio, contribuindo para a viticultura orgânica e sustentável. Na Romênia, Hosu, Cristea e Cimpoiu (2014) utilizaram redes neurais para prever propriedades antioxidantes de vinhos tintos, além de classificar vinhos por safra e vinícola. Na Austrália, Song et al. (2014) aplicaram imagens aéreas e índices no infravermelho próximo (NIR) para classificar zonas de vigor de *Pinot Noir*, correlacionando vigor com rendimento, acidez e compostos aromáticos. Já na Itália, Oberti et al. (2014) empregaram imagens multiespectrais para detecção precoce do oídio, mostrando que ângulos de visão entre 40° e 60° aumentavam a sensibilidade do diagnóstico. Por fim, na Galícia (Espanha), Gómez-Meire et al. (2014) aplicaram técnicas de aprendizado de máquina para autenticação de vinhos brancos autóctones, com a Floresta Aleatória alcançando classificação perfeita, consolidando o uso da IA no controle de origem e qualidade.

5.1.3 Comparativo entre estudos (2009-2014)

Os estudos analisados entre 2009 e 2014 apresentam diferenças marcantes em termos de tecnologia empregada, objetivos investigativos e nível de maturidade das soluções propostas.

Tecnologia: As pesquisas variaram entre o uso de redes neurais artificiais (Cortez et al., 2009; Astray et al., 2010; Hosu; Cristea; Cimpoiu, 2014), máquinas de vetor de suporte (Li; Ma; Wang, 2011; Bromberg; Pérez, 2012), visão computacional (Berenstein et al., 2010; Nuske et al., 2011; Reis et al., 2012; Tardáguila et al., 2012; Oberti et al., 2014), modelos fuzzy e multivariados (Morari et al., 2009; Coulon et al., 2012; Menesatti et al., 2013), bem como aplicações de espectroscopia e sensores hiperespectrais (Qin et al., 2010; Versari et al., 2011; Song et al., 2014).

Objetivo: As finalidades abrangeram desde a previsão climática e fisiológica (Sallis et al., 2009; Vaudour et al., 2010), diagnóstico fitossanitário (Li; Ma; Wang, 2011; Oberti et al., 2014), controle de qualidade enológica (Astray et al., 2010; Gómez-Meire et al., 2014), classificação de zonas de manejo e vigor (Morari et al.,

2009; Song et al., 2014) até a otimização de defensivos agrícolas (Berenstein et al., 2010; Menesatti et al., 2013).

Maturidade: A maioria dos estudos desse período manteve caráter experimental e exploratório, testando algoritmos em bases de dados limitadas ou em condições controladas de campo e laboratório. Apenas alguns como Berenstein et al. (2010); Menesatti et al. (2013) apresentaram estimativas concretas de impacto no manejo, sugerindo uma transição para soluções aplicáveis em escala produtiva.

Em síntese, o período de 2009 a 2014 correspondeu à fase exploratória da inteligência artificial na viticultura, caracterizada pela experimentação de técnicas diversas em contextos limitados, que estabeleceram as bases conceituais e metodológicas para os avanços subsequentes.

5.1.4 Implicações práticas, teóricas e setoriais (2009-2014)

Práticas: Redução do uso de defensivos agrícolas (Berenstein et al., 2010; Menesatti et al., 2013), maior precisão no manejo diferenciado do vinhedo (Morari et al., 2009; Song et al., 2014), diagnóstico precoce de doenças (Li; Ma; Wang, 2011; Oberti et al., 2014) e melhoria da produtividade com menor custo de insumos.

Teóricas: Consolidação do uso de algoritmos de aprendizado de máquina como instrumentos de modelagem em viticultura; integração de dados multiespectrais, químicos e climáticos; e avanço da visão computacional aplicada a ambientes complexos como vinhedos.

Setoriais: As pesquisas sinalizaram caminhos para a viticultura de precisão, fortalecendo a relação entre ciência da computação, engenharia agrícola e enologia. Também anteciparam a relevância da IA na rastreabilidade e certificação de vinhos, especialmente no contexto europeu (Astray et al., 2010; Gómez-Meire et al., 2014).

5.1.5 Lacunas identificadas (2009-2014)

Apesar dos avanços, algumas lacunas persistiram nesse período inicial:

- **Escalabilidade limitada:** muitos modelos foram validados apenas em pequena escala, sem comprovação em vinhedos comerciais de grande porte.
- **Dependência de dados locais:** algoritmos eram fortemente ajustados a variedades específicas, reduzindo a generalização para outros contextos.
- **Integração tecnológica:** os estudos ainda tratavam isoladamente visão computacional, espectroscopia e sensoriamento remoto, sem sistemas integrados de apoio à decisão.

5.2 – Expansão experimental e validação de modelos (2015–2019)

O período de 2015 a 2019 marcou uma etapa decisiva para a consolidação das aplicações de inteligência artificial (IA) na viticultura. Após a fase exploratória entre 2009 e 2014 — quando os modelos preditivos e sistemas de visão computacional ainda eram majoritariamente experimentais —, observa-se neste intervalo uma transição para abordagens mais robustas e validadas empiricamente.

Os algoritmos tornaram-se mais sofisticados, incorporando aprendizado profundo, modelagem fuzzy, mineração de dados e integração com redes de sensores IoT. A viticultura de precisão passou a se apoiar na combinação entre sensoriamento remoto, análise espectral e modelagem estatística inteligente, abrindo espaço para a automatização de tarefas e para a tomada de decisão em tempo real tanto no campo quanto na vinificação.

5.2.1 Panorama Global (2015–2019)

2015: A expansão das abordagens probabilísticas e de modelagem fuzzy foi uma tendência marcante. Baudrit et al. (2015), na França, desenvolveram um modelo gráfico probabilístico para descrever a maturação da baga, integrando variáveis químicas e fisiológicas. O estudo representou um avanço ao permitir a quantificação da incerteza nos estágios de maturidade, contribuindo para um manejo mais preciso do ponto de colheita. Na Grécia, Peter Groumpos (2015) propôs um modelo matemático inovador baseado em mapas cognitivos fuzzy para o gerenciamento

integrado da viticultura e da vinificação. Essa abordagem ampliou o entendimento sistêmico das interações entre fatores climáticos, agronômicos e tecnológicos, destacando o potencial das redes cognitivas na modelagem de processos agrícolas complexos. Em um contexto mais aplicado, Portalés e Ribes-Gómez (2015), na Espanha, desenvolveram um sistema de avaliação de qualidade de uvas baseado em imagens, voltado à triagem das cargas no momento da recepção nas vinícolas. O método automatizava a inspeção visual por meio de análise computacional de cor, textura e forma, antecipando o uso da visão computacional em escala industrial para controle de qualidade.

2016–2017: Nos anos seguintes, o foco deslocou-se para o campo, com o fortalecimento de estudos que integraram visão computacional, espectroscopia e aprendizado de máquina em condições reais de cultivo. Gutiérrez et al. (2016), na Espanha, demonstraram o uso combinado de mineração de dados e espectroscopia no infravermelho próximo (NIR) para fenotipagem de plantas sob condições de campo, abrindo caminho para o monitoramento não destrutivo do vigor e do estado fisiológico da videira. Na China, Hou, Li e He (2016) desenvolveram um modelo baseado em índices espectrais e no algoritmo de colônia de formigas para detectar a doença do enrolamento da folha da videira. O método combinou 11 índices espectrais com técnicas de clusterização inteligente, demonstrando alta precisão na identificação precoce de sintomas. Millan et al. (2016), na Espanha, aplicaram análise de imagens para modelar a contagem de flores na videira, obtendo correlações consistentes com o rendimento final. Em paralelo, Orlando et al. (2016), na Itália, validaram o uso do aplicativo PocketLAI para estimar o índice de área foliar (LAI) em vinhedos, destacando o potencial de soluções móveis e acessíveis para viticultores. O ano de 2017 consolidou o uso de robótica e automação. Lopes et al. (2017), em Portugal, apresentaram o VINBOT, um robô terrestre projetado para viticultura de precisão, equipado com sensores ópticos e câmeras de alta resolução. O sistema demonstrou eficiência em tarefas de monitoramento autônomo e coleta de dados agronômicos. Ang, Seng e Ge (2017), em Cingapura, exploraram algoritmos bioinspirados de visão computacional, desenvolvendo modelos de reconhecimento visual baseados em comportamentos naturais aplicados à viticultura — uma incorporação pioneira de paradigmas de inteligência natural nas tarefas de

percepção agrícola. Aquino et al. (2017) iniciaram estudos de previsão antecipada de produtividade com base em imagens adquiridas em campo, representando um avanço para o planejamento logístico e o manejo adaptativo de vinhedos. Por fim, no Brasil, Dos Santos et al. (2017, publicado em 2020) testaram métodos de aprendizado de máquina para detecção automática de frutos em campo, evidenciando o amadurecimento da pesquisa nacional em viticultura tropical e de pequeno porte.

2018–2019: O biênio final dessa fase trouxe uma intensificação da integração entre IoT, aprendizado profundo e modelagem de decisão automatizada.

Belkaroui et al. (2018), na Tunísia, propuseram uma ontologia de eventos para viticultura baseada em redes de sensores, estruturando semanticamente dados provenientes de múltiplas fontes para apoiar o raciocínio automatizado sobre o estado do vinhedo. Loggenberg et al. (2018), na África do Sul, desenvolveram um modelo de detecção de estresse hídrico em uvas Shiraz por meio de imagens hiperespectrais e aprendizado de máquina, reforçando a capacidade da IA em interpretar respostas fisiológicas de plantas a condições ambientais. Yagoubi et al. (2018), na França, introduziram um modelo baseado em verificação formal (model checking) para resolver o problema da colheita diferencial, contribuindo para decisões mais eficientes de colheita seletiva. O ano de 2019 caracterizou-se pela diversificação das aplicações e pela expansão para plataformas colaborativas e sistemas embarcados. Mylonas, Voutos e Sofou (2019), na Grécia, apresentaram uma plataforma colaborativa para anotação e enriquecimento de dados vitícolas, reforçando o papel da curadoria de dados no aprendizado supervisionado. Santos et al. (2019), em Portugal, aplicaram aprendizado de máquina para segmentação de vinhedos em imagens de satélite, enquanto Marques et al. (2019) classificaram variedades de uva por meio de aprendizado supervisionado. Ainda em Portugal, Silva et al. (2019) apresentaram soluções IoT de baixo custo com LoRa® para monitoramento de vinhedos, ampliando a conectividade rural. Fuentes et al. (2019), na Austrália, desenvolveram um modelo de detecção não invasiva de contaminação por fumaça em dosséis e bagas, unindo sensoriamento remoto e modelagem preditiva. Magalhães et al. (2019) avaliaram algoritmos de planejamento de trajetórias para poda e monitoramento com robôs autônomos, enquanto Martins et

al. (2019) apresentaram os MetBots, robôs integrados a análises metabolômicas para viticultura de precisão. Outros avanços se destacaram globalmente: Chu et al. (2019), na China, desenvolveram um modelo híbrido otimizado de IA para previsão de preços de uvas, conectando dados de mercado à produção; Silver e Monga (2019), no Canadá, utilizaram deep learning para estimar produtividade a partir de imagens de vinhedos, com acurácia superior às abordagens tradicionais; e Maia (2019), em Portugal, aplicou análise de imagem para estimativa de produção da casta Syrah, reforçando o alinhamento entre pesquisa acadêmica e aplicação prática. Ainda nesse contexto, Bento, da Cunha e Barata (2019) analisaram o papel transformador da Agricultura 4.0 sob uma perspectiva sociotécnica, destacando como a introdução de tecnologias inteligentes na viticultura reconfigura práticas e interações entre humanos e máquinas.

5.2.2 Comparativo entre estudos (2015–2019)

Os estudos realizados entre 2015 e 2019 revelam um amadurecimento significativo na aplicação de IA à viticultura, com diferenças marcantes em relação à tecnologia, objetivos investigativos e maturidade das soluções.

Tecnologia: As pesquisas evoluíram do uso de modelos probabilísticos e sistemas fuzzy (Baudrit et al., 2015; Peter Groumos, 2015) para abordagens híbridas orientadas por dados e integradas à visão computacional. Houve crescente incorporação de sensores ópticos e espectrais, além do uso de sistemas móveis e plataformas embarcadas (Millan et al., 2016; Lopes et al., 2017). A partir de 2018, destacou-se o emprego de aprendizado profundo e a convergência entre IA, Internet das Coisas (IoT) e sensoriamento remoto (Fuentes et al., 2019; Silva et al., 2019).

Objetivo: As finalidades principais concentraram-se em três eixos: (1) modelagem e predição de variáveis vitícolas e enológicas, incluindo maturação e rendimento; (2) automação da detecção e classificação de doenças e parâmetros de qualidade; e (3) integração de dados multiespectrais e climáticos para aprimorar o manejo do vinhedo. A análise de imagens e o sensoriamento emergiram como ferramentas centrais para diagnóstico e controle do ciclo produtivo.

Maturidade: O período marca a transição entre experimentos laboratoriais e validações em campo real. Modelos passaram a ser testados em vinhedos comerciais e a utilizar bancos de dados ampliados. O avanço das arquiteturas de deep learning e o aumento da capacidade computacional favoreceram o desenvolvimento de protótipos operacionais e aplicações práticas, com início da validação econômica e agrônômica das soluções.

Assim, entre 2015 e 2019, observa-se o amadurecimento técnico e científico das aplicações de IA na viticultura, com a consolidação de modelos validados em campo e o início da integração entre sensores, visão computacional e aprendizado de máquina, preparando o terreno para a era dos sistemas inteligentes integrados.

5.2.3 Implicações práticas, teóricas e setoriais (2015-2019)

Práticas: As aplicações de IA possibilitaram maior eficiência no monitoramento do vinhedo, redução de erros humanos e melhoria no controle de doenças e irrigação. Sistemas embarcados e sensores conectados à IoT permitiram a coleta contínua de dados, favorecendo o manejo adaptativo e a previsão antecipada de produtividade.

Teóricas: As pesquisas reforçaram a integração interdisciplinar entre IA, agronomia e ciência dos dados, expandindo o uso de redes neurais, visão computacional e sistemas fuzzy em ambientes agrícolas complexos. Também se destacaram os primeiros esforços de integração entre modelos de aprendizado de máquina e redes sensoriais distribuídas.

Setoriais: O conjunto de estudos consolidou as bases da viticultura inteligente, aproximando o setor produtivo de soluções digitais aplicadas ao campo. A expansão da IA trouxe impactos positivos sobre sustentabilidade, rastreabilidade e controle de qualidade, ao mesmo tempo em que abriu espaço para políticas de inovação e transformação tecnológica nas cadeias produtivas de vinho.

5.2.4 Lacunas identificadas (2015-2019)

Apesar do progresso observado, algumas limitações permaneceram evidentes no período:

- **Escalabilidade restrita:** a maioria dos modelos continuou sendo testada em áreas experimentais, com poucos casos de aplicação em escala comercial.
- **Padronização insuficiente:** a ausência de protocolos comuns para aquisição e anotação de dados limitou a comparação entre métodos e regiões.
- **Interoperabilidade tecnológica:** a integração entre sensores, drones, estações climáticas e softwares de IA ainda era fragmentada.
- **Generalização dos modelos:** muitos algoritmos mostraram dependência de variáveis locais, comprometendo a adaptação a diferentes terroirs.
- **Adoção regional desigual:** embora Europa e América do Norte tenham avançado em aplicações práticas, no Brasil e em países latino-americanos o uso permaneceu concentrado em estudos de caso e experimentos piloto.

5.3 Consolidação e integração de sistemas inteligentes (2020–2024)

O período de 2020 a 2024 representa a consolidação da inteligência artificial na viticultura, marcada pelo amadurecimento das soluções desenvolvidas nas fases anteriores e pela integração de múltiplas tecnologias — incluindo aprendizado profundo, fusão multimodal de dados, sensoriamento remoto de alta resolução, Internet das Coisas (IoT) e modelagem preditiva em larga escala.

Essa etapa assinala a transição das aplicações experimentais para sistemas integrados de apoio à decisão, com foco na interoperabilidade entre sensores, modelos e plataformas digitais.

As pesquisas passaram a priorizar a fusão entre dados de campo, imagens aéreas, informações climáticas e registros agronômicos, visando não apenas o monitoramento e a previsão, mas também a automação de processos, a rastreabilidade produtiva e a sustentabilidade ambiental.

O ciclo 2020–2024 pode, portanto, ser compreendido como a fase de maturidade científica e tecnológica da viticultura inteligente, na qual a IA deixa de ser um

experimento isolado e torna-se componente estrutural do ecossistema agrícola digital.

5.3.1 Panorama Global (2020–2024)

2020: O ano de 2020 foi marcado pela expansão do uso de redes neurais profundas e pela popularização de sensores multiespectrais. Na França, Kerkech, Hafiane e Canals (2020) desenvolveram a *VddNet*, uma rede convolucional especializada na detecção de doenças da videira a partir de imagens multiespectrais e mapas de profundidade, obtendo alta robustez mesmo sob variações de iluminação. Nos Estados Unidos, Silver e Nasa (2020) aprimoraram modelos de previsão de rendimento com base em múltiplas imagens do vinhedo, utilizando *deep learning* para estimar o número de cachos ainda na planta, reforçando o potencial da IA na estimativa não invasiva de produtividade. Na Espanha, Santos et al. (2020) introduziram um sistema tridimensional de detecção, segmentação e rastreamento de uvas, combinando redes neurais convolucionais com associação temporal de objetos — obtendo desempenho superior às abordagens bidimensionais. Na Alemanha, Zabawa et al. (2020) aplicaram segmentação semântica com CNNs para contagem automática de bagas, contribuindo para o avanço da fenotipagem automatizada. No Brasil, Bischoff e Farias (2020) apresentaram o sistema *VitForecast*, baseado em IoT para previsão de doenças em vinhedos, integrando sensores ambientais, redes sem fio e modelos preditivos. Ainda em 2020, Jesus (2020), em Portugal, desenvolveu o sistema *PhenoEngine*, que integrou dados de satélite e variáveis climáticas para modelar a fenologia da videira, consolidando a aplicação de detecção remota em modelagem fenológica.

2021–2022: Em 2021, a atenção voltou-se à análise de grandes volumes de dados e à consolidação teórica. No Canadá, Newlands (2021) publicou uma revisão abrangente sobre o uso de IA e Big Data na viticultura, destacando desafios como interoperabilidade e gestão de dados massivos. No Brasil, Arnecke (2021) aplicou modelos de previsão de séries temporais para estimar a demanda de vinhos na Serra Gaúcha, expandindo a aplicação da IA para o âmbito econômico da cadeia vitivinícola. Em 2022, intensificou-se a integração multimodal e o uso de imagens de

drones e satélites. Na Alemanha, Kierdorf et al. (2022) utilizaram redes generativas adversariais condicionais (cGANs) para estimar bagas ocultas por folhas, superando limitações visuais no monitoramento de cachos. Em Portugal, Barros et al. (2022) compararam modelos de segmentação multiespectral por *deep learning*, identificando as arquiteturas mais eficazes para o mapeamento de vinhedos. No Brasil, Oliveira (2022) desenvolveu um sistema automatizado de irrigação da videira no semiárido, demonstrando como a IA pode otimizar o uso de água em regiões de escassez hídrica. Na Suíça, Olenskyj et al. (2022) aplicaram redes neurais convolucionais end-to-end para estimar a produtividade diretamente a partir de imagens terrestres, eliminando etapas intermediárias. Em Portugal, Barriguinha et al. (2022) integraram NDVI, dados climáticos e aprendizado de máquina para prever a produtividade no Douro, alcançando elevada acurácia. López-García et al. (2022) aplicaram *machine learning* a imagens multiespectrais e RGB de drones para monitorar o estado hídrico das videiras ao longo do tempo. Na Itália, Pagliai et al. (2022) compararam nuvens de pontos 3D aéreas e terrestres para avaliar o tamanho da copa, reforçando a importância da modelagem tridimensional em viticultura de precisão.

2023–2024: Entre 2023 e 2024, a IA consolidou-se como eixo central da viticultura digital, destacando-se pelo uso de modelos de previsão antecipada de produtividade, integração multimodal de dados e aplicações em processos enológicos e comerciais. Em 2023, Palacios et al. (2023), na Espanha, desenvolveram um sistema de visão computacional para predição antecipada de produtividade em diferentes variedades de uvas. No Brasil, Andrade et al. (2023) compararam algoritmos de *machine learning* — como Random Forest, SVM e redes neurais — para estimativa de rendimento, demonstrando a eficácia das abordagens híbridas. Na Grécia, Badeka et al. (2023) aplicaram a arquitetura YOLOv7 para avaliação automática da maturação das uvas, demonstrando o potencial dos detectores em tempo real na fenotipagem digital. Na França, De la Fuente et al. (2023) combinaram imagens de satélite e aprendizado de máquina para estimar a produtividade em larga escala. Nesse mesmo período, surgiram as primeiras experiências de vinificação orientada por IA, aplicadas à análise química e definição de perfis sensoriais, conforme relatado pelo portal Wine-Searcher (2023) —

marcando a transição entre o uso experimental e a aplicação industrial da IA. Em 2024, observa-se a convergência plena entre dados multiespectrais, climáticos e de manejo. Kamangir et al. (2024) propuseram o modelo Climate-Management Aware Vision Transformer (CMAViT), uma arquitetura multimodal de *deep learning* que combina imagens de sensoriamento remoto, dados meteorológicos e de manejo agrícola, alcançando precisão superior à de modelos convencionais. Rafique et al. (2024), no Sul da Ásia, adaptaram o modelo STICS com técnicas de IA para simular a fenologia e o rendimento de uvas de mesa, ampliando o alcance da tecnologia a novas zonas vitícolas. Na Itália, Dimitri e Trambusti (2024) aplicaram *machine learning* para relacionar condições climáticas e qualidade do vinho, demonstrando a capacidade da IA de capturar interações complexas entre ambiente e produto. No Brasil, Pereira et al. (2024) exploraram a viticultura e enologia de precisão, destacando parâmetros químicos e fenológicos como fatores determinantes na valorização de vinhos com tipicidades distintas. Em Portugal, Madeira (2024) utilizou *machine learning* para diagnóstico da saúde das plantas, e na Índia, Barbole e Jadhav (2024) compararam modelos bidimensionais e tridimensionais de previsão de rendimento, evidenciando ganhos com imagens 3D. Gatou et al. (2024) realizaram uma revisão sistemática sobre IA na viticultura, abordando bases de dados, doenças e métricas de desempenho. Na África do Sul, Jewan et al. (2024) combinaram dados hiperespectrais, térmicos e de solo para aprimorar a previsão de rendimento e a estimativa da composição das bagas. Em complemento, Loggenberg, Strever e Münch (2024) revisaram os avanços recentes em sensoriamento óptico aplicado à viticultura, e Saraceni et al. (2024) exploraram métodos de geração de dados auto-supervisionados, mesclando ambientes simulados e imagens reais. Gavrilović et al. (2024), por sua vez, aplicaram o algoritmo YOLO e o método K-means clustering a imagens de drones, obtendo 90% de acurácia na detecção automática de videiras e zoneamento de vinhedos com base em índices de vegetação. No contexto latino-americano, Ray (2024) destacou o papel da IA na viticultura argentina, especialmente entre pequenos produtores que passaram a adotar plataformas inteligentes como o Agrobot, desenvolvido em parceria com a Microsoft, para otimização de insumos e rastreabilidade produtiva.

Segundo o Estadão (2024), essa integração tecnológica também se expandiu para outros países, com uso de sensores, algoritmos de irrigação automatizada e

softwares analíticos aplicados à formulação de vinhos com perfis sensoriais otimizados. Ainda em 2024, o projeto Wine of Moldova (2024) apresentou, na feira ProWein, os primeiros vinhos do mundo desenvolvidos com apoio de um sistema de IA o Chelaris Bot marco simbólico da enologia digital. Por fim, Stefenon e Martins (2024) discutiram o conceito de “terroir digital”, refletindo sobre a integração entre tradição e inovação algorítmica na viticultura 4.0.

5.3.2 Comparativo entre estudos (2020–2024)

Os estudos de 2020 a 2024 consolidaram a IA como núcleo estruturante da viticultura digital, apresentando diferenças quanto às tecnologias, objetivos e níveis de maturidade:

Tecnologia: O uso de deep learning, sensores multiespectrais e visão computacional tornou-se predominante (Kerkech et al., 2020; Santos et al., 2020). A partir de 2022, os estudos passaram a incorporar análises tridimensionais, redes generativas e fusão multimodal de dados provenientes de satélites, drones e sensores terrestres (Pagliai et al., 2022; Olenskyj et al., 2022).

Entre 2023 e 2024, avançaram as arquiteturas multimodais e auto-supervisionadas, como *vision transformers* e modelos híbridos (Kamangir et al., 2024; Jewan et al., 2024).

Objetivo: As pesquisas passaram a abranger toda a cadeia vitivinícola, desde o campo até a vinificação, incluindo previsão de produtividade, monitoramento fenológico, fermentação e formulação de vinhos (Wine-Searcher, 2023; Wine of Moldova, 2024).

Maturidade: O período é caracterizado por soluções escaláveis e interoperáveis, capazes de operar em tempo real e integrar múltiplas fontes de dados. A IA consolidou-se como componente central dos sistemas de decisão autônomos, integrando-se a plataformas comerciais e políticas públicas de inovação rural.

De modo geral, o período de 2020 a 2024 representa a consolidação plena da viticultura inteligente, em que a inteligência artificial passou de ferramenta experimental a elemento estruturante de um ecossistema digital agrícola, marcando a transição para a Agricultura 5.0.

5.3.3 Implicações práticas, teóricas e setoriais (2020-2024)

Práticas: A IA ampliou o monitoramento remoto de variáveis ambientais, a previsão de produtividade e a automação de processos agrícolas e enológicos. O uso de dados multiespectrais e climáticos permitiu decisões mais rápidas, precisas e sustentáveis.

Teóricas: O período consolidou o paradigma da agricultura cognitiva, em que *deep learning* e fusão de dados se combinam à teoria agrônômica e à modelagem fenológica. O conceito de terroir digital emergiu para descrever a convergência entre variabilidade ambiental, dados e identidade produtiva.

Setoriais: As pesquisas impulsionaram a transição para a Agricultura 5.0, marcada pela integração entre IA, robótica, IoT e análise preditiva. O setor vitivinícola passou a incorporar tecnologias digitais à gestão e comercialização, influenciando também o marketing e o posicionamento de mercado dos vinhos.

5.3.4 Lacunas identificadas (2020-2024)

Apesar dos avanços, persistem desafios significativos:

- **Reprodutibilidade:** Falta de padronização e documentação de *datasets* dificulta a validação independente dos modelos.
- **Interoperabilidade:** Muitos sistemas ainda não integram sensores, plataformas e modelos de diferentes fabricantes.
- **Cobertura geográfica:** A produção científica continua concentrada em regiões temperadas, com pouca representatividade de zonas tropicais e semiáridas.

- **Aspectos éticos e socioeconômicos:** Há escassez de estudos sobre os impactos da automação no trabalho humano e na sustentabilidade social.
- **Integração global:** Persiste a necessidade de bancos de dados colaborativos e modelos universais de fenotipagem e predição, capazes de abranger diferentes terroirs e escalas produtivas.

6 CONSIDERAÇÕES FINAIS

A presente pesquisa permitiu compreender a trajetória evolutiva da inteligência artificial (IA) na viticultura ao longo de três marcos temporais distintos (2009–2014, 2015–2019 e 2020–2024), revelando um processo contínuo de amadurecimento tecnológico, científico e setorial. A análise cronológica dos estudos demonstrou que a IA passou de experimentos isolados de previsão e classificação para sistemas integrados e inteligentes de apoio à decisão, configurando um novo paradigma para a viticultura de precisão e, posteriormente, para a viticultura inteligente.

Entre 2009 e 2014, observou-se uma fase exploratória, marcada pela aplicação inicial de algoritmos de aprendizado de máquina, visão computacional e modelos fuzzy em estudos de pequena escala. Países como Espanha, Itália, França e Portugal lideraram as pesquisas acadêmicas, enquanto Austrália e Estados Unidos apresentaram avanços aplicados em rastreabilidade e controle de qualidade. Essa etapa foi fundamental para consolidar as bases conceituais e metodológicas que permitiram a transição para o uso mais abrangente da IA no setor.

No período de 2015 a 2019, a IA na viticultura entrou em uma fase de expansão experimental e validação de modelos. As técnicas tornaram-se mais robustas e começaram a ser aplicadas em condições reais de campo, especialmente na Europa Mediterrânea (Portugal, Espanha, França, Itália e Grécia), onde predominam vinhedos com infraestrutura tecnológica e tradição científica consolidada. Observou-se o avanço da visão computacional, aprendizado profundo, sensoriamento remoto e integração com redes IoT, resultando em ganhos expressivos para o manejo agrícola e a sustentabilidade. No contexto latino-americano, países como Argentina e Brasil começaram a se inserir na agenda de pesquisa, ainda de forma pontual, porém demonstrando potencial de adaptação das tecnologias às condições locais.

Já entre 2020 e 2024, o cenário se consolidou em uma etapa de integração e maturidade. As soluções de IA tornaram-se componentes estruturais da viticultura digital, com sistemas interoperáveis, baseados em deep learning, fusão multimodal de dados, modelagem preditiva e automação completa. Destacam-se os avanços da

França, Espanha, Portugal e Itália no desenvolvimento de sistemas integrados, e o papel emergente de Brasil, África do Sul e Índia, que passaram a adaptar modelos de IA às condições tropicais e semiáridas. O conceito de “terroir digital” consolidou-se como símbolo da fusão entre tradição vitícola e inovação algorítmica. Além disso, a IA expandiu-se para toda a cadeia vitivinícola — do manejo da videira à vinificação e à comercialização — inaugurando a era da Agricultura 5.0, baseada em inteligência conectada, sustentabilidade e decisão autônoma.

Em síntese, os principais achados apontam que a IA tem se consolidado como elemento estratégico para o futuro da viticultura global, promovendo avanços em produtividade, rastreabilidade, qualidade e sustentabilidade ambiental. A literatura evidencia que a adoção mais intensa ocorre em países de tradição vitivinícola e alto investimento em pesquisa e desenvolvimento, enquanto regiões emergentes, como a América Latina, apresentam crescimento promissor, porém ainda limitado por questões de infraestrutura tecnológica, padronização de dados e acesso à inovação.

Este estudo contribui de forma particularmente significativa para o contexto da viticultura brasileira, especialmente a tropical e semiárida. Ao mapear o “estado da arte” global, esta revisão fornece um fundamento sólido para que pesquisadores e produtores locais possam direcionar esforços na adaptação e desenvolvimento de soluções de IA focadas nos desafios específicos do nosso terroir, como a gestão hídrica de precisão e a adaptação de modelos fenológicos a múltiplos ciclos anuais.

Como caminhos futuros, recomenda-se o avanço de pesquisas em quatro frentes principais:

- Adaptação de modelos a diferentes terroirs e condições climáticas, com ênfase em zonas tropicais e semiáridas;
- Desenvolvimento de bases de dados colaborativas e abertas, que favoreçam a interoperabilidade e a validação cruzada de algoritmos;
- Exploração de aspectos éticos, sociais e econômicos da automação na viticultura, incluindo seus impactos sobre o trabalho e a identidade produtiva;

- Integração entre IA, biotecnologia e sensoriamento avançado, voltada à previsão da qualidade do vinho desde o campo até o consumidor final.

Em conclusão, a inteligência artificial representa não apenas uma ferramenta tecnológica, mas uma nova linguagem da viticultura contemporânea — capaz de transformar a relação entre o produtor, o ambiente e o vinho. Seu avanço contínuo aponta para um futuro em que ciência de dados e tradição vitivinícola se entrelaçam na busca por eficiência, autenticidade e sustentabilidade no mundo do vinho.

REFERÊNCIAS

ANDRADE, Caio Bustani et al. Grape yield prediction models: Approaching different machine learning algorithms. *Horticulturae*, v.9, n.12, p. 1294, 2023.

ARNECKE, Thamiris Medeiros. Previsão de demanda aplicada a séries temporais da viticultura gaúcha. 2021.

Astray, Gonzalo et. al. Artificial neural networks: a promising tool to evaluate the authenticity of wine *redes neuronales: una herramienta prometedora para evaluar la autenticidad del vino*. *CyTA-Journal of Food*, v. 8, n.1, p.79-86, 2010.

AQUINO, Arturo et. al. Automated early yield prediction in vineyards from on-the-go image acquisition. *Computers and electronics in agriculture*, v. 144, p. 26-36, 2018.

ANG, Li Minn; SENG, Kah Phooi; GE, Feng Lu. Natural inspired intelligent visual computing and its application to viticulture. *Sensors*, v. 17, n. 6, p. 1186, 2017.

BADEKA, Eftichia et al. A deep learning approach for precision viticulture, assessing grape maturity via YOLOv7. *Sensors*, v. 23, n. 19, p. 8126, 2023.

BISCHOFF, Vinicius; FARIAS, Kleinner. VitForecast: an IoT approach to predict diseases in vineyard. In: *Proceedings of the XVI Brazilian Symposium on Information Systems*. 2020. p. 1-8.

BARRIGUINHA, André et al. Using NDVI, climate data and machine learning to estimate yield in the Douro wine region. *International Journal of Applied Earth Observation and Geoinformation*, v. 114, p. 103069, 2022.

BARROS, Tiago et al. Multispectral vineyard segmentation: A deep learning comparison study. *Computers and electronics in agriculture*, v. 195, p. 106782, 2022.

BRASIL DE VINHOS. Queda de consumo, diminuição de áreas de vinhedos e de produção: qual o futuro do vinho no mundo? [S. l.], 6 maio 2024. Disponível em: <<https://brasildevinhos.com.br/queda-de-consumo-diminuicao-de-areas-de-vinhedos-e-de-producao-qual-o-futuro-do-vinho-no-mundo/>>. Acesso em: 21 maio 2025.

BARBOLE, Dhanashree; JADHAV, Parul M. Comparative analysis of 2D and 3D vineyard yield prediction system using artificial intelligence. *Journal of Agricultural Engineering*, v. 55, n. 1, 2024.

BERNA, Amalia Z. et al. Geographical origin of Sauvignon Blanc wines predicted by mass spectrometry and metal oxide based electronic nose. *Analytica Chimica Acta*, v. 648, n. 2, p. 146-152, 2009.

BERENSTEIN, Ron et al. Grape clusters and foliage detection algorithms for autonomous selective vineyard sprayer. *Intelligent Service Robotics*, v. 3, n. 4, p. 233-243, 2010.

BROMBERG, Facundo; PÉREZ, D. S. Interpolación espacial mediante aprendizaje de máquinas en viñedos de la Provincia de Mendoza, Argentina. In: XIII Argentine Symposium on Artificial Intelligence (ASAI 2012)(XLI JAIIO, La Plata, 27 y 28 de agosto de 2012). 2012.

BAUDRIT, Cédric et al. A probabilistic graphical model for describing the grape berry maturity. *Computers and Electronics in Agriculture*, v. 118, p. 124-135, 2015.

BELKAROUI, Rami et al. Towards events ontology based on data sensors network for viticulture domain. In: Proceedings of the 8th International Conference on the Internet of Things. 2018. p. 1-7.

BENTO, Carlos; RUPINO DA CUNHA, Paulo; BARATA, João. Cultivating sociomaterial transformations in agriculture 4.0: The case of precision viticulture. In: Americas Conference on Information Systems. 2019.

CORTEZ, Paulo et al. Modeling wine preferences by data mining from physicochemical properties. *Decision support systems*, v. 47, n. 4, p. 547-553, 2009.

COULON-LEROY, Cécile et al. Prediction of vine vigor and precocity using data and knowledge-based fuzzy inference systems. *Oeno One*, v. 46, n. 3, p. 185-205, 2012.

CHU, Xiaoquan et al. An optimized hybrid model based on artificial intelligence for grape price forecasting. *British Food Journal*, v. 121, n. 12, p. 3247-3265, 2019.

DE LA FUENTE, David et al. Yield estimation using machine learning from satellite imagery. In: *BIO Web of Conferences*. EDP Sciences, 2023. p. 01013.

DIMITRI, Giovanna Maria; TRAMBUSTI, Alberto. Precision agriculture for wine production: A machine learning approach to link weather conditions and wine quality. *Heliyon*, v. 10, n. 11, 2024.

DECOURSELLE, Thomas et al. Vineyard leaf roughness characterization by computer vision and cloud computing technics. In: *International Conference on Agricultural Engineering-AgEng 2010*. 2010. p. 309.

DOS SANTOS, A. A. et al. Detecção de frutos em campo por aprendizado de máquina. 2020.

ESTADÃO. Inteligência artificial chega na produção de vinhos. São Paulo: Radar Paladar, 26 nov. 2024. Disponível em:

<https://www.estadao.com.br/paladar/radar/inteligencia-artificial-producao-vinhos/>.

Acesso em: 9 out. 2025.

FERNANDEZ-MARTINEZ, ROBERTO et al. Application of wrapper methods for feature selection in modelling ripening process of a viticulture crop. In: *10th WSEAS International Conference on Applied Computer and Applied Computational Science, ACACOS'11*. 2011. p. 142-147.

FUENTES, Sigfredo et al. Non-invasive tools to detect smoke contamination in grapevine canopies, berries and wine: A remote sensing and machine learning modeling approach. *Sensors*, v. 19, n. 15, p. 3335, 2019.

GATOU, Paraskevi et al. Artificial intelligence techniques in grapevine research: A comparative study with an extensive review of datasets, diseases, and techniques evaluation. *Sensors*, v. 24, n. 19, p. 6211, 2024.

GAVRILOVIĆ, Milan et al. Vineyard Zoning and Vine Detection Using Machine Learning in Unmanned Aerial Vehicle Imagery. *Remote Sensing*, v. 16, n. 3, p. 584, 2024.

GAGO, Jorge; LANDÍN, Mariana; GALLEGO, Pedro Pablo. Artificial neural networks modeling the in vitro rhizogenesis and acclimatization of *Vitis vinifera* L. *Journal of Plant Physiology*, v. 167, n. 15, p. 1226-1231, 2010.

GÓMEZ-MEIRE, S. et al. Assuring the authenticity of northwest Spain white wine varieties using machine learning techniques. *Food Research International*, v. 60, p. 230-240, 2014.

GUTIÉRREZ, Salvador et al. Data mining and NIR spectroscopy in viticulture: applications for plant phenotyping under field conditions. *Sensors*, v. 16, n. 2, p. 236, 2016.

HALL, Andrew; LOUIS, John. Vineclipper: a proximal search algorithm to tie GPS field locations to high resolution grapevine imagery. In: *Innovations in Remote Sensing and Photogrammetry*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009. p. 361-372.

HOSU, Anamaria; CRISTEA, Vasile-Mircea; CIMPOIU, Claudia. Analysis of total phenolic, flavonoids, anthocyanins and tannins content in Romanian red wines

Prediction of antioxidant activities and classification of wines using artificial neural networks. *Food chemistry*, v. 150, p. 113-118, 2014.

HOU, Jingwei; LI, Longtang; HE, Jie. Detection of grapevine leafroll disease based on 11-index imagery and ant colony clustering algorithm. *Precision Agriculture*, v. 17, n. 4, p. 488-505, 2016.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Uva: Produção agropecuária. Disponível em:

<<https://www.ibge.gov.br/explica/producao-agropecuaria/uva/br>. Acesso em: 19 maio 2025>.

INTERNATIONAL ORGANISATION OF VINE AND WINE. OIV Strategic Plan 2025–2029. [S.l.]: OIV, 2024. Disponível em:

<https://www.oiv.int/sites/default/files/documents/EN_OIV_Strategic_Plan_2025-2029_0.pdf>. Acesso em: 28 maio 2025

JEWAN, Shaikh Yassir Yousouf et al. Integrating Hyperspectral, Thermal, and Ground Data with Machine Learning Algorithms Enhances the Prediction of Grapevine Yield and Berry Composition. *Remote Sensing*, v. 16, n. 23, p. 4539, 2024.

JESUS, Jorge Diogo. Modelação da Fenologia da Vinha a Partir de Técnicas de Deteção Remota-Phenoengine. 2020. Dissertação de Mestrado. Universidade do Porto (Portugal).

KAMANGIR, Hamid et al. Cnavit: Integrating climate, management, and remote sensing data for crop yield estimation with multimodel vision transformers. arXiv preprint arXiv:2411.16989, 2024.

KIERDORF, Jana et al. Behind the leaves: Estimation of occluded grapevine berries with conditional generative adversarial networks. *Frontiers in artificial intelligence*, v. 5, p. 830026, 2022.

KERKECH, Mohamed; HAFIANE, Adel; CANALS, Raphael. VddNet: Vine disease detection network based on multispectral images and depth map. *Remote Sensing*, v. 12, n. 20, p. 3305, 2020.

LIAKOS, Konstantinos G. et al. Machine learning in agriculture: a review. *Sensors*, v. 18, n. 8, p. 2674, 2018.

LOGGENBERG, Kyle; STREVER, Albert; MÜNCH, Zahn. Scoping the Field: Recent Advances in Optical Remote Sensing for Precision Viticulture. *ISPRS International Journal of Geo-Information*, v. 13, n. 11, p. 385, 2024.

LÓPEZ-GARCÍA, Patricia et al. Machine learning-based processing of multispectral and RGB UAV imagery for the multitemporal monitoring of vineyard water status. *Agronomy*, v. 12, n. 9, p. 2122, 2022.

LI, Guanlin; MA, Zhanhong; WANG, Haiguang. Image recognition of grape downy mildew and grape powdery mildew based on support vector machine. In: *International Conference on Computer and Computing Technologies in Agriculture*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. p. 151-162.

LOPES, Carlos M. et al. VINBOT-um robô terrestre para viticultura de precisão. *Actas Portuguesas de Horticultura*, nº 29, p. 517-523, 2017.

LOGGENBERG, Kyle et al. Modelling water stress in a Shiraz vineyard using hyperspectral imaging and machine learning. *Remote Sensing*, v. 10, n. 2, p. 202, 2018.

MASSRUHÁ, Silvia Maria Fonseca Silveira; LEITE, M. A. de A. *Agro 4.0: rumo à agricultura digital*. 2017. Disponível em: <<https://www.alice.cnptia.embrapa.br/bitstream/doc/1073150/1/PL-Agro4.0-JC-na-Escola.pdf>>. Acesso em: 12 maio 2025.

MASSRUHÁ, Silvia Maria Fonseca Silveira et al. *A transformação digital no campo rumo à agricultura sustentável e inteligente*. Brasília, DF: Embrapa, 2020.

MENDES, Cássia Isabel Costa et al. Agricultura digital: pesquisa, desenvolvimento e inovações nas cadeias produtivas. In: MENDES, Cássia Isabel Costa et al. O direito frente à digitalização da agricultura. Brasília, DF: Embrapa, 2020. p. 307–327. ISBN 978-65-86056-37-2.

MADEIRA, Miguel Ângelo Lage. Machine Learning for Precision Viticulture: Focusing on Plant Health. 2024. Dissertação de Mestrado. Universidade NOVA de Lisboa (Portugal).

MORARI, Francesco; CASTRIGNANÒ, A.; PAGLIARIN, C. Application of multivariate geostatistics in delineating management zones within a gravelly vineyard using geo-electrical sensors. *Computers and Electronics in Agriculture*, v. 68, n. 1, p. 97-107, 2009.

MATEO, F. et al. Predictive assessment of ochratoxin A accumulation in grape juice based-medium by *Aspergillus carbonarius* using neural networks. *Journal of Applied Microbiology*, v. 107, n. 3, p. 915-927, 2009.

MENESATTI, Paolo et al. Multivariate forecasting model to optimize management of grape downy mildew control. *Vitis*, v. 52, n. 3, p. 141-148, 2013.

MYLONAS, Phivos; VOUTOS, Yorghos; SOFOU, Anastasia. A collaborative pilot platform for data annotation and enrichment in viticulture. *Information*, v. 10, n. 4, p. 149, 2019.

MAIA, Guilherme Fonseca. Estimativa da produção de uva na casta Syrah com recurso a análise de imagem. 2019. Dissertação de Mestrado. Universidade de Lisboa (Portugal).

MAGALHAES, Sandro Augusto et al. Path planning algorithms benchmarking for grapevines pruning and monitoring. In: EPIA conference on artificial intelligence. Cham: Springer International Publishing, 2019. p. 295-306.

MARQUES, Pedro et al. Grapevine varieties classification using machine learning. In: EPIA Conference on Artificial Intelligence. Cham: Springer International Publishing, 2019. p. 186-199.

MARTINS, Rui Costa et al. Metbots: Metabolomics robots for precision viticulture. In: EPIA Conference on Artificial Intelligence. Cham: Springer International Publishing, 2019. p. 156-166.

MILLAN, Borja; AQUINO, Arturo; DIAGO, Maria P.; TARDAGUILA, Javier. Image analysis-based modelling for flower number estimation in grapevine. *Journal of the Science of Food and Agriculture*, [S. l.], v. 97, n. 3, p. 784-792, 2016. DOI: <https://doi.org/10.1002/jsfa.7797>

NAIKWADE, Rohan R. et al. Agricultura 5.0: futuro da agricultura inteligente. In: Conferência Nacional sobre Tendências Tecnológicas Globais Inovadoras em Arte, Design, Tecnologia, Gestão, Ciência Védica, Educação e Arquitetura, Cinema e Mídia, 2021. p. 1–6.

NEWLANDS, Nathaniel K. Artificial intelligence and Big Data analytics in vineyards: A review. IntechOpen, 2021.

NEUMAN, William. The Grapes of Math. *Wired*, 1 nov. 2001. Disponível em: <https://www.wired.com/2001/11/wine/>. Acesso em: 5 jun. 2025.

NUSKE, Stephen et al. Yield estimation in vineyards by visual grape detection. In: 2011 IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE, 2011. p. 2352-2358.

ORGANIZAÇÃO INTERNACIONAL DA VINHA E DO VINHO (OIV). State of the World Vine and Wine Sector in 2024. 2025. Disponível em: https://www.oiv.int/sites/default/files/2025-04/OIV-State_of_the_World_Vine-and-Wine-Sector-in-2024.pdf.> Acesso em: 12 maio 2025.

OLENSKYJ, Alexander G. et al. End-to-end deep learning for directly estimating grape yield from ground-based imagery. *Computers and Electronics in Agriculture*, v. 198, p. 107081, 2022.

OLIVEIRA, L.V.P. Manejo da Irrigação da Videira com Sistemas Automatizados no semiárido brasileiro. 2022. 62f. Dissertação (Mestrado em Engenharia Agrícola), Universidade Federal do Vale do São Francisco, UNIVASF, Juazeiro-BA.

OBERTI, Roberto et al. Automatic detection of powdery mildew on grapevine leaves by image analysis: Optimal view-angle range to increase the sensitivity. *Computers and Electronics in Agriculture*, v. 104, p. 1-8, 2014.

ORLANDO, Francesca et al. Estimating leaf area index (LAI) in vineyards using the PocketLAI smart-app. *Sensors*, v. 16, n. 12, p. 2004, 2016.

PEREIRA, G. E. et al. Viticultura de precisão e enologia de precisão: ferramentas e principais parâmetros para a produção de uvas, elaboração e valorização de vinhos com tipicidades distintas em cada “terroir”. 2024.

PIVOTO, D. et al. Desenvolvimento científico de tecnologias agrícolas inteligentes e sua aplicação no Brasil. *Journal of Innovation Management*, [S. l.], v. 6, n. 4, p. 114-136, 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214317316301184>>. Acesso em: 29 maio 2025.

PROTAS, JF da S.; LAZZAROTTO, J.J.; MACHADO, CAE. Panorama da vitivinicultura brasileira em 2022. 2024.

PALACIOS, Fernando et al. Early yield prediction in different grapevine varieties using computer vision and machine learning. *Precision Agriculture*, v. 24, n. 2, p. 407-435, 2023.

PAGLIAI, Andrea et al. Comparison of aerial and ground 3D point clouds for canopy size assessment in precision viticulture. *Remote Sensing*, v. 14, n. 5, p. 1145, 2022.

PÉREZ, D. S.; BROMBERG, Facundo. Segmentación de imágenes en viñedos para la medición autónoma de variables vitícolas. In: XVIII Congreso Argentino de Ciencias de la Computación. 2012.

PETER, Groumpos P.; ANTIGONI, Anninou P.; VASILEIOS, Groumpos P. A new mathematical modelling approach for viticulture and winemaking using fuzzy cognitive maps. *IFAC-PapersOnLine*, v. 48, n. 24, p. 15-20, 2015.

PORTALÉS, Cristina; RIBES-GÓMEZ, Emilio. An image-based system to preliminary assess the quality of grape harvest batches on arrival at the winery. *Computers in Industry*, v. 68, p. 105-115, 2015.

QIN, JiangLin et al. A non-linear model of nondestructive estimation of anthocyanin content in grapevine leaves with visible/red-infrared hyperspectral. In: International Conference on Computer and Computing Technologies in Agriculture. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010. p. 47-62.

RAFIQUE, Rizwan et al. Adapting the process based STICS model to simulate phenology and yield of table grapes-a high value fruit crop in a new emerging viticulture zone of South Asia. *Scientia Horticulturae*, v. 336, p. 113419, 2024.

RAY, S. AI helps Argentine small farmers and winemakers compete while luring a new generation. Microsoft Source, 2024. Disponível em: <https://news.microsoft.com/source/features/ai/argentina-wine-agriculture/>. Acesso em: 9 out. 2025.

REIS, Manuel JCS et al. Automatic detection of bunches of grapes in natural environment from color images. *Journal of Applied Logic*, v. 10, n. 4, p. 285-290, 2012.

SARACENI, Leonardo et al. Self-supervised data generation for precision agriculture: Blending simulated environments with real imagery. In: 2024 IEEE 20th International Conference on Automation Science and Engineering (CASE). IEEE, 2024. p. 71-77.

STEFENON, Claudia; MARTINS, Henrique Marafiga. Terroir e Inteligência Artificial:: uma revisão sobre tradição e tecnologia na vitivinicultura. In: VI Congresso Internacional de Ontopsicologia e Desenvolvimento Humano. 2024. p. 182-189.

SAIZ-RUBIO, V.; ROVIRA-MÁS, F. Da agricultura inteligente à agricultura 5.0: uma revisão sobre o gerenciamento de dados de culturas. *Agronomy*, [S. l.], v. 10, n. 2, p. 1-23, 2020. Disponível em: <https://doi.org/10.3390/agronomy10020207>. Acesso em: 29 maio 2025.

SANTIN, W. O campo em tempo real. *Globo Rural*, n. 418, p. 14-19, ago. 2020.

SHEPHERD, Mark et al. Priorities for science to overcome hurdles thwarting the full promise of the 'digital agriculture' revolution. *Journal of the Science of Food and Agriculture*, v. 100, n. 14, p. 5083-5092, 2020.

SANTOS, Thiago T. et al. Grape detection, segmentation, and tracking using deep neural networks and three-dimensional association. *Computers and Electronics in Agriculture*, v. 170, p. 105247, 2020.

SILVER, Daniel L.; NASA, Jabun. Estimating Grape Yield on the Vine from Multiple Images. arXiv preprint arXiv:2004.04278, 2020.

SALLIS, P. et al. Frost prediction using a combinational model of supervised and unsupervised neural networks for crop management in vineyards. In: 18th IMACS World Congress-MODSIM09 International Congress on Modelling and Simulation. 2009. p. 13-17.

SONG, Jianqiang et al. Pinot Noir wine composition from different vine vigour zones classified by remote imaging technology. *Food chemistry*, v. 153, p. 52-59, 2014.

SANTOS, Luís et al. Vineyard segmentation from satellite imagery using machine learning. In: EPIA Conference on Artificial Intelligence. Cham: Springer International Publishing, 2019. p. 109-120.

SILVA, Nuno et al. Low-cost IoT LoRa® solutions for precision agriculture monitoring practices. In: EPIA Conference on Artificial Intelligence. Cham: Springer International Publishing, 2019. p. 224-235.

SILVER, Daniel L.; MONGA, Tanya. In vino veritas: Estimating vineyard grape yield from images using deep learning. In: Canadian Conference on Artificial Intelligence. Cham: Springer International Publishing, 2019. p. 212-224.

TARDÁGUILA, Javier et al. Applications of computer vision techniques in viticulture to assess canopy features, cluster morphology and berry size. In: I International Workshop on Vineyard Mechanization and Grape and Wine Quality 978. 2012. p. 77-84.

VAUDOUR, Emmanuelle; CAREY, Victoria A.; GILLIOT, Jean-Marc. Digital zoning of South African viticultural terroirs using bootstrapped decision trees on morphometric data and multitemporal SPOT images. *Remote sensing of Environment*, v. 114, n. 12, p. 2940-2950, 2010.

VERSARI, Andrea et al. Prediction of colloidal stability in white wines using infrared spectroscopy. *Journal of food engineering*, v. 104, n. 2, p. 239-245, 2011.

WINE OF MOLDOVA. Wine of Moldova launches world's first serious AI wine at ProWein 2024. *Wine Business*, 13 mar. 2024. Disponível em: <https://www.winebusiness.com/news/article/284637>. Acesso em: 9 out. 2025.

WINE-SEARCHER. Introducing the first AI wine. 2023. Disponível em: <https://www.wine-searcher.com/m/2023/04/introducing-the-first-ai-wine>. Acesso em: 9 out. 2025.

YAGOUBI, Rim Saddem et al. New approach for differential harvest problem: The model checking way. IFAC-PapersOnLine, v. 51, n. 7, p. 57-63, 2018.

ZHAI, Zhaoyu et al. Decision support systems for agriculture 4.0: survey and challenges. Computers and Electronics in Agriculture, v. 170, p. 105256, 2020.

ZABAWA, Laura et al. Counting of grapevine berries in images via semantic segmentation using convolutional neural networks. ISPRS Journal of Photogrammetry and Remote Sensing, v. 164, p. 73-83, 2020.

ANEXOS

ANEXOS A – Tabela comparativa dos estudos (2009–2014):

Ano	País	Autores	Aplicação	Técnica de IA	Tipo de dado	Impacto/Resultado
2009	Nova Zelândia	Sallis et al.	Previsão de geadas em vinhedos	Redes neurais supervisionadas e não supervisionadas	Climáticos	Ferramenta de adaptação climática com alta precisão na previsão de geadas
2009	Portugal	Cortez et al.	Previsão de preferências sensoriais de vinhos	Mineração de dados e SVM	Físico-químicos	Modelagem precisa de preferências sensoriais a partir de variáveis laboratoriais
2009	Alemanha	Hall & Louis	Correção de imprecisões de GPS em vinhedos	Algoritmo VineClipper (busca proximal)	Imagens aéreas e georreferenciadas	Aumento da acurácia no mapeamento do dossel e na geolocalização de videiras

2009	Itália	Morari et al.	Delimitação de zonas de manejo em solos pedregosos	Lógica fuzzy e estatística multivariada	Geométricos e de solo	Identificação de zonas homogêneas para manejo de precisão
2009	Austrália	Berna et al.	Determinação da origem geográfica de vinhos	Espectrometria de massas + narizes eletrônicos	Químicos e voláteis	Alta acurácia na rastreabilidade e autenticação de vinhos
2009	Espanha	Mateo et al.	Previsão de ocratoxina A em sucos de uva	Redes neurais MLP e RBF	Microbiológicos e ambientais	Predição eficaz de micotoxinas, ampliando a segurança alimentar
2010	Israel	Berenstein et al.	Pulverização seletiva automatizada	Visão computacional	Imagens RGB	90% de precisão na detecção de cachos e redução de 30% no uso de pesticidas
2010	África do Sul	Vaudour et al.	Mapeamento digital de terroirs	Árvores de decisão	Imagens SPOT multitemporais	78% de acurácia na classificação de zonas

						homogêneas
2010	Espanha	Gago, Landín & Gallego	Modelagem da rizogênes e e aclimação <i>in vitro</i>	Redes neurais artificiais	Fisiológicos e laboratoriais	Otimização de processos de biotecnologia vegetal
2010	China	Qin et al.	Estimativa de antocianinas em folhas de videira	Modelos não lineares	Hiperespectrais	Monitoramento não destrutivo de pigmentos foliares
2010	França	Decourselle et al.	Caracterização de rugosidade e foliar	Visão computacional + cloud computing	Imagens de folhas	Otimização da pulverização de precisão
2010	Espanha	Astray et al.	Autenticação de vinhos	Redes neurais artificiais	Químicos e sensoriais	Classificação precisa de origem e autenticidade
2011	EUA	Nuske et al.	Estimativa de produtividade com robótica embarcada	Visão computacional + robótica	Imagens RGB e sensores	Margem de erro <10% na predição de colheita

2011	Espanha	Fernández-Martínez et al.	Seleção de variáveis na maturação da uva	Wrapper methods	Ambientais e fenológicos	Redução de erro em modelos preditivos
2011	China	Li, Ma & Wang	Diagnóstico de míldio e oídio	SVM	Imagens foliares	Taxa de acerto superior a 90%
2011	Itália	Versari et al.	Previsão de estabilidade de coloidal em vinhos	Espectroscopia NIR + regressão	Químicos	R ² = 0,85; predição confiável da estabilidade de coloidal
2012	Portugal	Reis et al.	Deteção automática de cachos de uva	Visão computacional	Imagens de campo	Acurácia de 97% em uvas tintas e 91% em brancas
2012	Argentina	Bromberg & Pérez	Interpolação espacial de variáveis vitícolas	SVM e LSVM	Geoestatísticos e agrônomicos	Superou métodos tradicionais de krigagem e IDW
2012	Argentina	Pérez & Bromberg	Medição automática de variáveis vitícolas	Segmentação de imagens (K-means, SVM, GMM)	Imagens RGB	Automação da medição de troncos e variáveis de campo

2012	Espanha	Tardáguila et al.	Análise fenotípica da copa e dos cachos	Visão computacional	Imagens RGB	Avaliação objetiva e escalável da morfologia da planta
2012	França	Coulon et al.	Previsão de vigor e precocidade da videira	Inferência fuzzy	Agrônomicos e climáticos	Criação de indicadores para manejo adaptativo
2013	Itália	Menesatti et al.	Controle de míldio	Modelos multivariados	Agrônomicos e meteorológicos	Redução de 50% no uso de fungicidas à base de cobre
2014	França	Coulon-Leroy et al.	Modelagem fuzzy de vigor da videira	Fuzzy inference (fisPro)	Agrônomicos	Integração de múltiplos parâmetros agrônomicos
2014	Itália	Oberti et al.	Deteção precoce do oídio	Visão computacional multiespectral	Imagens multiespectrais	Diagnóstico otimizado em ângulos de 40°–60°
2014	Espanha	Gómez-Meira et al.	Autenticação de vinhos brancos autóctones	Random Forest	Químicos	Classificação perfeita das variedades

						s regionais
2014	Romênia	Hosu, Cristea & Cimpoi	Previsão de atividade antioxidante e classificação de vinhos	Redes neurais	Químicos	Correlação robusta entre compostos fenólicos e atividade antioxidante
2014	Austrália	Song et al.	Classificação de zonas de vigor	NIR + aprendizagem de máquina	Imagens aéreas	Correlação entre vigor, rendimento e qualidade aromática

ANEXOS B – Tabela comparativa dos estudos (2015–2019):

Ano	País	Autores	Aplicação	Técnica de IA	Tipo de dado	Impacto/Resultado
2015	França	Baudrit et al.	Modelagem da maturação da baga	Modelo gráfico probabilístico	Químicos e fisiológicos	Quantificação da incerteza e melhor definição do ponto ótimo de colheita
2015	Grécia	Peter Groupos et al.	Modelagem integrada da viticultura e vinificação	Mapas cognitivos fuzzy	Climáticos e agrônomicos	Representação sistêmica das interações vitícolas e

			o			enológica s
2015	Espanha	Portalés & Ribes-Gómez	Avaliação automatizada da qualidade e de uvas na recepção da vinícola	Visão computacional	Imagens RGB	Automação da inspeção visual e padronização do controle de qualidade
2016	Espanha	Gutiérrez et al.	Fenotipagem de plantas em campo	Mineração de dados + espectroscopia NIR	Espectrais e agrônomicos	Monitoramento não destrutivo de vigor e estado fisiológico
2016	China	Hou, Li & He	Detecção da doença do enrolamento da folha da videira	Algoritmo de colônia de formigas + índices espectrais	Espectrais e foliares	Alta precisão na identificação precoce da doença
2016	Espanha	Millan et al.	Estimativa do número de flores e correlação com rendimento	Análise de imagem + modelagem estatística	Imagens de campo	Correlação consistente entre número de flores e produtividade
2016	Itália	Orlando et al.	Estimativa do índice de área foliar (LAI)	Aplicativo PocketLAI (modelagem empírica)	Imagens móveis e medições ópticas	Solução de baixo custo e alta acessibilidade para produtores

2017	Portugal	Lopes et al.	Robô terrestre para viticultura de precisão (VINBOT)	Visão computacional + sensores ópticos	Imagens e dados agrônomicos	Monitoramento autônomo e coleta automatizada de dados em campo
2017	Cingapura	Ang, Seng & Ge	Reconhecimento visual inspirado na natureza	Algoritmos bioinspirados	Imagens RGB	Modelagem visual baseada em comportamentos naturais aplicados à viticultura
2017	Espanha	Aquino et al.	Previsão antecipada de produtividade	Aprendizado de máquina + visão computacional	Imagens de campo	Estimativa precoce de rendimento com alta correlação com a colheita real
2017 (publicado em 2020)	Brasil	Dos Santos et al.	Deteção automática de frutos em campo	Aprendizado de máquina supervisionado	Imagens RGB	Primeira validação nacional de IA para viticultura tropical
2018	Tunísia	Belkaroui et al.	Ontologia de eventos em viticultura com redes de sensores	Ontologias semânticas + IoT	Dados sensoriais e contextuais	Integração semântica de dados para raciocínio automatizado

2018	África do Sul	Loggenberg et al.	Detecção de estresse hídrico em uvas Shiraz	Aprendizado de máquina + imagens hiperespectrais	Espectrais e fisiológicos	Diagnóstico precoce de estresse hídrico com alta acurácia
2018	França	Yagoubi et al.	Otimização da colheita diferenciada	Model checking (verificação formal)	Operacionais e de planeamento	Tomada de decisão automatizada na colheita seletiva
2019	Grécia	Mylonas, Voutos & Sofou	Plataforma colaborativa de anotação e enriquecimento de dados	Sistemas colaborativos + aprendizagem supervisionada	Bases de dados vitícolas	Melhoria na curadoria e anotação de dados para aprendizagem de máquina
2019	Portugal	Santos et al.	Segmentação de vinhedos por imagens de satélite	Aprendizado de máquina supervisionado	Imagens de satélite	Delimitação automatizada de vinhedos com alta precisão espacial
2019	Portugal	Marques et al.	Classificação de variedades de uva	Aprendizado supervisionado	Imagens e dados morfológicos	Identificação automatizada de cultivares de videira
2019	Portugal	Silva et al.	Monitoramento vitícola com soluções	IoT + LoRa® + aprendizagem de máquina	Sensoriais e ambientais	Expansão da conectividade rural e

			IoT de baixo custo			monitoramento contínuo de vinhedos
2019	Austrália	Fuentes et al.	Detecção de contaminação por fumaça em bagas e dosséis	Aprendizado de máquina + sensoria-mento remoto	Espectrais e químicos	Diagnóstico não invasivo de contaminação por fumaça
2019	Portugal	Maia	Estimativa de produção na casta Syrah	Análise de imagem	Imagens de campo	Correlação robusta entre parâmetros visuais e rendimento
2019	China	Chu et al.	Previsão de preços de uvas	Modelo híbrido de IA	Econômicos e produtivos	Integração entre dados de mercado e produção agrícola
2019	Canadá	Silver & Monga	Estimativa de produtividade por deep learning	Deep learning (CNN)	Imagens RGB	Acurácia superior às abordagens tradicionais de estimativa de rendimento
2019	Portugal	Martins et al.	Robôs metabólicos para viticultura de	Robótica + aprendizado de máquina	Metabólicos e espectrais	Análise automatizada de compostos químicos

			precisão (MetBots)			no campo
2019	Portugal	Magalhães et al.	Planejamento de trajetórias para poda e monitoramento	Planejamento inteligente + aprendizado de máquina	Dados espaciais e operacionais	Otimização do deslocamento de robôs agrícolas
2019	Portugal	Bento, da Cunha & Barata	Impactos sociotécnicos da Agricultura 4.0 na viticultura	Análise sociotécnica com base em IA	Conceituais e organizacionais	Reflexão sobre transformações humanas e tecnológicas no setor

ANEXOS C – Tabela comparativa dos estudos (2020–2024):

Ano	País	Autores	Aplicação	Técnica de IA	Tipo de dado	Impacto / Resultado
2020	França	Kerkech, Hafiane & Canals	Detecção de doenças da videira	CNN (VddNet)	Imagens multiespectrais e mapas de profundidade	Alta robustez em variações de iluminação; diagnóstico automatizado de doenças.
2020	EUA	Silver & Nasa	Estimativa de rendimento na videira	Deep learning (CNN)	Imagens RGB multivista	Predição precisa do número de cachos e estimativ

						a não destrutiva de produtividade.
2020	Espanha	Santos et al.	Detecção, segmentação e rastreamento 3D de uvas	Redes neurais convolucionais + associação temporal	Imagens tridimensionais	Acurácia superior às abordagens 2D; avanço em fenotipagem digital.
2020	Alemanha	Zabawa et al.	Contagem de bagas de uva	Segmentação semântica com CNN	Imagens RGB	Detecção automática e precisa de bagas, reduzindo erros humanos.
2020	Brasil	Bischoff & Farias	Previsão de doenças em vinhedos	IoT + modelos preditivos	Dados de sensores ambientais	Sistema VitForecast integra clima e umidade para alertas antecipados de doenças.
2020	Portugal	Jesus	Modelagem fenológica (PhenoEngine)	Detecção remota + regressão	Dados climáticos e imagens de satélite	Modelagem da fenologia com precisão temporal aprimorada.
2021	Canadá	Newlands	Revisão sobre IA e Big	Revisão sistemática	Dados secundários	Identificação de desafios

			Data na viticultura			em interoperabilidade e gestão de dados massivos
2021	Brasil	Arnecke	Previsão de demanda de vinhos	Modelos de séries temporais	Dados econômicos e de vendas	Aplicação da IA na gestão de mercado vitivinícola.
2022	Alemanha	Kierdorf et al.	Estimativa de bagas ocultas por folhas	Redes generativas adversariais (cGAN)	Imagens RGB ocultas	Melhoria na estimativa de produtividade em cachos parcialmente visíveis.
2022	Portugal	Barros et al.	Segmentação multiespectral de vinhedos	Deep learning (comparativo)	Imagens multiespectrais	Identificação de arquitetura ideal para mapeamento de vinhedos.
2022	Brasil	Oliveira	Manejo automatizado de irrigação	Modelagem automatizada com IA	Dados de sensores e umidade do solo	Otimização da irrigação e uso eficiente de água no semiárido.
2022	Suíça	Olenskyj et al.	Estimativa direta de rendimento	CNN end-to-end	Imagens terrestres	Predição de rendimento sem

			to			etapas intermediárias, com alta acurácia.
2022	Portugal	Barriguiha et al.	Estimativa de produtividade	Aprendizado de máquina (ML)	NDVI, clima e dados históricos	Elevada acurácia na previsão de rendimento no Douro.
2022	Espanha	López-García et al.	Monitoramento hídrico multitemporal	Machine learning	Imagens UAV RGB e multiespectrais	Monitoramento preciso do estado hídrico das videiras.
2022	Itália	Pagliai et al.	Avaliação tridimensional da copa	Deep learning 3D	Nuvens de pontos aéreas e terrestres	Melhor precisão no cálculo de volume da copa e vigor.
2023	Espanha	Palacios et al.	Predição antecipada de rendimento	Visão computacional + ML	Imagens RGB	Predição precoce da produtividade com alta correlação real.
2023	Brasil	Andrade et al.	Comparação de algoritmos de rendimento	Random Forest, SVM, RNA	Dados fenológicos e climáticos	Modelos híbridos apresentam melhor desempenho.

2023	Grécia	Badeka et al.	Avaliação da maturação de uvas	Deep learning (YOLOv7)	Imagens RGB	Detecção em tempo real com alta precisão.
2023	França	De la Fuente et al.	Estimativa de produtividade via satélite	ML supervisionado	Imagens de satélite	Predição em larga escala com alta acurácia.
2023	Global	Wine-Searcher	Vinificação orientada por IA	Modelos de recomendação e química computacional	Dados sensoriais e químicos	Primeiros vinhos desenvolvidos com suporte de IA.
2024	Sul da Ásia	Rafique et al.	Simulação de fenologia e rendimento	Modelo STICS + IA	Dados meteorológicos e agrônomicos	Adaptação a novas zonas vitícolas; simulação precisa.
2024	Itália	Dimitri & Trambusti	Relação clima-qualidade do vinho	ML supervisionado	Dados meteorológicos e químicos	Predição da qualidade baseada em clima.
2024	Brasil	Pereira et al.	Viticultura e enologia de precisão	Modelos híbridos	Dados fenológicos e químicos	Identificação de parâmetros de terroir e valorização de vinhos típicos.
2024	Portugal	Madeira	Diagnóstico da saúde da videira	Machine learning	Imagens e dados de sensores	Monitoramento de sanidade e vigor vegetal.

2024	Índia	Barbole & Jadhav	Comparação de modelos 2D e 3D	IA híbrida	Imagens RGB e 3D	Modelos 3D superaram 2D em acurácia de predição.
2024	Grécia	Gatou et al.	Revisão de técnicas de IA na viticultura	Revisão sistemática	Bases de dados e estudos publicados	Síntese sobre datasets e métricas de desempenho.
2024	África do Sul	Jewan et al.	Predição de rendimento e composição de bagas	ML multimodal	Dados hiperespectrais, térmicos e de solo	Previsão aprimorada da produtividade e qualidade.
2024	África do Sul	Loggenberg et al.	Revisão sobre sensoria mento óptico	Revisão bibliográfica	Dados ópticos e UAV	Atualização sobre tendências em sensoria mento para viticultura.
2024	Internacional	Kamangir et al.	Estimativa multimodal de rendimento (CMAViT)	Vision transformers	Dados climáticos, de manejo e sensoria mento	Modelo multimodal de alta precisão.
2024	Sérvia	Gavrilović et al.	Zoneamento e detecção de videiras	YOLO + K-means	Imagens UAV	90% de acurácia na detecção automática e

						zoneamento.
2024	Argentina	Ray	Plataformas inteligentes (Agrobit)	IA aplicada à IoT	Dados produtivos e climáticos	Pequenos produtores adotam IA para otimização e rastreabilidade.
2024	Moldávia	Wine of Moldova	Produção de vinhos com IA	Sistema Chelaris Bot	Dados sensoriais e de fermentação	Primeiro vinho criado com apoio direto de IA.
2024	Brasil	Stefenon & Martins	Revisão sobre terroir digital	Revisão teórica	Literatura interdisciplinar	Integração entre tradição e inovação algorítmica.
2024	EUA	Saraceni et al.	Geração de dados auto-supervisionados	Aprendizado auto-supervisionado	Imagens simuladas e reais	Melhora de generalização de modelos agrícolas.