

**MODELOS DE SISTEMAS DE SUPORTE À DECISÃO PARA AGRICULTURA DE PRECISÃO: APLICAÇÕES NO MONITORAMENTO CLIMÁTICO E PREDIÇÃO DE RENDIMENTO AGRÍCOLA**

**DECISION SUPPORT SYSTEM MODELS FOR PRECISION AGRICULTURE: APPLICATIONS IN CLIMATE MONITORING AND AGRICULTURAL YIELD PREDICTION**

**MODELOS DE SISTEMAS DE APOYO A LA TOMA DE DECISIONES PARA LA AGRICULTURA DE PRECISIÓN: APLICACIONES EN LA MONITORIZACIÓN CLIMÁTICA Y LA PREDICCIÓN DEL RENDIMIENTO AGRÍCOLA**

 <https://doi.org/10.56238/arev7n11-290>

**Data de submissão:** 24/10/2025

**Data de publicação:** 24/11/2025

**Euzimar Dos Santos Chagas**

Graduando em Tecnologia em Agrocomputação

Instituição: Instituto Federal de Educação, Ciências e Tecnologia de Rondônia (IFRO)

E-mail: euzimarchagas@hotmail.com

**Miguel Fabrício Zamberlan**

Mestre em Administração

Instituição: Instituto Federal de Educação, Ciências e Tecnologia de Rondônia (IFRO)

E-mail: miguel.zamberlan@ifro.edu.br

---

**RESUMO**

Este artigo analisa modelos de sistemas de suporte à decisão aplicados à agricultura de precisão, temática relevante pela necessidade de decisões orientadas por dados em cenários de variabilidade meteorológica e pressão por eficiência. O objetivo é mapear tipologias de sistemas, fontes e integrações de dados climáticos e de sensoriamento remoto, e famílias de modelos preditivos para estimativa de produtividade. Foi realizada revisão bibliográfica entre 2015 e 2025 em Scopus, Web of Science, SciELO, IEEE Xplore e Google Acadêmico, com triagem por título, resumo e texto completo, remoção de duplicados e extração padronizada de cultura, local, dados utilizados, tipo de sistema, algoritmo, métricas e limitações. Os estudos foram sintetizados em matriz comparativa. A revisão identificou três vertentes principais, baseadas em regras, em modelos e em dados com aprendizado de máquina, e verificou amplo uso de séries meteorológicas, reanálises e índices espectrais integrados a plataformas operacionais nacionais. Abordagens com aprendizado de máquina apresentaram melhor desempenho que modelos estatísticos, com  $R^2$  de 0,81 e RMSE de 176,93 kg ha<sup>-1</sup> em soja, erros inferiores a 10 por cento com redes profundas e previsões nacionais com rRMSE de 6 por cento. Persistiram limitações de lacunas de dados, generalização espaço-temporal, custos e necessidade de calibração e explicabilidade. Conclui-se que a integração clima mais sensoriamento remoto e modelos híbridos constitui caminho promissor, e que investimentos em infraestrutura e capacitação ampliam a adoção prática dos sistemas.

**Palavras-chave:** Agricultura Digital. Sensoriamento Remoto. Aprendizado de Máquina. Produtividade. Validação Espacial.

## ABSTRACT

This article analyzes decision support system models applied to precision agriculture, a relevant topic due to the growing need for data-driven decision-making in scenarios of meteorological variability and increasing pressure for efficiency. The objective is to map system typologies, sources and integrations of climate data and remote sensing, and families of predictive models used for yield estimation. A bibliographic review was conducted between 2015 and 2025 in Scopus, Web of Science, SciELO, IEEE Xplore, and Google Scholar, following screening by title, abstract, and full text, removal of duplicates, and standardized extraction of crop, location, data used, system type, algorithm, metrics, and reported limitations. The studies were synthesized in a comparative matrix. The review identified three main system branches—rule-based, model-based, and data-driven approaches using machine learning—and found extensive use of meteorological time series, reanalysis products, and spectral indices integrated into national operational platforms. Machine learning approaches outperformed statistical models, achieving  $R^2$  of 0.81 and RMSE of 176.93 kg ha<sup>-1</sup> for soybean, errors below 10 percent with deep networks, and national-scale forecasts with rRMSE of 6 percent. Persistent limitations included data gaps, spatiotemporal generalization issues, costs, and the need for calibration and explainability. It is concluded that integrating climate and remote sensing data with hybrid models is a promising pathway, and that investments in infrastructure and training can enhance the practical adoption of these systems.

**Keywords:** Digital Farming. Remote Sensing. Machine Learning. Crop Forecasting. Spatial Validation.

## RESUMEN

Este artículo analiza modelos de sistemas de apoyo a la toma de decisiones aplicados a la agricultura de precisión, un tema relevante debido a la necesidad de tomar decisiones basadas en datos en escenarios de variabilidad meteorológica y presión por eficiencia. El objetivo es mapear tipologías de sistemas, fuentes e integraciones de datos climáticos y de teledetección, y familias de modelos predictivos para la estimación de la productividad. Se realizó una revisión bibliográfica entre 2015 y 2025 en Scopus, Web of Science, SciELO, IEEE Xplore y Google Académico, con selección por título, resumen y texto completo, eliminación de duplicados y extracción estandarizada de cultivo, ubicación, datos utilizados, tipo de sistema, algoritmo, métricas y limitaciones. Los estudios se sintetizaron en una matriz comparativa. La revisión identificó tres vertientes principales, basadas en reglas, en modelos y en datos con aprendizaje automático, y verificó un amplio uso de series meteorológicas, reanálisis e índices espectrales integrados en plataformas operativas nacionales. Los enfoques con aprendizaje automático presentaron un mejor rendimiento que los modelos estadísticos, con un  $R^2$  de 0,81 y un RMSE de 176,93 kg ha<sup>-1</sup> en la soja, errores inferiores al 10 % con redes profundas y previsiones nacionales con un rRMSE del 6 %. Persistieron las limitaciones de las lagunas de datos, la generalización espacio-temporal, los costes y la necesidad de calibración y explicabilidad. Se concluye que la integración del clima con la teledetección y los modelos híbridos constituye una vía prometedora, y que las inversiones en infraestructura y capacitación amplían la adopción práctica de los sistemas.

**Palabras clave:** Agricultura Digital. Teledetección. Aprendizaje Automático. Productividad. Validación Espacial.

## 1 INTRODUÇÃO

A agricultura de precisão consolidou-se, nas últimas décadas, como um conjunto de práticas e tecnologias que permitem observar, medir e responder à variabilidade espacial e temporal dos sistemas de produção agrícola, com o objetivo de elevar a eficiência técnica e econômica, reduzir desperdícios e mitigar impactos ambientais. A transição de um enfoque centrado em máquinas para um ecossistema digital, que integra sensores, Sistema Global de Navegação por Satélite (GNSS), sistemas de informação geográfica, imagens orbitais e plataformas analíticas, caracteriza a evolução recente do campo e amplia o escopo da tomada de decisão baseada em dados (Inamasu *et al.*, 2024; Molin, 2024). Nesse contexto, a agricultura passa a operar em camadas de informação cada vez mais ricas e frequentes, viabilizando decisões de manejo mais precisas em solos, plantas e operações mecanizadas, além de maior capacidade de resposta a condições meteorológicas adversas e a oscilações de mercado.

A variabilidade climática, expressa por extremos de precipitação, ondas de calor e alterações em janelas térmicas e hídricas, intensifica incertezas sobre o desempenho das lavouras e reforça a necessidade de ferramentas que antecipem cenários e orientem o produtor. A literatura nacional destaca que estratégias digitais, como monitoramento meteorológico, sensoriamento remoto e automação de processos, potencializam ganhos de eficiência no uso de insumos, principalmente água em sistemas irrigados, ao mesmo tempo em que oferecem meios para adaptação a riscos climáticos crescentes (Gundim *et al.*, 2023; Assad; Assad, 2024). Esses dados, quando coletados de forma contínua por estações, redes de Internet das Coisas (IoT) e satélites, alimentam modelos capazes de estimar estados atuais das culturas, prever rendimento e recomendar intervenções.

Os Sistemas de Suporte à Decisão (SSD), concebidos para integrar dados, modelos e interfaces de análise, surgem como eixo organizador dessa transformação digital no agro. De maneira geral, tais sistemas executam funções de monitoramento, diagnóstico, previsão e recomendação, apoiadas por diferentes paradigmas de modelagem, como regras baseadas em conhecimento, modelos de processo e abordagens orientadas a dados, incluindo algoritmos de aprendizado de máquina e técnicas de inteligência artificial (Zhai *et al.*, 2020; Souza; Oliveira; Macário, 2020). Embora a literatura reporte avanços expressivos, persiste uma lacuna relevante: a integração consistente entre informações climáticas em tempo quase real e produtos de sensoriamento remoto, em arquiteturas de SSD que conciliem qualidade de dados, interoperabilidade, usabilidade e custo de implementação, ainda é heterogênea entre regiões, culturas e perfis de produtores.

Além da integração de fontes de dados, observa-se heterogeneidade nas famílias de modelos preditivos utilizadas para rendimento agrícola, que vão de regressões e séries temporais até ensembles e redes neurais profundas. Estudos brasileiros com soja mostram que a incorporação de índices

espectrais de satélite e variáveis meteorológicas, combinada a algoritmos de aprendizado de máquina, pode elevar a acurácia da previsão em diferentes fases do ciclo, o que reforça o potencial de SSD que conectem clima, sensoriamento remoto e modelagem preditiva para apoiar decisões in season (Schwalbert *et al.*, 2020; Dos Santos *et al.*, 2022). Ao mesmo tempo, a literatura alerta para desafios metodológicos, como a necessidade de métricas robustas, validações espacial e temporal adequadas e comunicação transparente de incertezas, sob pena de superestimar o desempenho dos modelos e comprometer a confiança do usuário final.

Diante desse cenário, o objetivo geral deste artigo é analisar os principais modelos de Sistemas de Suporte à Decisão aplicados à agricultura de precisão, com ênfase no monitoramento climático e na predição de rendimento agrícola. Especificamente, busca-se: i) identificar e caracterizar tipologias de SSD relevantes ao agro, ii) levantar e comparar famílias de modelos estatísticos e de aprendizado de máquina empregadas na previsão de rendimento, iii) mapear fontes e fluxos de dados climáticos e de sensoriamento remoto integráveis aos SSD, bem como suas limitações e requisitos operacionais, e iv) discutir métricas e protocolos de validação adequados ao contexto agrícola brasileiro. Ao cumprir esses objetivos, pretende-se oferecer um panorama crítico e ao mesmo tempo prático, útil para pesquisadores, técnicos e produtores.

O artigo está assim organizado: após esta introdução, apresenta-se um referencial teórico conciso, estruturado em duas subseções dedicadas aos fundamentos da agricultura de precisão e às definições, funções e tipologias dos Sistemas de Suporte à Decisão. Em seguida, descrevem-se os procedimentos metodológicos adotados na revisão. Na sequência, a Seção 4 reúne a sistematização dos resultados, contemplando a análise integrada dos modelos preditivos de rendimento, do monitoramento climático e do sensoriamento remoto, bem como quadros comparativos que sintetizam dados, métricas, limitações e oportunidades identificadas na literatura. Por fim, apresentam-se as considerações finais, com implicações práticas e direções para pesquisas futuras.

## 2 REFERENCIAL TEÓRICO

### 2.1 AGRICULTURA DE PRECISÃO: CONCEITOS E FUNDAMENTOS

A agricultura de precisão (AP) representa um marco na modernização do setor agrícola, caracterizando-se pelo uso intensivo de tecnologias para gerenciar a variabilidade espacial e temporal dos sistemas produtivos. Seu conceito está fundamentado na ideia de aplicar insumos e práticas agrícolas no local certo, no momento adequado e na quantidade exata, maximizando a eficiência produtiva e minimizando impactos ambientais. No Brasil, esse campo evoluiu a partir da adoção inicial de tecnologias voltadas à mecanização e monitoramento, até alcançar a atual fase digital, em que há

integração de sensores, dados geoespaciais e inteligência computacional. Essa transição reflete uma perspectiva histórica de constante transformação, em que a agricultura passa a operar como um ecossistema digital integrado, no qual a coleta e a análise de dados orientam a tomada de decisão no período compreendido entre 2015 e 2025 (Inamasu et al., 2024; Molin, 2024).

As ferramentas utilizadas na AP são diversificadas e englobam desde sensores proximais e remotos até sistemas avançados de georreferenciamento. Os sensores permitem medir parâmetros de solo, planta e atmosfera, fornecendo informações em tempo real que podem ser cruzadas com bancos de dados históricos. O uso de Sistema de Posicionamento Global (GPS) possibilita a localização precisa das operações agrícolas, enquanto softwares de geoprocessamento, como Sistema de Informação Geográfica (SIG/QGIS), permitem a análise espacial detalhada de variáveis de interesse. Além disso, drones, também denominados Veículos Aéreos Não Tripulados (VANTs), ampliaram a capacidade de monitoramento por meio de imagens de alta resolução, auxiliando na identificação de problemas fitossanitários, deficiências nutricionais e heterogeneidades no campo (Queiroz et al., 2021; Amaral et al., 2021; Oliveira; Brandão; Rodrigues, 2022).

A importância da AP transcende os ganhos de produtividade e se estende à redução dos riscos associados à variabilidade climática. Práticas de irrigação de precisão, por exemplo, têm se mostrado eficazes para otimizar o uso da água, recurso cada vez mais escasso em muitas regiões, contribuindo para a sustentabilidade da produção agrícola. Essa abordagem permite ajustar o fornecimento hídrico às necessidades específicas das plantas, melhorando o aproveitamento dos recursos e reduzindo desperdícios. Além disso, a integração de dados climáticos e agronômicos possibilita prever cenários de risco, oferecendo suporte a estratégias adaptativas em situações de seca ou excesso de chuva (Gundim et al., 2023; Assad; Assad, 2024).

Apesar de seus avanços, a adoção da AP ainda enfrenta barreiras significativas, especialmente em regiões de agricultura familiar e em áreas com menor acesso a recursos tecnológicos. O alto custo de aquisição de equipamentos e softwares, aliado à necessidade de capacitação técnica para interpretar os dados e operar os sistemas, são fatores limitantes para muitos produtores. Estudos realizados no sudoeste de Goiás mostram que, embora a percepção dos benefícios seja clara, ainda existe resistência e dificuldade de adoção, resultando em desigualdade no acesso às inovações (Soares Filho; Cunha, 2015). Nesse sentido, políticas públicas, iniciativas de extensão rural e programas de incentivo podem ser fundamentais para democratizar o acesso às tecnologias de precisão no campo brasileiro.

## 2.2 Sistemas de suporte à decisão no contexto agrícola

Os Sistemas de Suporte à Decisão (SSD) configuram-se como ferramentas essenciais para a agricultura contemporânea, pois integram dados de diferentes fontes, modelos analíticos e interfaces

amigáveis, oferecendo informações úteis e açãoáveis para agricultores, técnicos e formuladores de políticas. No contexto agrícola, sua função é apoiar processos de monitoramento, previsão e recomendação, transformando dados complexos em informações acessíveis que subsidiam decisões em tempo oportuno. A literatura aponta que os SSD evoluíram com a agricultura digital e hoje abrangem desde aplicações móveis de fácil acesso até plataformas complexas que integram grandes volumes de dados e análises preditivas (Zhai *et al.*, 2020; Souza; Oliveira; Macário, 2020).

As tipologias de SSD variam de acordo com a lógica de processamento dos dados e a natureza dos modelos empregados. Os sistemas baseados em regras utilizam conhecimentos previamente estruturados e motores de inferência para recomendar práticas, sendo comuns em aplicações ambientais e de gestão de recursos naturais. Já os sistemas baseados em modelos empregam simulações biofísicas e matemáticas, como o caso de aplicativos que utilizam graus-dia para estimar estádios fenológicos de culturas. Outra tipologia é a dos sistemas orientados a dados, que se beneficiam do avanço das técnicas de aprendizado de máquina e inteligência artificial, capazes de identificar padrões complexos em séries temporais, dados climáticos e de sensoriamento remoto (Zhai *et al.*, 2020; Feijó *et al.*, 2021; Steinmetz *et al.*, 2020; Mouratiadou *et al.*, 2023).

A arquitetura dos SSD geralmente é composta por uma base de dados, onde são armazenadas informações de diferentes fontes, uma base de modelos, que processa essas informações por meio de algoritmos e equações, e uma interface que apresenta os resultados de forma acessível ao usuário final. Em sistemas mais modernos, há integração em tempo quase real entre dados coletados por sensores IoT, estações meteorológicas, satélites e plataformas digitais, possibilitando maior dinamismo e rapidez nas respostas. Essa integração, contudo, exige interoperabilidade entre diferentes sistemas, além de infraestrutura tecnológica adequada, o que nem sempre está disponível para pequenos produtores (Souza; Oliveira; Macário, 2020; Mouratiadou *et al.*, 2023; Jadlovská; Paralič; Vaščák, 2023).

Outro aspecto relevante refere-se à usabilidade e às formas de visualização de dados. A eficiência de um SSD depende não apenas da qualidade dos modelos e das bases de dados, mas também da clareza com que as informações são transmitidas. Visualizações em mapas, gráficos interativos e dashboards dinâmicos são recursos que favorecem a compreensão e o uso efetivo dos resultados pelos agricultores, ao mesmo tempo em que permitem comunicar incertezas e cenários alternativos (Gutiérrez *et al.*, 2019).

Apesar dos avanços, ainda existem barreiras significativas para a adoção ampla de SSD. Questões como custos elevados de desenvolvimento e manutenção, dificuldades de interoperabilidade entre diferentes plataformas, necessidade de validação contínua dos modelos e desafios relacionados

à confiança dos usuários limitam a expansão dessas ferramentas em diferentes contextos. Revisões sobre sua aplicação em irrigação, por exemplo, demonstram que, embora tragam ganhos em eficiência no uso da água, fatores como usabilidade e aceitação pelos agricultores são determinantes para seu sucesso (Ara *et al.*, 2021).

### 3 METODOLOGIA

A presente pesquisa caracteriza-se como uma revisão bibliográfica de natureza básica e abordagem qualitativa, com caráter exploratório-descritivo, tendo como finalidade mapear, descrever e analisar modelos de Sistemas de Suporte à Decisão (SSD) aplicados à agricultura de precisão, especialmente em suas aplicações voltadas ao monitoramento climático e à previsão de rendimento agrícola. O estudo parte da premissa de que a agricultura moderna depende cada vez mais de dados e tecnologias inteligentes para sustentar decisões estratégicas e operacionais, sendo os SSD instrumentos centrais nesse processo. Dessa forma, buscou-se compreender como a literatura científica recente tem tratado a integração entre fontes climáticas, sensoriamento remoto e algoritmos preditivos, de modo a identificar tendências, lacunas e desafios para o avanço desses sistemas no contexto agrícola.

As fontes consultadas foram selecionadas em bases de dados científicas amplamente reconhecidas pela qualidade e abrangência multidisciplinar, entre elas Scopus, Web of Science, SciELO, IEEE Xplore e Google Acadêmico, garantindo um levantamento diversificado e representativo das produções nacionais e internacionais sobre o tema. O recorte temporal adotado abrangeu o período de 2015 a 2025, considerando a relevância de estudos contemporâneos em função do rápido avanço das tecnologias de aprendizado de máquina e da expansão da agricultura digital no Brasil e no mundo. Foram incluídos artigos científicos, capítulos de livros, dissertações, teses e documentos técnicos que apresentassem resultados empíricos, metodológicos ou tecnológicos relacionados a SSD, aprendizado de máquina, sensoriamento remoto e agricultura de precisão. Como critérios de exclusão, eliminaram-se trabalhos duplicados, textos sem foco direto no tema ou que não apresentavam informações metodológicas suficientes, bem como publicações sem acesso ao conteúdo integral.

O processo de busca e seleção dos estudos foi conduzido de forma sistemática, utilizando combinações de termos em português e inglês para ampliar a abrangência das consultas. As expressões empregadas nas buscas incluíram, entre outras: (“decision support system” OR “sistema de suporte à decisão”) AND (“precision agriculture” OR “agricultura de precisão”) AND (“yield prediction” OR “rendimento agrícola”) AND (“remote sensing” OR “sensoriamento remoto”) AND (“climate data” OR “dados climáticos”). Após a busca inicial, foi realizada a triagem em três etapas sucessivas: leitura

de títulos e resumos para exclusão de materiais irrelevantes, leitura completa dos textos potencialmente elegíveis e remoção de duplicidades entre bases. Os estudos selecionados tiveram suas informações extraídas de forma padronizada, contemplando variáveis como ano de publicação, país de origem, cultura agrícola estudada, fontes de dados (climáticas ou espectrais), tipo de SSD, algoritmos empregados, métricas de desempenho (RMSE, MAE, R<sup>2</sup>) e principais limitações relatadas.

A síntese dos resultados obtidos foi organizada em uma matriz comparativa, permitindo identificar padrões, convergências e lacunas nos estudos analisados. As evidências foram agrupadas conforme a tipologia dos SSD (baseados em regras, em modelos ou em dados/inteligência artificial), o tipo de fonte de dados utilizada (climática e de sensoriamento remoto) e as famílias de modelos preditivos empregadas (estatísticos, aprendizado de máquina e deep learning). Essa estrutura possibilitou o reconhecimento de tendências metodológicas e tecnológicas, bem como a compreensão das limitações associadas à integração de diferentes tipos de dados nos processos de tomada de decisão agrícola. A análise foi conduzida de forma interpretativa, buscando conectar as abordagens teóricas aos resultados empíricos e estruturando a discussão de acordo com as etapas típicas de um pipeline de SSD, compreendendo a coleta, o processamento, a modelagem e a aplicação prática dos resultados.

Do ponto de vista ético, o estudo enquadra-se como uma pesquisa exclusivamente documental, baseada em informações secundárias e de domínio público, não envolvendo a coleta de dados com seres humanos nem experimentos laboratoriais. Por essa razão, encontra-se dispensado de submissão ao Comitê de Ética em Pesquisa, conforme disposto na Resolução CNS nº 510/2016, que regula estudos nas áreas de Ciências Humanas e Sociais.

## 4 RESULTADOS E DISCUSSÃO

### 4.1 CARACTERIZAÇÃO DO CORPUS

O corpus analisado nesta revisão bibliográfica foi composto por um conjunto representativo de estudos publicados entre os anos de 2015 e 2025, com predominância de trabalhos recentes, o que evidencia o dinamismo e a relevância crescente da temática no contexto da agricultura digital. Verificou-se um aumento expressivo das publicações a partir de 2020, reflexo direto da expansão das tecnologias de aprendizado de máquina, sensoriamento remoto e Internet das Coisas (IoT) aplicadas ao campo agrícola. Essa tendência acompanha a consolidação da Agricultura 4.0, que vem impulsionando o uso de Sistemas de Suporte à Decisão (SSD) para previsão de produtividade, manejo de irrigação e monitoramento ambiental (Zhai *et al.*, 2020; Souza; Oliveira; Macário, 2020).

Em termos geográficos, observou-se uma liderança brasileira na produção científica sobre o tema, com contribuições significativas de instituições como a Embrapa, a Universidade Federal de

Lavras (UFLA) e a Universidade de São Paulo (USP), que têm atuado em rede para integrar dados climáticos, imagens de satélite e algoritmos preditivos em SSD aplicados à agricultura tropical. Além do Brasil, destacaram-se colaborações internacionais, especialmente com universidades da Alemanha, Austrália e Estados Unidos, que vêm desenvolvendo modelos voltados para culturas de larga escala e para o aprimoramento de sistemas híbridos de previsão agrícola (Mouratiadou *et al.*, 2023; von Bloh *et al.*, 2023).

No recorte temático, as culturas agrícolas mais estudadas foram a soja e a cana-de-açúcar, que juntas representaram mais de 60% das investigações revisadas. Essa predominância justifica-se pela relevância econômica e pela ampla disponibilidade de dados históricos dessas culturas no Brasil. Outros cultivos analisados incluíram arroz, milho e café, em menor número, geralmente associados a estudos regionais ou a experimentos locais de integração entre sensores e estações meteorológicas (Steinmetz *et al.*, 2020; Oliveira; Brandão; Rodrigues, 2022).

Quanto à escala de aplicação, observou-se a coexistência de pesquisas locais, voltadas a propriedades ou fazendas experimentais, e de estudos regionais e nacionais, voltados à calibração e à validação de modelos em grandes áreas agrícolas. Essa diversidade metodológica demonstra o avanço da modelagem em múltiplas escalas e a tendência de utilização de bases abertas de clima e sensoriamento remoto, como ERA5, CHIRPS e SATVeg, em conjunto com dados locais coletados via estações meteorológicas automáticas e drones (Schwalbert *et al.*, 2020).

A Tabela 1 apresenta a caracterização sintética dos principais estudos incluídos na revisão, organizados por autor, ano, cultura analisada, local de aplicação, tipo de modelo e fontes de dados utilizadas. Essa estruturação permitiu identificar o avanço das abordagens híbridas, nas quais modelos estatísticos tradicionais são combinados a algoritmos de aprendizado de máquina e dados de sensoriamento remoto, resultando em SSD mais robustos e adaptáveis às variações climáticas e espaciais.

Quadro 1 – Caracterização dos estudos incluídos na revisão

Autor/Ano	Cultura Agrícola	Local/Região	Escala de Aplicação	Tipo de Modelo	Fonte de Dados Utilizada
Wei; Molin (2020)	Soja	Brasil	Local (campo experimental)	Régressão linear múltipla	Variáveis agronômicas e meteorológicas
Pagani <i>et al.</i> (2017)	Cana-de-açúcar	Brasil (Sudeste)	Regional	Modelo fisiológico (CANEGRO)	Indicadores agrometeorológicos
Luciano <i>et al.</i> (2021)	Cana-de-açúcar	Brasil (Nordeste)	Local	Modelo empírico + RS	Sensoriamento remoto (imagens orbitais) e clima
Dos Santos <i>et al.</i> (2022)	Soja	Cerrado (MATOPIBA)	Regional	Machine Learning (RF, SVM, RNA)	Séries climáticas e espectrais
Batistella <i>et al.</i> (2023)	Soja	Sul do Brasil	Regional	Random Forest	Sensores orbitais (NDVI, EVI)
von Bloh <i>et al.</i> (2023)	Soja	Brasil (escala nacional)	Nacional	Ensemble (ML + Clima + RS)	Dados climáticos e de sensoriamento remoto
Bandeira <i>et al.</i> (2024)	Soja	Brasil (Centro-Oeste)	Local	Deep Learning (CNN)	Imagens RGB de vagens/grãos
Schwalbert <i>et al.</i> (2020)	Soja	Sul do Brasil	Regional	LSTM (IA)	Clima + NDVI + RS orbital
. <i>et al.</i> (2021)	Multicultivos	Brasil	Regional	Análise integrada de sensores	Estações meteorológicas + IoT + RS
Embrapa Agricultura Digital (2024)	Multicultivos	Brasil (Amazônia Legal)	Nacional	SSD institucional	SATVeg, Agritempo, AgroAPI (clima + RS)

Fonte: Elaborado pelo autor (2025), com base nos estudos revisados.

A análise dos trabalhos evidencia o protagonismo do Brasil na implementação e desenvolvimento de SSD agrícolas, especialmente no uso de dados integrados de clima e sensoriamento remoto para previsão de produtividade e manejo sustentável. Nota-se também o avanço de metodologias baseadas em aprendizado de máquina e deep learning, que vêm substituindo gradativamente os modelos puramente estatísticos, oferecendo maior acurácia e adaptabilidade. Além disso, a consolidação de sistemas públicos como SATVeg e Agritempo demonstra o fortalecimento da infraestrutura digital agrícola brasileira, tornando o país referência na América Latina em pesquisa aplicada à agricultura de precisão e à análise preditiva.

#### 4.2 TIPOLOGIA E ARQUITETURA DOS SSD AGRÍCOLAS

Os Sistemas de Suporte à Decisão (SSD) no contexto agrícola apresentam uma grande diversidade de estruturas e funções, refletindo a evolução tecnológica e a variedade de demandas no campo. A literatura revisada identifica três tipologias principais de SSD: os baseados em regras, os

baseados em modelos e os baseados em dados e inteligência artificial (IA). Cada tipo possui características, aplicações e limitações próprias, que determinam sua adequação a diferentes contextos produtivos e escalas de operação.

Os SSD baseados em regras representam a forma mais clássica de sistema de decisão, construídos sobre motores de inferência e ontologias que codificam o conhecimento de especialistas em forma de regras condicionais do tipo “se–então”. Esses sistemas utilizam bases de conhecimento estruturadas e permitem ao usuário obter recomendações diretas de manejo a partir de parâmetros previamente definidos. No Brasil, um exemplo relevante é o sistema *@grogest\_Ambiental*, descrito por Feijó *et al.* (2021), que utiliza regras e inferências lógicas para sugerir práticas agrícolas sustentáveis e reduzir o impacto ambiental em propriedades rurais. Essa abordagem é especialmente útil em situações de baixa disponibilidade de dados históricos, pois depende mais do conhecimento técnico consolidado do que de grandes volumes de informação.

Os SSD baseados em modelos utilizam simulações matemáticas e biofísicas para descrever os processos que ocorrem nos sistemas agrícolas, como crescimento vegetal, balanço hídrico e dinâmica de nutrientes. Esses modelos são alimentados por dados experimentais, climáticos e edáficos, permitindo estimar o comportamento das culturas sob diferentes cenários. Um exemplo representativo é o PlanejArroz, desenvolvido pela Embrapa Clima Temperado, que integra modelos de graus-dia e o simulador SimulArroz para apoiar o manejo e estimar a produtividade do arroz irrigado (Steinmetz *et al.*, 2020). Essa categoria de SSD é amplamente utilizada para o planejamento agrícola e análise de risco, sendo capaz de incorporar variáveis meteorológicas e fisiológicas de modo dinâmico.

Os SSD baseados em dados e inteligência artificial são os mais recentes e têm se destacado pela capacidade de processar grandes volumes de informações heterogêneas provenientes de sensores, satélites, estações meteorológicas e bancos de dados históricos. Tais sistemas utilizam algoritmos de aprendizado supervisionado e não supervisionado, como árvores de decisão, redes neurais artificiais, máquinas de vetores de suporte (SVM) e modelos de ensemble, para gerar previsões de produtividade, detecção de anomalias e recomendações de manejo (Zhai *et al.*, 2020; Mouratiadou *et al.*, 2023). Esses SSD possuem maior flexibilidade, podendo aprender padrões a partir dos dados e adaptar-se a novos contextos agrícolas, embora dependam fortemente da qualidade e da disponibilidade das bases de informação.

Em relação à arquitetura dos SSD agrícolas, a literatura descreve uma estrutura modular e hierárquica, geralmente composta por três camadas principais: base de dados, base de modelos e interface de usuário. A camada de dados integra informações provenientes de múltiplas fontes, como sensores in situ, estações meteorológicas, reanálises climáticas, imagens de satélite e dados de solo. A

camada de modelos realiza o processamento e a análise desses dados, por meio de simulações, regressões, algoritmos de aprendizado de máquina ou inferência baseada em regras. Por fim, a camada de interface apresenta os resultados de forma interativa e visual, utilizando dashboards, mapas, gráficos e painéis de controle para apoiar a interpretação dos resultados e a tomada de decisão em tempo quase real (Souza; Oliveira; Macário, 2020).

Os desafios de interoperabilidade e integração em tempo real ainda são pontos críticos no desenvolvimento de SSD agrícolas. Segundo Jadlovská, Paralič e Vaščák (2023), a compatibilidade entre sistemas heterogêneos e o fluxo contínuo de dados exigem arquiteturas mais flexíveis, capazes de conectar múltiplas fontes e formatos sem perda de desempenho. Além disso, há a necessidade de padronização de protocolos e interfaces para permitir a comunicação entre plataformas, o que se torna essencial à medida que o setor agrícola adota soluções baseadas em Internet das Coisas (IoT) e computação em nuvem.

A Quadro 2 apresenta um resumo das principais fontes de dados e formas de integração utilizadas em SSD agrícolas, conforme identificado nos estudos revisados. Essa síntese evidencia a tendência de convergência entre dados climáticos, sensoriamento remoto e modelagem inteligente, consolidando o conceito de agricultura digital orientada por dados.

Quadro 2 – Fontes de dados e integração em Sistemas de Suporte à Decisão agrícolas

<b>Tipo de SSD</b>	<b>Exemplo / Referência</b>	<b>Fontes de Dados Utilizadas</b>	<b>Forma de Integração</b>	<b>Finalidade Principal</b>
Baseado em regras	Feijó <i>et al.</i> (2021)	Dados de solo, clima e práticas agrícolas	Ontologia e motor de inferência	Recomendação de manejo ambiental
Baseado em modelos	Steinmetz <i>et al.</i> (2020)	Séries meteorológicas, dados fenológicos e de solo	Modelagem biofísica (SimulArroz)	Planejamento de safra e previsão de produtividade
Baseado em dados/IA	Zhai <i>et al.</i> (2020); Mouratiadou <i>et al.</i> (2023)	Dados de sensores, satélites, IoT e históricos climáticos	Algoritmos de aprendizado de máquina e IA	Predição de rendimento e otimização de insumos
Arquitetura integrada	Souza; Oliveira; Macário (2020)	Multicamadas de dados agrícolas (clima, RS, IoT)	Base de dados + base de modelos + interface	Integração em tempo real e visualização de resultados
Modelo de interoperabilidade	Jadlovská; Paralič; Vaščák (2023)	Dados climáticos e agronômicos de múltiplos provedores	Pipeline distribuído e conversão automática	Interoperabilidade entre plataformas agrícolas

Fonte: Elaborado pelo autor (2025), com base nos estudos revisados.

A análise permite inferir que a tendência atual da agricultura digital é a hibridização das abordagens, unindo características dos SSD baseados em regras, modelos e dados em sistemas únicos, interoperáveis e dinâmicos. Esses sistemas combinam a confiabilidade das simulações biofísicas com

a adaptabilidade dos algoritmos de IA, tornando-se ferramentas cada vez mais indispensáveis para o planejamento agrícola e a mitigação de riscos climáticos. Além disso, observa-se uma crescente incorporação de arquiteturas em nuvem e de interfaces móveis, que democratizam o acesso à tecnologia e aproximam o produtor rural da tomada de decisão orientada por dados.

#### 4.3 MONITORAMENTO CLIMÁTICO E SENSORIAMENTO REMOTO NOS SSD

O monitoramento climático e o sensoriamento remoto (SR) constituem componentes estruturantes dos Sistemas de Suporte à Decisão (SSD) aplicados à agricultura de precisão, pois fornecem dados atmosféricos e espectrais contínuos, espacializados e de alta resolução temporal, fundamentais para caracterizar condições ambientais, identificar estresses e apoiar a modelagem produtiva. A literatura recente destaca que a integração entre múltiplas fontes, estações meteorológicas, redes IoT agrícolas, plataformas de reanálise climática e séries temporais orbitais, fortalece a capacidade dos SSD de representar a variabilidade espacial e temporal dos sistemas agrícolas, consolidando a transição para uma agricultura digital orientada por dados (Queiroz *et al.*, 2021).

Os dados climáticos utilizados em SSD geralmente derivam de estações meteorológicas automáticas e de bases globais de reanálise, como ERA5 e CHIRPS, que fornecem séries temporais de temperatura, precipitação, radiação solar, umidade e vento. A literatura demonstra que a combinação entre medições locais e fontes globais tende a melhorar a acurácia de modelos e indicadores agrometeorológicos, favorecendo sua aplicabilidade operacional. Esse processo tem sido potencializado pela incorporação de sensores IoT no campo, que permitem o monitoramento em tempo real de microclimas e viabilizam aplicações como controle remoto de irrigação, detecção precoce de estresse hídrico e gestão automatizada de ambientes agrícolas (Kamienski *et al.*, 2019).

No âmbito do sensoriamento remoto, índices espectrais derivados de imagens orbitais ou captadas por drones, como NDVI, EVI e VARI, são amplamente utilizados para estimar vigor vegetativo, biomassa e estado nutricional das plantas. Os estudos analisados evidenciam que plataformas aéreas (VANTS) complementam as imagens orbitais ao oferecer diagnósticos de alta resolução para mapeamentos topográficos, detecção de anomalias e apoio a práticas de manejo localizado (Amaral *et al.*, 2021). A integração entre esses produtos espectrais e dados climáticos permite análises multiescalares essenciais para prever o desempenho das culturas durante o ciclo produtivo.

Iniciativas institucionais brasileiras têm desempenhado papel estratégico nesse processo. A Embrapa Agricultura Digital (2024) destaca plataformas como SATVeg, Agritempo e AgroAPI, que consolidam séries históricas e dados atualizados de clima e vegetação. O SATVeg integra índices de

vegetação derivados de satélite para monitoramento temporal da cobertura vegetal; o Agritempo fornece indicadores agrometeorológicos e previsões climáticas; e o AgroAPI disponibiliza serviços padronizados para integração automatizada de dados em SSD. Essas ferramentas ampliam a capacidade de monitorar áreas de elevada sensibilidade ambiental, como a Amazônia e o Cerrado, facilitando a aplicação operacional dos SSD em regiões sujeitas à forte variabilidade pluviométrica.

A síntese dos estudos revela que a integração entre dados climáticos e espectrais constitui um dos avanços mais expressivos da agricultura de precisão contemporânea. A consolidação de plataformas interoperáveis e automatizadas viabiliza a coleta, o processamento e a análise de dados em tempo quase real, permitindo a construção de SSD mais responsivos, precisos e escaláveis. Além disso, a crescente maturidade de sistemas públicos de monitoramento amplia o acesso de produtores e técnicos a informações qualificadas, fortalecendo a sustentabilidade produtiva e a resiliência climática em diferentes contextos agrícolas.

Quadro 3 – Fontes de dados climáticos e espectrais integradas em SSD agrícolas

Fonte de Dados	Tipo de Informação	Plataforma / Origem	Frequência / Resolução	Aplicação nos SSD	Referência
Estações meteorológicas automáticas	Temperatura, precipitação, umidade, vento	INMET / redes locais	Horária a diária	Monitoramento de clima e calibração de modelos	Queiroz <i>et al.</i> (2021)
Reanálises climáticas (ERA5, CHIRPS)	Séries históricas e dados espaciais de precipitação e temperatura	ECMWF / NASA / NOAA	Horária a mensal / 0,1°–0,25°	Modelagem climática e previsão agrometeorológica	Queiroz <i>et al.</i> (2021)
Sensores IoT agrícolas	Dados microclimáticos e de solo (umidade, temperatura, condutividade)	Plataformas IoT e redes LoRa / NB-IoT	Minutal a horária	Irrigação de precisão e controle remoto	Kamienski <i>et al.</i> (2019)
Sensoriamento remoto orbital (satélites)	Índices NDVI, EVI, VARI, biomassa, vigor vegetativo	MODIS, Sentinel-2, Landsat-8	5 a 16 dias / 10–250 m	Monitoramento de vegetação e estimativa de produtividade	Amaral <i>et al.</i> (2021)
Drones (VANTS)	Imagens RGB e multiespectrais de alta resolução	DJI, Parrot, senseFly	Sob demanda / 2–10 cm	Diagnóstico de estresse, mapeamento de zonas de manejo	Amaral <i>et al.</i> (2021)
SATVeg	Séries temporais de índices espectrais (NDVI, EVI)	EMBRAPA / INPE	Semanal / nacional	Monitoramento de culturas e cobertura vegetal	EMBRAPA AGRICULTURA DIGITAL (2024)
Agritempo	Dados climáticos e risco	EMBRAPA / INMET	Diário	Supporte à tomada de decisão climática	EMBRAPA AGRICULTURA DIGITAL (2024)

	agrometeorológico				
AgroAPI	Integração de dados climáticos e espectrais via API	EMBRAPA	Em tempo real	Fornecimento de dados a SSD externos e privados	EMBRAPA AGRICULTURA DIGITAL (2024)

Fonte: Elaborado pelo autor (2025), com base nos estudos revisados.

#### 4.4 PREDIÇÃO DE RENDIMENTO: MODELOS, DESEMPENHO E TRADE-OFFS

A predição de rendimento agrícola constitui uma das aplicações mais consolidadas e estratégicas dos Sistemas de Suporte à Decisão (SSD), sendo amplamente explorada pela literatura recente em razão de seu impacto no planejamento produtivo, na gestão de riscos e na alocação eficiente de recursos. Os estudos analisados destacam duas grandes famílias de abordagens: os modelos estatísticos tradicionais e os modelos baseados em aprendizado de máquina, além de arquiteturas profundas que vêm ganhando relevância com o avanço das tecnologias de sensoriamento remoto.

Os modelos estatísticos foram historicamente os primeiros a serem utilizados em predição de produtividade, aplicando regressões lineares, múltiplas e séries temporais para correlacionar variáveis climáticas e agronômicas ao rendimento. Embora conceitualmente simples, essas abordagens permanecem úteis quando se busca interpretabilidade ou quando a disponibilidade de dados é limitada. Os estudos incluídos na revisão ressaltam que equações baseadas em componentes do rendimento, como número de grãos e massa de mil sementes, podem alcançar resultados satisfatórios, com  $R^2$  em torno de 0,70 e MAE próximo de  $640 \text{ kg ha}^{-1}$  (Wei; Molin, 2020). Modelos fisiológicos, como o CANEGRO, também se destacam ao representar processos ecofisiológicos e capturar variações temporais e espaciais do crescimento de culturas como cana-de-açúcar (Pagani et al., 2017).

A literatura recente, entretanto, evidencia uma migração para abordagens mais robustas, baseadas em aprendizado de máquina (Machine Learning – ML). Métodos como Random Forest (RF), Support Vector Machines (SVM), redes neurais artificiais (RNA) e algoritmos ensemble apresentam desempenho superior por lidarem melhor com não linearidades, colinearidade entre variáveis e grandes volumes de dados heterogêneos. Em estudos conduzidos no Cerrado brasileiro, algoritmos de ML superaram modelos lineares e polinomiais, alcançando valores de  $R^2$  de 0,81 e RMSE de  $176,93 \text{ kg ha}^{-1}$  com o uso de Random Forest (Dos Santos et al., 2022). Resultados similares foram observados em aplicações que incorporaram dados de sensores orbitais, reforçando que métodos baseados em árvores conseguem explorar padrões espectrais e climáticos de forma mais eficiente (Batistella et al., 2023).

O uso de deep learning vem ampliando ainda mais o potencial preditivo dos SSD. Redes neurais convolucionais (CNN), por exemplo, têm sido aplicadas à análise de imagens RGB obtidas por

smartphones, possibilitando estimativas de rendimento com erros inferiores a 10% (Bandeira et al., 2024). Em estudos de maior escala, modelos que integram dados climáticos, espectrais e de manejo agrícola foram capazes de prever rendimento de soja meses antes da colheita, apresentando erros relativos de apenas 6% (von Bloh et al., 2023). Esses achados demonstram que arquiteturas profundas conseguem extrair informações espaciais e texturais diretamente das imagens, reduzindo a necessidade de grandes conjuntos de variáveis auxiliares e aumentando a escalabilidade operacional.

A comparação entre métodos exige o uso de métricas apropriadas, como RMSE, MAE e R<sup>2</sup>, que permitem avaliar o ajuste, a magnitude dos erros e a confiabilidade dos modelos. Os estudos incluídos convergem ao mostrar que modelos estatísticos costumam apresentar maior interpretabilidade, enquanto algoritmos de Machine Learning (ML) e Deep Learning (DL) fornecem melhor desempenho preditivo, principalmente quando trabalham com dados espectrais combinados a séries climáticas.

Outro aspecto central identificado na literatura refere-se às estratégias de validação, essenciais para evitar a superestimação da acurácia. Em aplicações envolvendo dados agroclimáticos e geoespaciais, validações tradicionais, como k-fold aleatório, podem gerar vieses devido à autocorrelação espacial ou temporal. Assim, autores como Roberts et al. (2017) recomendam validações espaciais e temporais, que respeitam a estrutura dos dados e testam a capacidade de generalização dos modelos em diferentes regiões ou ciclos produtivos. Essa abordagem é particularmente relevante em regiões de clima altamente variável, como as áreas agrícolas do Cerrado e da Amazônia.

De maneira geral, os estudos analisados indicam uma tendência crescente à integração de abordagens híbridas, combinando modelos biofísicos de simulação com algoritmos de aprendizado de máquina. Essa estratégia busca equilibrar o *trade-off* entre interpretabilidade, custo computacional e desempenho preditivo, oferecendo soluções mais robustas e aplicáveis em diferentes escalas espaciais. A convergência entre dados climáticos, sensoriamento remoto e técnicas computacionais avançadas configura o caminho mais promissor para aprimorar a precisão e a confiabilidade dos SSD voltados à predição de rendimento no contexto agrícola brasileiro.

#### 4.5 LIMITAÇÕES RECORRENTES E OPORTUNIDADES DE PESQUISA

A revisão da literatura permitiu identificar um conjunto de limitações recorrentes que ainda restringem a aplicabilidade e a eficiência dos Sistemas de Suporte à Decisão (SSD) na agricultura de precisão, especialmente em regiões tropicais e de elevada variabilidade ambiental, como a Amazônia e o Centro-Oeste brasileiros. Essas limitações estão associadas à qualidade dos dados, à generalização

espaço-temporal dos modelos, aos custos de implementação tecnológica e à necessidade de calibração e explicabilidade das soluções de inteligência artificial.

Uma das principais restrições encontradas refere-se às lacunas e inconsistências nas bases de dados agrícolas. Em muitos casos, as séries históricas de variáveis meteorológicas são curtas ou apresentam falhas de registro devido à escassez de estações automáticas e à cobertura desigual das redes de monitoramento. Além disso, as imagens de sensoriamento remoto podem ser comprometidas por cobertura de nuvens, especialmente em regiões de clima úmido, reduzindo a frequência e a qualidade das observações. Essas deficiências comprometem a calibração dos modelos e a acurácia das previsões. Segundo dos Santos Silva *et al.* (2023), a comparação entre diferentes fontes de dados de precipitação na Amazônia Legal revelou discrepâncias significativas entre produtos de reanálise, como o ERA5-Land e o CHIRPS, destacando a necessidade de validação local e ajustes regionais antes de seu uso operacional em SSD.

Outro desafio crítico está relacionado à generalização espaço-temporal dos modelos preditivos, ou seja, à capacidade de um modelo calibrado em uma região ou cultura ser transferido para outro contexto com desempenho satisfatório. Essa limitação decorre da variabilidade nas práticas agrícolas, nas condições edafoclimáticas e na qualidade dos dados de entrada. Roberts *et al.* (2017) destacam que, sem estratégias adequadas de validação cruzada, os modelos podem apresentar sobreajuste e desempenho artificialmente elevado, o que reduz sua confiabilidade em aplicações reais. Essa fragilidade é agravada pela ausência de padronização de protocolos de treinamento e validação nos estudos agrícolas, dificultando a comparação direta entre resultados de diferentes pesquisas.

Os custos de implementação e a infraestrutura tecnológica também se configuraram como barreiras à adoção ampla de SSD, especialmente entre pequenos e médios produtores. A limitação de conectividade em áreas rurais e o custo elevado de equipamentos de sensoriamento e armazenamento em nuvem dificultam a operacionalização dos sistemas em tempo real. Kamienski *et al.* (2019) apontam que, embora as plataformas baseadas em IoT tenham reduzido significativamente o custo de sensores e dispositivos, ainda há desafios de interoperabilidade e escalabilidade, principalmente em regiões com baixa cobertura de rede móvel.

Por fim, destaca-se a necessidade de calibração local e de modelos explicáveis (XAI - Explainable Artificial Intelligence), que permitam interpretar as decisões tomadas pelos algoritmos e compreender as variáveis que mais influenciam os resultados. A falta de transparência de alguns modelos de aprendizado profundo dificulta a validação científica e a aceitação por parte dos técnicos e produtores, que necessitam de explicações claras sobre as recomendações geradas pelos SSD. O desenvolvimento de modelos híbridos, capazes de combinar conhecimento agronômico com inferência

estatística e aprendizado de máquina, representa uma oportunidade promissora para superar essa limitação e aumentar a confiabilidade dos sistemas.

Portanto, o avanço dos SSD no Brasil depende diretamente de investimentos em infraestrutura digital, ampliação das bases de dados públicas e integradas, e capacitação técnica dos profissionais envolvidos no manejo agrícola. A criação de repositórios padronizados, o incentivo à adoção de protocolos abertos e o fortalecimento de parcerias entre universidades, órgãos públicos e setor privado são caminhos estratégicos para consolidar o país como referência em agricultura de precisão e inovação tecnológica aplicada ao campo. Essas ações são fundamentais para tornar os SSD ferramentas efetivas de planejamento, mitigação de riscos climáticos e aumento sustentável da produtividade agrícola.

## 5 CONSIDERAÇÕES FINAIS

O presente estudo teve como objetivo geral analisar e sistematizar os modelos de Sistemas de Suporte à Decisão (SSD) aplicáveis à agricultura de precisão, com ênfase em suas aplicações no monitoramento climático e na predição de rendimento agrícola. A partir da revisão bibliográfica realizada entre 2015 e 2025, verificou-se que a área tem passado por um processo contínuo de inovação tecnológica, impulsionado pela expansão da agricultura digital e pelo avanço das ferramentas de inteligência artificial e sensoriamento remoto. Os objetivos específicos foram plenamente atendidos, uma vez que a revisão permitiu compreender as principais tipologias de SSD, as fontes de dados mais empregadas, os modelos preditivos mais eficazes e os desafios que ainda limitam sua aplicação em larga escala.

Os resultados revelaram que a consolidação dos modelos de SSD agrícolas ocorre em três vertentes principais: sistemas baseados em regras, baseados em modelos e baseados em dados e inteligência artificial. Os modelos baseados em regras, como o sistema @grogest\_Ambiental, continuam sendo valiosos para o manejo orientado por conhecimento técnico e normas ambientais, especialmente em contextos de baixa disponibilidade de dados. Já os modelos baseados em simulações biofísicas, como o PlanejArroz, se destacam pela capacidade de integrar variáveis fisiológicas e climáticas, oferecendo subsídios para o planejamento agrícola e a previsão de estádios fenológicos. Por sua vez, os modelos baseados em dados e aprendizado de máquina emergem como a principal tendência da atualidade, permitindo previsões mais precisas e adaptáveis por meio do uso de algoritmos como Random Forest, Support Vector Machines e redes neurais profundas.

A revisão também evidenciou as tendências tecnológicas mais relevantes no campo da agricultura de precisão, especialmente a integração de aprendizado de máquina e sensoriamento remoto. As pesquisas analisadas demonstraram que a combinação de imagens orbitais, índices

espectrais (NDVI, EVI, VARI) e variáveis meteorológicas tem potencial para gerar modelos altamente acurados de previsão de rendimento. Estudos recentes, como os de Dos Santos et al. (2022), Bandeira et al. (2024) e von Bloh et al. (2023), confirmam a superioridade de abordagens baseadas em inteligência artificial em relação aos modelos estatísticos tradicionais, atingindo valores de  $R^2$  superiores a 0,80 e erros relativos inferiores a 10% em culturas como soja e cana-de-açúcar. Esses resultados indicam que os SSD modernos tendem a evoluir para plataformas híbridas, combinando o rigor dos modelos biofísicos com a flexibilidade e o poder de generalização dos algoritmos de aprendizado de máquina.

Outro achado importante refere-se à integração entre dados climáticos e espectrais como fator determinante para o avanço da predição agrícola. A utilização conjunta de informações provenientes de estações meteorológicas automáticas, redes IoT, reanálises climáticas (ERA5, CHIRPS) e sensoriamento remoto possibilita a construção de SSD mais robustos e responsivos. No Brasil, destacam-se as plataformas públicas SATVeg, Agritempo e AgroAPI, desenvolvidas pela Embrapa, que têm contribuído para a democratização do acesso a dados agrícolas e para o fortalecimento da agricultura digital. Essas iniciativas são fundamentais para regiões de alta variabilidade climática, como a Amazônia e o Centro-Oeste, onde a disponibilidade de dados confiáveis é um requisito essencial para a previsão de safras e o manejo adaptativo das lavouras.

Apesar dos avanços observados, a revisão também identificou limitações persistentes que restringem o pleno aproveitamento dos SSD no setor agrícola. Entre elas, destacam-se as lacunas de dados meteorológicos e espectrais, a heterogeneidade das condições edafoclimáticas, os altos custos de implementação tecnológica e a necessidade de calibração local dos modelos. Além disso, a opacidade de certos algoritmos de inteligência artificial levanta preocupações quanto à explicabilidade e transparência dos resultados, o que reforça a importância de desenvolver abordagens de Inteligência Artificial Explicável (XAI), capazes de justificar suas previsões de forma comprehensível para técnicos e produtores.

Como perspectiva futura, aponta-se a necessidade de investir em validações multi-safra e multi-região, de modo a aumentar a confiabilidade dos modelos e permitir sua replicação em diferentes contextos produtivos. Recomenda-se, ainda, o fortalecimento das infraestruturas digitais rurais, a ampliação das bases públicas de dados integrados e a capacitação técnica de profissionais e agricultores no uso de ferramentas de agricultura digital. Essas ações são essenciais para viabilizar o uso efetivo dos SSD em todo o território brasileiro e para consolidar o país como referência em inovação agroambiental.

Por fim, destaca-se que este estudo contribui de forma prática ao oferecer uma síntese crítica e atualizada sobre os modelos de SSD para agricultura de precisão, podendo servir como guia de referência para pesquisadores, extensionistas, técnicos e produtores rurais. Ao apresentar uma visão integrada das tecnologias disponíveis, dos desafios e das perspectivas, a pesquisa reforça a importância de uma agricultura orientada por dados, mais eficiente, sustentável e resiliente às mudanças climáticas, especialmente nas regiões de clima tropical e elevada variabilidade, como a Amazônia e o Centro-Oeste do Brasil.

## REFERÊNCIAS

- AMARAL, L. R.; ZERBATO, C.; FREITAS, R.; BARBOSA JUNIOR, M.; SIMÕES, I. O. UAV applications in Agriculture 4.0. **Revista Ciência Agronômica**, v. 51, edição especial, 2021. Disponível em: <https://periodicos.ufc.br/revistacienciaagronomica/article/view/84923>. Acesso em: 18 set. 2025.
- ARA, I.; HTUN, N. N.; GUTIÉRREZ, F.; SCHLENZ, F.; KASIMATI, A.; VERBERT, K. Application, adoption and opportunities for improving decision support systems in irrigated agriculture: a review. **Agricultural Water Management**, v. 257, 107161, 2021. Disponível em: <https://espace.library.uq.edu.au/view/UQ:d64ba78>. Acesso em: 18 set. 2025.
- ASSAD, E. D.; ASSAD, M. L. R. C. L. Mudanças do clima e agropecuária: impactos, mitigação e adaptação – desafios e oportunidades. **Estudos Avançados**, v. 38, n. 112, p. 271–292, 2024. DOI: 10.1590/s0103-4014.202438112.015. Disponível em: <https://www.scielo.br/j/ea/a/jJP56TJd4ZCKvQ4YmPhXgCk/>. Acesso em: 18 set. 2025.
- BANDEIRA, P. M. C.; VILLAR, F. M. M.; PINTO, F. A. C.; SILVA, F. L.; BANDEIRA, P. P. C. Soybean crop yield estimation using artificial intelligence techniques. **Acta Scientiarum. Agronomy**, v. 46, n. 1, e67040, 2024. Disponível em: <https://periodicos.uem.br/ojs/index.php/ActaSciAgron/article/view/67040>. Acesso em: 18 set. 2025.
- BATISTELLA, D.; MODOLO, A. J.; CAMPOS, J. R. R.; LIMA, V. A. Comparative analysis of orbital sensors for estimating soybean yield using Random Forest. **Ciência e Agrotecnologia**, v. 47, e022223, 2023. DOI: 10.1590/1413-7054-202300100220. Disponível em: <https://www.scielo.br/j/cagro/a/B4ZDQZFqZY4tQsKVmtHbZNM/>. Acesso em: 18 set. 2025.
- BRASIL. Conselho Nacional de Saúde. *Resolução nº 510, de 7 de abril de 2016*. Dispõe sobre as normas aplicáveis a pesquisas em Ciências Humanas e Sociais. *Diário Oficial da União*, Brasília, DF, 24 maio 2016, Seção 1, p. 44. Disponível em: <https://www.gov.br/conselho-nacional-de-saude/pt-br/atos-normativos/resolucoes/2016/resolucao-no-510.pdf>. Acesso em: 14 nov. 2025.
- CAVALCANTE, R. B. L.; COELHO, G.; ALVALÁ, R. C.; SOUZA, E. B.; COSTA, L. C.; OLIVEIRA, C. P. Evaluation of extreme rainfall indices from CHIRPS precipitation estimates over the Brazilian Amazonia. **Atmospheric Research**, v. 238, 104879, 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0169809519314073>. Acesso em: 18 set. 2025.
- COPERNICUS CLIMATE CHANGE SERVICE (C3S). *ERA5: Fifth generation of ECMWF atmospheric reanalyses of the global climate*. [S. l.]: .: Copernicus Climate Change Service, 2017-. Disponível em: <https://cds.climate.copernicus.eu/>. Acesso em: 14 nov. 2025.
- DOS SANTOS, V. B.; DOS SANTOS, A. M. F.; MORAES, J. R. S. C.; VIEIRA, I. C. O.; ROLIM, G. S. Machine learning algorithms for soybean yield forecasting in the Brazilian Cerrado. **Journal of the Science of Food and Agriculture**, v. 102, n. 9, p. 3665–3672, 2022. DOI: 10.1002/jsfa.11713. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/34893984/>. Acesso em: 14 set. 2025.
- DOS SANTOS SILVA, F. D.; CAVALCANTE, R. M.; LIMA, J. C. S.; MOURA, M. S. B.; LOPES, A. M.; MOURA, G. B. A. Intercomparison of Different Sources of Precipitation Data in the Brazilian Legal Amazon. **Climate**, v. 11, n. 12, 241, 2023. DOI: 10.3390/cli11120241. Disponível em: <https://www.mdpi.com/2225-1154/11/12/241>. Acesso em: 14 set. 2025.
- EMBRAPA AGRICULTURA DIGITAL. Agricultura digital, inovação e aplicações. Capítulo 2. Campinas: Embrapa, 2024. Disponível em:

<https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1166995/1/PL-Agricultura-digital-2024.pdf>. Acesso em: 18 set. 2025.

**EMBRAPA. Agritempo – Sistema de Monitoramento Agrometeorológico.** [S. l.]: Embrapa, [s. d.]. Disponível em: <https://www.agritempo.gov.br/>. Acesso em: 14 nov. 2025.

**EMBRAPA. AgroAPI – Plataforma de APIs.** [S. l.]: Embrapa, [s. d.]. Disponível em: <https://www.agroapi.cnptia.embrapa.br/portal/>. Acesso em: 14 nov. 2025.

**EMBRAPA INFORMÁTICA AGROPECUÁRIA. Sistema de análise temporal da vegetação: SATVeg.** Campinas, 2016. Disponível em: <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1063350>. Acesso em: 14 nov. 2025.

FEIJÓ, T.; DAVID, J. M.; BRAGA, R.; OTENIO, M. H.; PAULA, V. R.; SANTOS, G. M.; CAMPOS, F.; STROELE, V. @grogest\_Ambiental: A Web-based Decision Support System for agribusiness. In: WebMedia '21 – Brazilian Symposium on Multimedia and the Web. New York: ACM, 2021. Disponível em:  
<https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1138154/1/grogest-Ambiental.pdf>. Acesso em: 19 set. 2025.

FREITAS, A. A. de; CARVALHO, V. S. B.; REBOITA, M. S. Extreme Precipitation Events During the Wet Season of the South America Monsoon: A Historical Analysis over Three Major Brazilian Watersheds (inclui Bacia do Madeira). **Climate**, v. 12, n. 11, 188, 2024. DOI: 10.3390/cli12110188. Disponível em: <https://www.mdpi.com/2225-1154/12/11/188>. Acesso em: 19 set. 2025.

GUNDIM, A. da S.; MELO, V. G. M. L.; COELHO, R. D.; SILVA, J. P.; ROCHA, M. P. A.; FRANÇA, A. C. F.; CONCEIÇÃO, A. M. P. Precision irrigation trends and perspectives: a review. **Ciência Rural**, v. 53, n. 8, e20220155, 2023. DOI: 10.1590/0103-8478cr20220155. Disponível em: <https://www.scielo.br/j/cr/a/bFcjn9tdSmdhkbRCxdpthtx/abstract/?lang=pt>. Acesso em: 19 set. 2025.

GUTIÉRREZ, F.; HTUN, N. N.; SCHLENZ, F.; KASIMATI, A.; VERBERT, K. A Review of Visualisations in Agricultural Decision Support Systems: an HCI Perspective. **Zenodo**, 2019. DOI: 10.5281/zenodo.3267196. Disponível em: <https://doi.org/10.5281/zenodo.3267196>. Acesso em: 19 set. 2025.

INAMASU, R. Y.; BERNARDI, A. C. de C.; VAZ, C. M. P.; PIRES, J. L. F.; GEBLER, L.; JORGE, L. A. de C.; BASSOI, L. H. Agricultura de precisão: perspectiva histórica e de constante transformação. In: Agricultura de precisão: um novo olhar na era digital. Campinas: **Embrapa/Editoracubo**, 2024. Disponível em:  
<https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1171030/1/P-Agricultura-de-precisao-perspectiva-historica-e-de-constante-transformacao.pdf>. Acesso em: 20 set. 2025.

JADLOVSKÁ, S.; PARALIČ, J.; VAŠČÁK, J. Architecture of an Agricultural Data Aggregation and Conversion Model. **Applied Sciences**, v. 13, n. 8, 5157, 2023. Disponível em:  
<https://www.mdpi.com/2076-3417/13/8/5157>. Acesso em: 20 set. 2025.

KAMIENSKI, C.; LORENZONI, G.; PINTO, T.; SANTOS, J.; PRADO, A.; JACOB, E.; SOUTO, E.; OLIVEIRA, J.; TODESCO, J.; TORRES, H. Smart Water Management Platform: IoT-Based Precision Irrigation for Agriculture. **Sensors**, v. 19, n. 2, 276, 2019. DOI: 10.3390/s19020276. Disponível em: <https://www.mdpi.com/1424-8220/19/2/276>. Acesso em: 20 set. 2025.

LUCIANO, A. C. dos S.; PICOLI, M. C. A.; DUFT, D. G.; ROCHA, J. V.; LEAL, M. R. L. V.; LE MAIRE, G. Empirical model for forecasting sugarcane yield on a local scale. **Computers and**

**Electronics in Agriculture**, v. 181, 105951, 2021. Disponível em:  
<https://ideas.repec.org/a/eee/agisys/v154y2017icp45-52.html>. Acesso em: 20 set. 2025.

MOLIN, J. P. Agricultura de precisão: um novo olhar na era digital. Campinas: **Embrapa/Editora Cubo**, 2024. DOI: 10.4322/978-65-86819-38-0.1000093. Disponível em:  
<https://doi.editoracubo.com.br/10.4322/978-65-86819-38-0.1000093>. Acesso em: 21 set. 2025.

MOURATIADOU, I.; BEEREN, J. E.; BURBACH, L.; HEILAND, S.; HOPFENSPITZ, A.; JUNGANDREAS, A.; KIESE, R.; KRUG, A.; NIKOLIC, O.; PIRO, F.; STURM, C.; TSCHULIK, K.; ZANDER, P. The Digital Agricultural Knowledge and Information System (DAKIS): Employing digitalisation to encourage diversified and multifunctional agricultural systems. **Environmental Science & Ecotechnology**, v. 16, 100274, 2023. Disponível em:  
<https://pmc.ncbi.nlm.nih.gov/articles/PMC10188627/>. Acesso em: 21 set. 2025.

MOURATIADOU, I.; BEEREN, J. E.; BURBACH, L.; HEILAND, S.; HOPFENSPITZ, A.; JUNGANDREAS, A.; KIESE, R.; KRUG, A.; NIKOLIC, O.; PIRO, F.; STURM, C.; TSCHULIK, K.; ZANDER, P. The Digital Agricultural Knowledge and Information System (DAKIS): Employing digitalisation to encourage diversified and multifunctional agricultural systems. *Environmental Science & Ecotechnology*, v. 16, 100274, 2023. Disponível em:  
<https://pmc.ncbi.nlm.nih.gov/articles/PMC10188627/>. Acesso em: 21 set. 2025.

OLIVEIRA, R. P.; BRANDÃO, Z. N.; RODRIGUES, H. M. Técnicas de Agricultura de Precisão para criação de Zonas de Manejo usando sensores proximais e software R na Fazenda Pamplona (Cristalina-GO). Brasília: **Embrapa**, 2022. (Série Documentos, 201). Disponível em:  
<https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1151214/1/Tecnicas-de-agricultura-de-precisao-para-criacao-de-zonas-de-manejo-2022.pdf>. Acesso em: 21 set. 2025.

PAGANI, V.; STELLA, T.; GUARNERI, T.; FINOTTO, G.; VAN DEN BERG, M.; MARIN, F. R.; ACUTIS, M.; CONFALONIERI, R. Forecasting sugarcane yields using agro-climatic indicators and the CANEGRO model: A case study in the main production region in Brazil. **Agricultural Systems**, v. 154, p. 45–52, 2017. Disponível em: <https://ideas.repec.org/a/eee/agisys/v154y2017icp45-52.html>. Acesso em: 21 set. 2025.

QUEIROZ, D. M.; COELHO, A. L. F.; VALENTE, D. S. M.; SCHUELLER, J. K. Sensors applied to Digital Agriculture: A review. **Revista Ciência Agronômica**, v. 51, ed. especial, e20207751, 2021. DOI: 10.5935/1806-6690.20200086. Disponível em:  
<https://periodicos.ufc.br/revistacienciaagronomica/article/download/84917/229069/321411>. Acesso em: 11 set. 2025.

ROBERTS, D. R.; BAHN, V.; CIUTI, S.; BOYCE, M. S.; ELITH, J.; GUI, L.; GUTIERREZ, R. J.; HASTIE, T.; HÖLTING, L.; HRABÁLKOVÁ, P.; KISLING, W. D.; LEHMANN, A.; LUOTO, M.; MCDougald, R.; NILSSON, M.; OPPEL, S.; OSBORNE, P. E.; REINEKING, B.; RENNER, I.; THUILLER, W.; WIEGAND, T.; WINTLE, B. A.; WOHNOUTKA, P.; ZURELL, D.; DORMANN, C. F. Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure. **Ecography**, v. 40, n. 8, p. 913–929, 2017. Disponível em:  
[https://www.wsl.ch/lud/biodiversity\\_events/papers/Roberts\\_et\\_al-2017-Ecography.pdf](https://www.wsl.ch/lud/biodiversity_events/papers/Roberts_et_al-2017-Ecography.pdf). Acesso em: 11 set. 2025.

SCHWALBERT, R. A.; AMADO, T. J. C.; CORASSA, G. M.; PIRES, J. L. F.; VENDRUSCOLO, E. P.; DELLA FLORA, L. P.; KAUFMANN, M. S.; HORBE, T. A. N.; GOMES, J. Satellite-based soybean yield forecast: Integrating machine learning and weather data for improving crop yield prediction in southern Brazil. **Agricultural and Forest Meteorology**, v. 284, 107886, 2020.

Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168192319305027>. Acesso em: 11 set. 2025.

SOARES FILHO, R.; CUNHA, J. P. A. R. Agricultura de precisão: particularidades de sua adoção no sudoeste de Goiás – Brasil. **Engenharia Agrícola**, v. 35, n. 4, p. 689–698, 2015. DOI: 10.1590/1809-4430-Eng.Agric.v35n4p689-698/2015. Disponível em: <https://www.scielo.br/j/eagri/a/PSDTZRmBFrCdxTsJFwSVbZm/abstract/?lang=pt>. Acesso em: 23 set. 2025.

SOUZA, K. X. S.; OLIVEIRA, S. R. M.; MACÁRIO, C. G. N. Agricultura digital: definições e tecnologias. In: MASSRUHÁ, S. M. F. S.; et al. (org.). Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas. Brasília, DF: **Embrapa**, 2020. cap. 2, p. 46–66. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1126215/1/LV-Agricultura-digital-2020-cap2.pdf>. Acesso em: 23 set. 2025.

STEINMETZ, S.; RIGHES, A. A.; MARCHESAN, E.; RADIN, B.; MARCHEZAN, E.; DEUS, A.; D'ÁVILA, L.; SILVA, L. F. S.; PARFITT, J. M. B. PlanejArroz: Aplicativo para o Planejamento do Manejo e Estimativa da Produtividade em Arroz Irrigado. Pelotas: **Embrapa Clima Temperado**, 2020. (Circular Técnica, 205). Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1124971/1/CIRCULAR-205.pdf>. Acesso em: 18 set. 2025.

VON BLOH, M.; NÓIA JÚNIOR, R. S.; WANGERPOHL, X.; SALTICK, A. O.; HALLER, V.; KAISER, L.; ASSENG, S. Machine learning for soybean yield forecasting in Brazil. **Agricultural and Forest Meteorology**, v. 341, 109670, 2023. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S016819232300360X>. Acesso em: 18 set. 2025.

WEI, M. C. F.; MOLIN, J. P. Soybean Yield Estimation and Its Components: A Linear Regression Approach. **Agriculture**, v. 10, n. 8, 348, 2020. Disponível em: <https://www.mdpi.com/2077-0472/10/8/348>. Acesso em: 18 set. 2025.

ZHAI, Z.; MARTÍNEZ, J. F.; BELTRÁN, V.; MARTÍNEZ, N. L. Decision support systems for agriculture 4.0: Survey and challenges. **Computers and Electronics in Agriculture**, v. 170, 105256, 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169919316497>. Acesso em: 18 set. 2025.