

PÓS-GRADUAÇÃO · PRODUÇÃO VEGETAL

Inteligência Artificial na Agricultura

Fundamentos, aplicações na agricultura digital e métodos para tomada de decisão.

Prof. Samuel de Assis Silva
Universidade Federal do Espírito Santo

Aula técnica · Dados, modelos, incerteza e ação no campo

UNIVERSIDADE ESTADUAL DE SANTA CRUZ
PROGRAMA DE PÓS-GRADUAÇÃO EM PRODUÇÃO VEGETAL
Mestrado e Doutorado



TESE DA AULA

IA é um componente de um sistema de decisão.

Ela transforma dados em estimativas, classificações e prioridades. A ação no campo ainda exige objetivo, restrições, risco e validação agronômica.

01

Diferenciar conceitos

IA, aprendizado de máquina, deep learning e otimização.

02

Relacionar método e dado

Escolher abordagens segundo o problema agrícola.

03

Avaliar modelos

Erro, validação, incerteza e explicabilidade.


04

Projetar decisões

Recomendações com supervisão humana e rastreabilidade.

A agricultura digital cria o ambiente da IA

O valor surge quando observação, análise, decisão e ação formam um ciclo fechado de aprendizagem.



Retroalimentação: o resultado observado atualiza dados, hipóteses e modelos.

Princípio: IA sem ação verificável é apenas análise.

Definições evitam promessas vagas

Cada termo descreve uma função distinta no sistema agrícola digital.

CONCEITO	IDEIA OPERACIONAL	SAÍDA TÍPICA	EXEMPLO NA AGRICULTURA
IA	Sistemas que inferem e tomam decisões.	Regra, previsão ou alerta.	Priorização de talhões.
ML	Algoritmos que aprendem padrões.	Classe, probabilidade ou valor.	Estimativa de produtividade.
Deep learning	Redes profundas que aprendem representações.	Características ou segmentos em imagens.	Segmentação de plantas daninhas.
Otimização	Escolha da melhor ação sob objetivo e restrições.	Dose, rota ou alocação.	Programação de irrigação.

Regra didática: modelo que prevê não é, por si só, um sistema que decide; a decisão requer objetivo, restrições e critério de risco.

Cinco famílias de problemas, cinco saídas

A formulação da pergunta vem antes da escolha do algoritmo.

FAMÍLIA	SAÍDA DO MODELO	DECISÃO OU EXEMPLO AGRÍCOLA
Classificação	Classe ou probabilidade de classe	Doença presente/ausente; nível de risco
Regressão	Valor contínuo estimado	Produtividade, umidade, biomassa ou demanda hídrica
Detecção / segmentação	Objeto, contorno ou pixel rotulado	Localizar planta daninha, falha ou área lesionada
Agrupamento	Grupos de observações similares	Explorar padrões e propor zonas de manejo
Otimização	Ação ou sequência de ações	Alocar água, definir dose, rota ou prioridade

Regra prática: não trate uma tarefa de otimização como mera previsão; a ação exige objetivos, custos e restrições explícitos.

Qualidade de dados determina o limite do modelo

Mais variáveis não compensam medidas mal contextualizadas. Cada observação precisa representar corretamente o fenômeno e sua escala.

Solo e planta

Umidade, nutrientes, fenologia, diagnóstico e amostras.

Clima e operação

Estações, previsão, telemetria e registros de manejo.

Imagem e espaço

Satélite, VANT, relevo, talhão e coordenadas.

Histórico produtivo

Colheita, aplicações, custos e resultados observados.

01 · RASTREABILIDADE

Metadados

Registrar local, tempo, unidade, sensor, protocolo e versão do dado.

02 · REPRESENTATIVIDADE

Cobertura real

Treino deve cobrir cultivares, solos, estádios, safras e condições relevantes.

03 · QUALIDADE

Outliers e ausências

Investigar antes de remover: uma exceção pode ser ruído ou um evento agrônomo crítico.

04 · INTEGRIDADE

Vazamento

Nenhuma informação futura ou do conjunto de teste pode contaminar o treinamento.

Regra prática: dados confiáveis permitem hipóteses melhores; dados enviesados produzem confiança enganosa.

Do dado à recomendação: ciclo de vida do modelo

Modelos agrícolas precisam ser projetados, testados e monitorados como parte de um processo decisório contínuo.

01

Formular

Definir a decisão, o alvo, a escala e o benefício mensurável.

CONTROLE: problema antes do algoritmo.

02

Preparar dados

Integrar fontes, verificar rótulos, unidades, tempo, local e qualidade.

CONTROLE: dados rastreáveis.

03

Treinar

Ajustar candidatos e registrar variáveis, parâmetros e versões.

CONTROLE: linha de base simples.

04

Validar

Testar em condições espaciais e temporais realistas, fora da amostra.

CONTROLE: erro e incerteza.

05

Implantar

Entregar recomendação com limites de uso, confiança e revisão humana.

CONTROLE: piloto monitorado.

06

Monitorar

Comparar previsão, ação e resultado; detectar deriva e atualizar.

CONTROLE: aprendizagem contínua.

MODELO

Gera estimativas ou classes a partir de padrões aprendidos.

DECISÃO

Combina a saída do modelo com custo, risco e restrições operacionais.

CAMPO

Confirma ou refuta hipóteses e produz os dados do próximo ciclo.

Aprendizado supervisionado conecta X a y

O treinamento usa exemplos rotulados para aprender uma função que transforma atributos observados em uma resposta de interesse.

modelo: $f(X) \rightarrow y$

X = clima, solo, imagem, manejo, fenologia
y = classe, produtividade, umidade, risco ou dose

Pergunta crítica: o rótulo representa o fenômeno agrônômico que se deseja decidir?

Dados rotulados

Observações com atributos e resultado conhecido.

Treinamento

O algoritmo ajusta parâmetros para reduzir erro.

Inferência

O modelo estima a resposta em novos casos.

SAÍDA DISCRETA

Classificação

Estima uma classe ou sua probabilidade.

Exemplos: estresse presente/ausente; nível de dano; categoria de solo.

Árvores · Random forest · Boosting · SVM

SAÍDA CONTÍNUA

Regressão

Estima um valor numérico e, idealmente, sua incerteza.

Exemplos: produtividade; teor de água; demanda de irrigação.

Regressão regularizada · Random forest · Boosting

Estrutura latente e representações profundas

Métodos diferentes respondem a perguntas distintas: explorar padrões sem rótulo ou aprender características complexas a partir dos dados.

SEM RÓTULOS PRÉVIOS

Aprendizado não supervisionado

Explora similaridade, colinearidade e padrões recorrentes. É útil para formular hipóteses — não para dispensar interpretação agronômica.

Agrupamento

Organiza observações similares; pode apoiar a exploração de zonas de manejo.

PCA

Reduz dimensionalidade e expõe combinações dominantes de variáveis.

REPRESENTAÇÕES COMPLEXAS

Aprendizado profundo

Redes com múltiplas camadas aprendem características úteis diretamente de imagens, sinais e séries temporais.

CNN

Padrões espaciais em imagens de folha, dossel e VANT.

U-Net

Segmentação por pixel de cultura, solo, dano ou planta daninha.



Sequências

Redes temporais e transformers para séries de clima e fenologia.

Alerta metodológico: um grupo estatístico não é automaticamente uma zona agronômica; maior capacidade do modelo também aumenta a necessidade de dados, validação e controle de generalização.

Visão computacional converte imagem em medida

A imagem só se torna informação útil quando aquisição, rótulo, modelo e validação correspondem ao problema agrônômico.



Generalização é o teste decisivo: cultivar, estágio fenológico, solo, iluminação, sensor e safra podem mudar o padrão visual e degradar a resposta fora do domínio de treinamento.

Selecionar modelo é equilibrar desempenho e uso

O melhor algoritmo é o que atende à decisão pretendida em condições reais de produção.

CRITÉRIO	PERGUNTA TÉCNICA	IMPLICAÇÃO AGRÍCOLA
Desempenho	O erro atende ao uso pretendido e supera uma linha de base simples?	Uma previsão pode ser estatisticamente boa e ainda insuficiente para definir uma intervenção.
Robustez	O modelo mantém qualidade em outros talhões, anos e condições?	Generalização importa mais que desempenho excepcional em um único conjunto.
Latência	A resposta chega no momento em que a ação ainda é possível?	Alertas fitossanitários e controle operacional têm janelas de decisão curtas.
Explicabilidade	A recomendação pode ser discutida com critérios técnicos?	Modelos devem apoiar hipóteses que possam ser verificadas no campo.
Custo	Dados, conectividade, processamento e manutenção são viáveis?	Soluções complexas só agregam valor quando podem ser sustentadas pela operação.

Boa prática: comparar candidatos sob o mesmo protocolo de validação e documentar a razão da escolha.

DECISÃO DE PROJETO

“Mais complexo” não significa “mais útil”.

Uma solução agrícola precisa combinar qualidade preditiva, disponibilidade de dados, tempo de resposta, transparência e custo operacional.

Escolha o modelo pela decisão que ele melhora — não apenas pela métrica que maximiza.

Métricas devem refletir o problema agronômico

A métrica adequada depende do tipo de saída e do custo associado a cada erro.

SAÍDA CONTÍNUA · REGRESSÃO

Quanto o modelo erra ao estimar?

MAE **MAE = média de |valor observado – valor previsto|**

Erro médio na unidade da variável.

RMSE **RMSE = raiz da média de (observado – previsto)²**

Penaliza erros grandes; útil quando falhas extremas são críticas.

Escolha: MAE comunica erro típico; RMSE evidencia erros extremos.

SAÍDA DISCRETA · CLASSIFICAÇÃO

O modelo encontra a classe importante?

Precisão **precisão = verdadeiros positivos / positivos previstos**

Entre os alertas, quantos eram positivos?

Revocação **revocação = verdadeiros positivos / positivos reais**

Quantos casos reais foram detectados?

F1 **F1 = 2 × precisão × revocação / (precisão + revocação)**

Equilíbrio entre alarmes corretos e detecção.

Antes de escolher a métrica: defina o que custa mais — fiscalizar um falso alerta ou perder um foco real.

Boa prática: reporte por talhão, safra ou condição; uma média global pode ocultar falhas.

Validação espacial e temporal evita otimismo artificial

Se treino e teste compartilham vizinhança espacial ou período, o modelo pode parecer melhor do que será em novas condições de uso.

RISCO

Divisão aleatória

Observações próximas podem cair nos dois conjuntos e transportar informação muito semelhante para o teste.

treino	teste
teste	treino
treino	teste

Efeito: erro aparentemente baixo, mas capacidade de generalização incerta.

ESPAÇO

Blocos espaciais

Separar regiões, talhões ou blocos geográficos aproxima o cenário de aplicar o modelo em uma área não observada.

bloco A	bloco B
bloco C	bloco D

Teste realista: o modelo enfrenta solo, manejo e condições locais diferentes.

TEMPO

Safras ou períodos futuros

Treinar em períodos anteriores e testar em período posterior avalia a estabilidade diante de clima e fenologia distintos.

safra 1	safra 2
safra 3	safra 4

Teste realista: a previsão não usa informações que ainda não existiam quando a decisão seria tomada.

PROTOCOLO MÍNIMO

1 - LINHA DE BASE

Comparar o modelo com média histórica, regra agrônômica ou método simples.

2 - PARTIÇÃO

Escolher blocos espaciais, anos, safras ou talhões independentes conforme a decisão.

3 - RELATO

Apresentar desempenho, variabilidade e incerteza por condição de uso.

Explicabilidade transforma previsão em hipótese

Explicar uma saída ajuda a orientar a investigação; não transforma associação estatística em causa comprovada.

EXPLICAÇÃO LOCAL · TALHÃO 07

Por que o modelo priorizou este talhão?

Estimativa: maior probabilidade de estresse, com confiança moderada.

Déficit hídrico		maior peso
Queda de vigor		peso alto
Estádio fenológico		peso médio
Textura do solo		peso menor

A explicação aponta variáveis associadas à previsão daquele caso, não uma prova de mecanismo fisiológico.

Uma saída explicada é mais fácil de discutir tecnicamente.

Ela ainda precisa ser confrontada com solo, clima, fenologia e observação de campo.

01 — Verificar coerência

As variáveis relevantes fazem sentido para a cultura, o estágio e a condição local?

02 — Considerar confiança

Baixa confiança deve acionar inspeção, amostragem ou uma regra conservadora.

03 — Confirmar no campo

A história identifica a causa, registra o diagnóstico e retroalimenta dados e modelo.

Princípio de uso responsável: explicabilidade deve produzir perguntas agronômicas melhores e decisões auditáveis — não uma justificativa automática para agir.

Uma recomendação exige objetivo e restrições

Um modelo estima o estado do sistema. A decisão escolhe ações segundo objetivo e limites.

PREDIÇÃO

“Qual é o risco de estresse?”

Modelo fornece valor, classe ou probabilidade.

DECISÃO

“O que deve ser feito agora?”

Compara ações, custos, benefícios e limites.

escolher ação = a^* que maximiza a utilidade esperada

Utilidade considera resultado estimado, custo, risco e restrições.

01 · OBJETIVO

O que melhorar?

Produtividade, margem ou resiliência.

02 · PREVISÃO

O que pode ocorrer?

Estado estimado, cenários e incerteza.

03 · RESTRIÇÕES

O que limita a ação?

Água, equipamento, janela operacional.

04 · GOVERNANÇA

Quem revisa?

Responsável técnico define limites e exceções.

Saída responsável: ação proposta + benefício esperado + nível de confiança + condição de revisão.

Otimização formaliza escolhas operacionais

Prever um estado é diferente de selecionar a melhor ação para um objetivo sob limites reais.

FORMA GERAL DA DECISÃO

Escolher ação a^* que maximiza a utilidade esperada $U(a \mid \text{cenário})$

A utilidade incorpora benefício, custo, risco e consequências da ação; o cenário reúne previsão e incerteza.

EXEMPLOS DE AÇÃO

Definir lâmina por setor, dose em taxa variável, rota de máquinas, sequência de pulverização ou prioridade de inspeção.

01 · VARIÁVEL

Ação decidida

Qual decisão é controlável? Dose, lâmina, área, horário, rota ou ordem de execução.

02 · OBJETIVO

Resultado desejado

Produtividade, margem, eficiência de uso, qualidade, risco reduzido ou estabilidade.

03 · RESTRIÇÕES

Limites reais

Água, orçamento, equipamento, capacidade, janela operacional, segurança e legislação.

04 · INCERTEZA

Condição variável

Clima, resposta da cultura, disponibilidade de recursos e erro da própria previsão.


FAMÍLIAS DE MÉTODOS

Programação linear e inteira · otimização estocástica · heurísticas · busca por cenários · regras de controle com supervisão humana.

Princípio: uma recomendação operacional deve apresentar a ação, o objetivo, as restrições consideradas e a condição que exige revisão pelo responsável técnico.

Irrigação integra modelo, balanço e decisão

A IA pode apoiar a estimativa e a priorização; a recomendação final precisa respeitar balanço hídrico, capacidade do sistema e limites operacionais.



REGRA DE DECISÃO

Não irrigar apenas porque há previsão de déficit.

A ação deve comparar o benefício esperado de reduzir estresse com o custo de água e energia, a probabilidade de chuva e as restrições hidráulicas.

SAÍDA OPERACIONAL


Recomendação auditável

Setor prioritário, faixa de lâmina, horário sugerido, confiança da estimativa e condição que exige validação do responsável técnico.

Mensagem-chave: o modelo torna a decisão mais informada; sensores, balanço e inspeção garantem que a ação permaneça coerente com o sistema solo–planta–atmosfera.

Taxa variável depende de diagnóstico confiável

Variabilidade observada não é, por si só, evidência de resposta econômica à intervenção. A prescrição precisa conectar causas, resposta e capacidade operacional.



Fechamento do ciclo: monitorar aplicação e resultado por zona transforma a taxa variável em experimento operacional e melhora a próxima recomendação.

Detecção precoce orienta inspeção fitossanitária

Visão computacional e imagens podem antecipar onde observar; não substituem o diagnóstico fitopatológico nem a responsabilidade técnica.

01 Observar Imagem de folha, dossel ou VANT; contexto de cultura, estádio, clima e manejo.	02 Triar padrão Modelo estima classe, foco provável ou nível de anomalia e registra confiança.	03 Priorizar vistoria Talhões e pontos com maior risco entram na agenda de inspeção de campo.
04 Confirmar diagnóstico Profissional avalia sintomas, incidência, severidade e causas alternativas.	05 Registrar e aprender Resultado da vistoria atualiza o histórico, os rótulos e o sistema de decisão.	


SITUAÇÃO	Risco operacional	Resposta recomendada
Alerta forte	Alta probabilidade ou grande impacto potencial, ainda com incerteza de causa.	Priorizar inspeção rápida; confirmar antes de prescrever intervenção.
Alerta fraco	Pode refletir ruído de imagem, estádio, iluminação ou sintoma inespecífico.	Cruzar com histórico e dados de campo; evitar ação automática.
Sem alerta	Falso negativo pode ocorrer com baixa resolução, baixa amostragem ou domínio novo.	Manter monitoramento de rotina e amostragem dirigida.

PRINCÍPIO DE IMPLEMENTAÇÃO

Humano no circuito: o sistema deve explicar a prioridade, indicar confiança e permitir que a confirmação de campo corrija a recomendação.

Produtividade, risco climático e logística se conectam


Previsões são mais valiosas quando orientam cenários e preparação operacional, reconhecendo a incerteza que permanece até a execução.



Saída responsável: plano de colheita ou suprimento com **cenários, gatilhos de revisão e margem de contingência** — não uma decisão fixa baseada em uma única previsão.

Robótica e IA generativa ampliam a operação

As duas tecnologias atuam em domínios distintos: uma percebe e controla sistemas físicos; a outra apoia síntese e consulta sobre informação.



Governança define se a IA será confiável


Confiança não resulta apenas da acurácia: ela depende de dados rastreáveis, responsabilidades explícitas e capacidade de corrigir o sistema em uso.

01 · DADOS Qualidade e rastreabilidade Origem, unidade, escala, rótulo, licença, versão e transformação dos dados devem poder ser recuperados e auditados.	02 · SOBERANIA Direitos e acesso Definir quem coleta, armazena, acessa, compartilha e utiliza dados de propriedades, máquinas e produção.	03 · EQUIDADE Representatividade Avaliar se o modelo funciona para diferentes regiões, cultivares, escalas produtivas e contextos de manejo.	
04 · SEGURANÇA Proteção e continuidade Controlar credenciais, backups, alterações, falhas de conectividade e riscos de uso indevido da recomendação.	05 · SUPERVISÃO Humano no circuito Delimitar autonomia, critérios de revisão, exceções e responsabilidade técnica pela decisão e pela ação executada.	06 · MONITORAMENTO Deriva e atualização Comparar previsão, recomendação e resultado para detectar mudanças no dado, no ambiente ou no desempenho do modelo.	
CICLO DE GOVERNANÇA	DOCUMENTAR Dados, hipóteses, versão do modelo, critérios de decisão e limites de uso.	MONITORAR Qualidade de entrada, desempenho, exceções, reclamações e indicadores de risco.	CORRIGIR Suspender, revisar, revalidar ou atualizar quando o sistema sai do domínio esperado.

Princípio: uma solução de IA agrícola deve ser capaz de mostrar o que usou, por que recomendou, quem decidiu e como será corrigida se falhar.

Protocolo de implantação responsável

A solução deve avançar por evidência: um protótipo útil não é automaticamente confiável para orientar decisões em escala.




CRITÉRIO DE AVANÇO	CLAREZA	BASELINE	GENERALIZAÇÃO	SEGURANÇA
	A decisão é relevante, mensurável e tem responsável técnico definido.	O ganho potencial supera a alternativa simples de forma verificável.	O resultado é estável fora do conjunto de desenvolvimento.	O piloto mantém supervisão, limites e retroalimentação em campo.

Regra de escala: ampliar o uso apenas quando desempenho, segurança, custo e governança permanecem adequados no contexto real de produção.

Caso integrador: priorizar talhões para inspeção

O objetivo não é “diagnosticar à distância”, mas usar dados para decidir onde a equipe deve observar primeiro e registrar o que encontrou.



EXEMPLO DE SAÍDA OPERACIONAL

Agenda de inspeção do dia

01	Talhão Norte	alto risco
02	Talhão 07	alto risco
03	Talhão Leste	risco médio
04	Talhão Baixada	monitorar

A lista combina escore, confiança, impacto potencial e viabilidade de deslocamento. Ela organiza a vistoria; não confirma uma causa nem autoriza intervenção automática.

Qual é o sinal?

Quais variáveis e padrões elevaram o risco naquele talhão?

Há confiança?

O caso está dentro do domínio conhecido pelo modelo ou exige cautela extra?

Qual é o custo de errar?

Falso negativo e falso positivo têm impactos diferentes sobre a agenda e a cultura.

O que o campo encontrou?

Diagnóstico, severidade, fotos e decisão entram no registro para validação contínua.

Regra de ouro: o valor da IA está em concentrar atenção onde ela é mais necessária, preservando a confirmação agrônômica e a rastreabilidade de cada decisão.

MENSAGEM FINAL

IA útil é IA integrada ao método agrônômico

O valor não está em automatizar decisões por si só, mas em melhorar a observação, a priorização, a experimentação e a aprendizagem sob condições reais de produção.

01 Começar pela decisão

Definir a pergunta agrônômica, o responsável, a restrição e o indicador de sucesso antes de escolher o algoritmo.

02 Validar fora do conforto do conjunto de dados

Testar em talhões, safras ou condições novas e relatar incerteza e limites relevantes.

03 Fechar o ciclo com campo e governança

Registrar decisão e resultado, revisar o modelo e manter supervisão técnica quando há risco agrônômico.

Referências essenciais

FAO. Digital Agriculture and AI Innovation. Orientações institucionais sobre inovação digital, dados e uso responsável de IA na agricultura.

Liakos, K. G. et al. (2018). Machine Learning in Agriculture: A Review. *Sensors*, 18(8), 2674.

Saiz-Rubio, V.; Rovira-Más, F. (2022). From Smart Farming to Agriculture 5.0: revisão sobre dados e gestão de culturas.

PARA DISCUTIR EM SEMINÁRIO

Qual decisão da sua linha de pesquisa poderia ser melhorada por IA — e que evidência seria necessária para que a recomendação fosse tecnicamente defensável?

Próximo passo acadêmico: transformar um problema de manejo em um caso de uso com dados, linha de base, desenho de validação, critério de decisão e plano de monitoramento.