

ARQUITETURA IOT COM OTIMIZAÇÃO MPMAS E CAMADA INTELIGENTE BASEADA EM REGRAS PARA APOIO À DECISÃO EM AGRICULTURA DE PRECISÃO

IOT ARCHITECTURE WITH MPMAS OPTIMIZATION AND A RULE-BASED
INTELLIGENT LAYER FOR DECISION SUPPORT IN PRECISION
AGRICULTURE

Engenharias, Ciências Agrárias • 19/07/2026

REGISTRO DOI: [10.70773/revistatopicos/784311442](https://doi.org/10.70773/revistatopicos/784311442)

Andrea Barboza Proto Sardi¹

Adriano Soares de Oliveira Bailão²

Gustavo Moura Barros³

Sergio Souza Novak⁴

Manoel Henrique Reis de Oliveira⁵

Valber Sardi Lopes⁶

RESUMO

A programação matemática de fazenda inteira constitui uma abordagem consolidada para apoiar a alocação de recursos agrícolas, mas sua aplicação prática ainda é limitada pela distância entre modelos, dados de campo e usuários. Este estudo apresenta o AgroMPMAS-IoT v2, evolução do AgroMPMAS v1, registrado institucionalmente no IF Goiano, como uma plataforma web de código aberto que integra sensores IoT, aquisição automática, otimização por programação inteira mista, camada inteligente baseada em regras, atuadores e painel de acompanhamento. A solução foi implementada em PHP 8.3, com persistência em XML, solvers GLPK/CBC e firmware ESP32. A contribuição metodológica central consiste em representar a irrigação de precisão como benefício endógeno associado à adoção conjunta de sensoriamento e tecnologia de irrigação. Desse modo, o sensor deixa de ser apenas um custo e passa a influenciar a decisão ótima por meio da economia de água. A avaliação foi conduzida em experimento controlado de uma propriedade-exemplo com 10 ha, duas culturas, oferta hídrica limitada e série de umidade do solo em queda. Com o acoplamento ativado, o lucro ótimo aumentou de R\$ 32.224,50 para R\$ 34.396,20 (+6,7%), o uso de água diminuiu de 40,00 para 32,11 unidades (-19,7%) e a área cultivada retornou de 9,34 para 10,00 ha. Os resultados demonstram que a integração entre telemetria e otimização modifica a decisão de investimento, o plano produtivo e a ordem de atuação, ampliando a utilidade da modelagem de fazenda inteira para sistemas de apoio à decisão em agricultura de precisão.

Palavras-chave: Sistemas ciberfísicos; Gestão rural; Modelagem computacional; Programação inteira mista; Aplicação web; Regressão linear.

ABSTRACT

Whole-farm mathematical programming is a well-established approach for agricultural resource allocation, but its practical use remains constrained by the gap between models, field data, and end users. This study presents AgroMPMAS-IoT v2, an evolution of AgroMPMAS v1, institutionally registered at IF Goiano, as an open-source web platform integrating IoT sensors, automatic data acquisition, mixed-integer programming optimization, a rule-based intelligent layer, actuators, and a monitoring dashboard. The solution was implemented in PHP 8.3 with XML persistence, GLPK/CBC solvers, and ESP32 firmware. Its main methodological contribution is to represent precision irrigation as an endogenous benefit conditional on the joint adoption of sensing and irrigation technology. Thus, the sensor is no longer treated only as a cost and starts influencing the optimal decision through water savings. The evaluation used a controlled experiment representing a 10-ha farm, two crops, limited water availability, and a decreasing soil-moisture series. When the coupling was enabled, optimal profit increased from BRL 32,224.50 to BRL 34,396.20 (+6.7%), water use decreased from 40.00 to 32.11 units (-19.7%), and cultivated area was restored from 9.34 to 10.00 ha. The results show that integrating telemetry and optimization changes the investment decision, the production plan, and the actuation command, expanding the applicability of whole-farm modeling to precision-agriculture decision-support systems.

Keywords: cyber-physical systems; farm management; computational modeling; mixed-integer programming; web application; linear regression.

1. INTRODUÇÃO

A gestão da produção agrícola tornou-se progressivamente mais complexa diante da variabilidade climática, da volatilidade dos mercados e da necessidade de intensificação sustentável. Modelos de planejamento de fazenda inteira, baseados em otimização ou programação matemática, foram concebidos precisamente para apoiar decisões nesse contexto, capturando as interligações entre atividades produtivas, recursos e restrições da propriedade (van Wijk et al., 2014; Hazell e Norton, 1986).

Antle et al. (2017) apontam dois desafios centrais para ampliar a utilidade desses modelos: a necessidade de melhores dados e a necessidade de reduzir a distância entre modelos e usuários quanto à acessibilidade, credibilidade e relevância. Mössinger, Troost e Berger (2022) abordaram diretamente o segundo desafio, propondo uma interface gráfica leve em R-Shiny acoplada ao arcabouço MPMAS (Schreinemachers e Berger, 2011) e demonstrando, em estudo de caso no Paraguai, que sessões de modelagem interativa são bem aceitas por pequenos agricultores e extensionistas. Naquele desenho, contudo, a entrada de dados é manual, por meio de sliders ajustados pelo usuário, e a cadeia de valor termina na apresentação de planos otimizados — isto é, resolve-se essencialmente Usuário → Interface → MPMAS.

Paralelamente, a digitalização da agricultura tornou viável a coleta massiva e contínua de dados por sensores de baixo custo (Weersink et al., 2018; Carolan, 2017). Persiste, no entanto, uma lacuna entre os dados brutos de campo e a sua incorporação a um arcabouço holístico de decisão que conecte medições, previsão e otimização de fazenda inteira (Sørensen et al., 2011). Sistemas de informação para gestão agrícola (FMIS) raramente incluem um componente de

otimização tática e estratégica de fazenda inteira (Fountas et al., 2015; Tummers et al., 2019).

Este artigo apresenta o AgroMPMAS-IoT v2, uma plataforma web de código aberto que evolui o sistema-base AgroMPMAS v1, estruturado na cadeia Usuário → Interface web → MPMAS → Painel, para um sistema ciberfísico capaz de incorporar telemetria, otimização e atuação. A hipótese central é que a integração entre Internet das Coisas (IoT) e otimização MPMAS, mediada por uma camada inteligente de recomendação baseada em regras e previsão estatística, transforma o sensor de elemento meramente informativo em variável de decisão economicamente relevante.

A questão de pesquisa investigada é: em que medida o acoplamento explícito entre dados de campo, economia hídrica e decisão de investimento altera a solução ótima de um modelo de fazenda inteira? Para respondê-la, o trabalho contribui com: (i) uma arquitetura aberta que fecha o ciclo aquisição–decisão–atuação; (ii) uma formulação que condiciona o benefício da irrigação de precisão à adoção conjunta de sensor e tecnologia; (iii) uma camada de recomendação simples, auditável e adequada a cenários com poucos dados; e (iv) uma avaliação controlada do efeito desse acoplamento sobre lucro, consumo de água, área cultivada e comando enviado ao atuador.

Além de apresentar a arquitetura, o artigo explicita a formulação matemática, descreve os componentes computacionais e estabelece um procedimento reproduzível para comparar cenários com e sem o benefício da irrigação de precisão. A análise concentra-se na validade do mecanismo de acoplamento e não pretende

substituir a calibração agronômica ou a validação em campo, tratadas como etapas necessárias para a evolução do protótipo.

2. FUNDAMENTAÇÃO TEÓRICA E TRABALHOS RELACIONADOS

2.1. Modelagem de Fazenda Inteira e MPMAS

A modelagem de fazenda inteira (whole-farm modeling) consolidou-se como arcabouço conceitual tanto para o apoio ao planejamento no nível da propriedade quanto para a análise da resposta do agricultor no nível de políticas (Hazell e Norton, 1986). A programação matemática — em especial a programação linear e a programação inteira mista — permite representar de forma explícita as inter-relações entre atividades produtivas, recursos e restrições da propriedade, identificando planos de manejo que maximizam um objetivo econômico sujeito a balanços de terra, água, trabalho e capital.

Esses modelos possuem natureza dupla. No uso prescritivo, respondem à pergunta sobre o que o agricultor deveria fazer, sugerindo planos otimizados. No uso descritivo e preditivo, sob a hipótese de que o produtor é, em grau suficiente, um otimizador cujas restrições são bem captadas, reproduzem o comportamento real e antecipam respostas a novos cenários (Janssen e van Ittersum, 2007). O arcabouço MPMAS (Multiple-agent Programming-based Modeling of Agricultural Systems) representa essa tradição em ambiente computacional, empregando programação inteira mista para simular decisões de agentes agrícolas e sendo aplicado em diversos estudos no mundo (Schreinemachers e Berger, 2011). A correta especificação das restrições de produção é, frequentemente,

mais determinante para descrever o comportamento econômico do que o refinamento da função objetivo (Berger e Troost, 2014).

Apesar de seu potencial, os modelos de sistemas agrícolas enfrentam um desafio recorrente: a distância entre os modelos e os usuários quanto à acessibilidade, à credibilidade e à relevância (Antle et al., 2017). Desde os primeiros sistemas especialistas e ferramentas de apoio à decisão, discute-se como aproximar a ciência da prática (Cox, 1996). O consenso atual aponta que a abordagem participativa, envolvendo os usuários no desenho e na entrega das ferramentas, é indispensável para o sucesso dos sistemas de apoio à decisão na agricultura (Rose et al., 2016).

Ainda assim, a adoção efetiva de ferramentas desenvolvidas por cientistas permanece baixa, o que indica que princípios de desenho centrado no usuário não foram amplamente incorporados (Rose et al., 2017). Limitações de interface e a dificuldade de tornar modelos complexos compreensíveis a agricultores com baixa familiaridade computacional figuram entre as principais barreiras (Lacoste e Powles, 2016). Nesse contexto, Mössinger, Troost e Berger (2022) propuseram uma interface gráfica leve para o MPMAS, viabilizando sessões de modelagem interativa que se mostraram bem aceitas por pequenos agricultores e extensionistas, e resolvendo, em essência, a cadeia usuário–interface–modelo. O presente trabalho parte dessa contribuição e da implementação dela derivada (AgroMPMAS v1) para estendê-la a um ciclo automatizado de sensoriamento e atuação.

2.2. Agricultura de Precisão, IoT e Sistemas Ciberfísicos

A agricultura de precisão pode ser entendida como o manejo localizado da produção com base em informação detalhada sobre a variabilidade espacial e temporal do sistema produtivo, visando otimizar o uso de insumos e reduzir impactos (Zhang, Wang e Wang, 2002). A queda no custo de sensores e de dispositivos de aquisição ampliou enormemente a capacidade de coletar dados de campo de forma contínua (Weersink et al., 2018; Carolan, 2017).

Há, contudo, um salto não trivial entre a disponibilidade de grandes volumes de dados e a obtenção de decisões de manejo mais sustentáveis, rentáveis e resilientes. Revisões sobre Big Data e agricultura inteligente destacam que o valor dos dados depende de sua incorporação a cadeias que transformem medições em informação e, então, em decisão (Wolfert et al., 2017; Kamilaris, Kartakoullis e Prenafeta-Boldú, 2017). Em outras palavras, medições e previsões precisam ser integradas a um arcabouço holístico de decisão no nível da fazenda — exatamente o papel que a modelagem de fazenda inteira pode desempenhar.

A Internet das Coisas (IoT) designa a interconexão, pela rede, de objetos físicos dotados de capacidade de sensoriamento, comunicação e, por vezes, atuação (Atzori, Iera e Morabito, 2010). Na agricultura, a IoT viabiliza o monitoramento de variáveis como umidade do solo, temperatura e condições climáticas, bem como o controle de dispositivos em campo, com potencial de modernizar práticas tradicionais (Tzounis et al., 2017). Plataformas de hardware de baixo custo, como o ESP32, e protocolos de comunicação simples permitem implementar nós de aquisição e atuação a custo acessível, inclusive para pequenos produtores.

Quando o sensoriamento, o processamento e a atuação são integrados em um laço de realimentação, configura-se um sistema ciberfísico: a parte computacional observa o estado do mundo físico, decide e age sobre ele. Wolfert et al. (2017) descrevem a agricultura inteligente justamente como um ciclo ciberfísico de gestão da fazenda, no qual tecnologias de informação e comunicação articulam aquisição de dados, análise e controle. Revisões sobre IoT na agricultura registram desde o monitoramento com geração de alertas por regras simples até o controle automatizado, com sugestões ao usuário ou acionamento direto de atuadores (Tzounis et al., 2017; Ayaz et al., 2019). É nesse espaço — o fechamento do laço entre dados de campo, otimização e atuação — que se insere a contribuição do AgroMPMAS-IoT v2.

2.3. FMIS e Apoio à Decisão Baseado em Regras

Os sistemas de informação para a gestão agrícola (Farm Management Information Systems — FMIS) auxiliam o agricultor a coletar, processar, armazenar e disseminar dados de processos da propriedade para melhorar a tomada de decisão (Sørensen et al., 2010). Houve, nos últimos anos, expansão expressiva no desenvolvimento e no uso desses sistemas (Tummers, Kassahun e Tekinerdogan, 2019).

Não obstante, a maioria das soluções comerciais concentra-se em tarefas específicas — contabilidade, rastreabilidade, manejo de pragas ou planejamento operacional de tarefas — e raramente incorpora um componente de otimização tática e estratégica de fazenda inteira, capaz de combinar as inter-relações entre múltiplas opções de produção e investimento e seus usos interligados de recursos (Fountas et al., 2015; Tummers, Kassahun e Tekinerdogan,

2019). Essa ausência define uma oportunidade clara: dotar os FMIS de um núcleo de otimização holística alimentado por dados reais de campo.

Entre a aquisição de dados e a otimização situa-se, nesta proposta, uma camada de apoio à decisão baseada em regras, limiares agronômicos e previsão estatística. A literatura de IoT agrícola reconhece que sistemas de monitoramento frequentemente operam com alertas e recomendações derivados de regras explícitas, antes de evoluírem para abordagens mais complexas (Tzounis et al., 2017). A escolha por uma lógica simples e auditável é deliberada: privilegia a explicabilidade ao agricultor e a robustez à baixa disponibilidade de dados rotulados em pequenas propriedades — atributos diretamente associados à credibilidade e à adoção das ferramentas de apoio à decisão (Rose et al., 2017).

A previsão da tendência de umidade do solo por regressão linear é um instrumento estatístico transparente, cujos coeficientes têm interpretação direta e cujo comportamento pode ser inspecionado pelo usuário. Sem prejuízo dessa simplicidade, a arquitetura permanece modular: revisões sobre análise de dados na agricultura indicam que métodos de aprendizado de máquina podem, futuramente, substituir ou complementar a previsão por regressão à medida que mais dados se tornem disponíveis (Kamilaris, Kartakoullis e Prenafeta-Boldú, 2017), sem alterar o restante do pipeline.

A revisão evidencia três constatações convergentes. Primeiro, a modelagem de fazenda inteira oferece um arcabouço maduro para decisões de manejo, mas historicamente esbarra na distância entre modelos e usuários. Segundo, a digitalização e a IoT disponibilizam

dados de campo em abundância, porém esse dado só gera valor quando incorporado a um arcabouço holístico de decisão. Terceiro, os FMIS atuais raramente integram otimização de fazenda inteira a dados reais e a mecanismos de atuação.

O AgroMPMAS-IoT v2 posiciona-se exatamente nessa interseção: estende o sistema-base AgroMPMAS v1 — derivado da interface leve para MPMAS — acoplando aquisição automática por IoT, uma camada inteligente de recomendação baseada em regras e previsão estatística, e a geração de ordens para atuadores, fechando o ciclo ciber-físico. Sua principal originalidade metodológica é tratar a adoção de sensoriamento e de tecnologia de irrigação como decisão endógena do modelo de otimização, condicionada a um benefício econômico real (a economia de água da irrigação de precisão), e não como mero custo. Com isso, articula em um único sistema as três frentes que a literatura, até aqui, tratava de forma fragmentada.

2.4. Trabalhos Relacionados e Lacuna de Pesquisa

A análise dos trabalhos relacionados mostra que as contribuições existentes se concentram, em geral, em partes específicas do problema. Algumas soluções aproximam o usuário de modelos matemáticos por meio de interfaces gráficas; outras coletam telemetria e automatizam tarefas locais; e os FMIS integram registros e rotinas administrativas. A lacuna investigada neste trabalho é a combinação, em uma única plataforma aberta, de telemetria de campo, otimização de fazenda inteira, recomendação interpretável e geração de comandos para atuação.

O antecedente imediato é o AgroMPMAS v1, a versão inicial implementa, em PHP/XML, a geração de modelos de programação

inteira mista, a resolução por solvers de código aberto (GLPK/CBC) e um painel web de decisão, operando a cadeia usuário–interface–modelo–painel. O AgroMPMAS-IoT v2 reutiliza a camada de dados e o núcleo de otimização e acrescenta aquisição automática por IoT, camada de recomendação e atuação.

No campo das interfaces para modelos de otimização agrícola, há soluções publicamente disponíveis. A interface web GAMS-MIRO permite operar modelos formulados em GAMS por navegador, removendo o ônus de hospedagem local de servidores; foi inclusive apontada na literatura como alternativa para planejamento de culturas sob incerteza (Mössinger et al., 2022). Britz (2014) descreve um gerador de interface gráfica para modelos econômicos, aplicado a modelos de fazenda como FarmDyn, CAPRI-FT e IFM-CAP. Pahmeyer, Kuhn e Britz (2021) disponibilizam o sistema web 'Fruchtfolge' para otimização de rotações de culturas com dados espaciais. Tais soluções, contudo, concentram-se na interface usuário–modelo e não incorporam aquisição automática de telemetria de campo nem a geração de ordens de atuação.

No segmento comercial, há ampla oferta de sistemas de informação para gestão agrícola (FMIS) e de controladores de irrigação ditos inteligentes. Os FMIS comerciais, todavia, em geral atendem a tarefas específicas — contabilidade, rastreabilidade, manejo de pragas ou planejamento operacional — sem um núcleo de otimização tática e estratégica de fazenda inteira (Fountas et al., 2015; Tummers, Kassahun e Tekinerdogan, 2019). Os controladores de irrigação por sensores, por sua vez, costumam operar por limiares locais de umidade, sem articulação com um modelo econômico que pondere o conjunto das atividades e dos recursos da propriedade.

À luz desse quadro, e sem prejuízo de busca de anterioridade formal junto aos órgãos de propriedade industrial, o diferencial técnico do AgroMPMAS-IoT v2 reside na integração, em uma única plataforma de código aberto, de quatro funções que as soluções acessíveis ao público tendem a tratar de forma isolada: (i) aquisição automática de telemetria por dispositivos IoT de baixo custo; (ii) otimização de fazenda inteira por programação inteira mista; (iii) uma camada inteligente de recomendação baseada em regras, limiares agronômicos e previsão estatística; e (iv) a geração de ordens para atuadores, fechando o ciclo ciber-físico. Soma-se a isso a originalidade de modelar a adoção de sensoriamento e de tecnologia de irrigação como decisão endógena do otimizador, condicionada a um benefício econômico real, e não como simples custo.

Em comparação com a interface móvel proposta por Mössinger, Troost e Berger (2022), a contribuição aqui não está apenas na forma de interação com o modelo. O foco é modificar a própria estrutura da decisão: o benefício técnico medido pelos sensores é transportado para o modelo econômico e passa a determinar se o investimento tecnológico deve ou não ocorrer. Essa distinção é importante porque uma interface mais acessível pode aproximar o usuário do modelo, mas não corrige uma formulação em que a tecnologia aparece exclusivamente como custo.

3. MATERIAIS E MÉTODOS

3.1. Arquitetura e Fluxo Operacional

O AgroMPMAS-IoT v2 organiza-se em sete estágios encadeados, executados por um orquestrador (pipeline) que pode ser disparado

manualmente, por requisição web ou de forma agendada para operação autônoma:

1. Sensores IoT: dispositivos de campo (p. ex. ESP32 com sensor de umidade do solo) medem variáveis ambientais.
2. Aquisição automática: as leituras são enviadas a um endpoint HTTP e persistidas em formato XML, substituindo a entrada manual por sliders.
3. Camada inteligente de recomendação: baseada em regras explícitas, limiares agrônômicos e previsão estatística — regressão linear da tendência de umidade do solo —, atua em dois momentos: antes da otimização, ajustando parâmetros do modelo conforme o estado do campo; e depois, traduzindo o plano ótimo em recomendações e ordens de irrigação.
4. MPMAS: um modelo de programação inteira mista de fazenda inteira é gerado dinamicamente a partir dos dados e dos ajustes da IA.
5. Otimização: O modelo é exportado em formato LP e resolvido por GLPK ou CBC
6. Atuadores: o plano ótimo e a recomendação da camada inteligente são traduzidos em comandos para válvulas/relés, disponibilizados por um endpoint consultado pelos dispositivos.
7. Painel web: indicadores, telemetria, recomendações e comandos são consolidados num dashboard

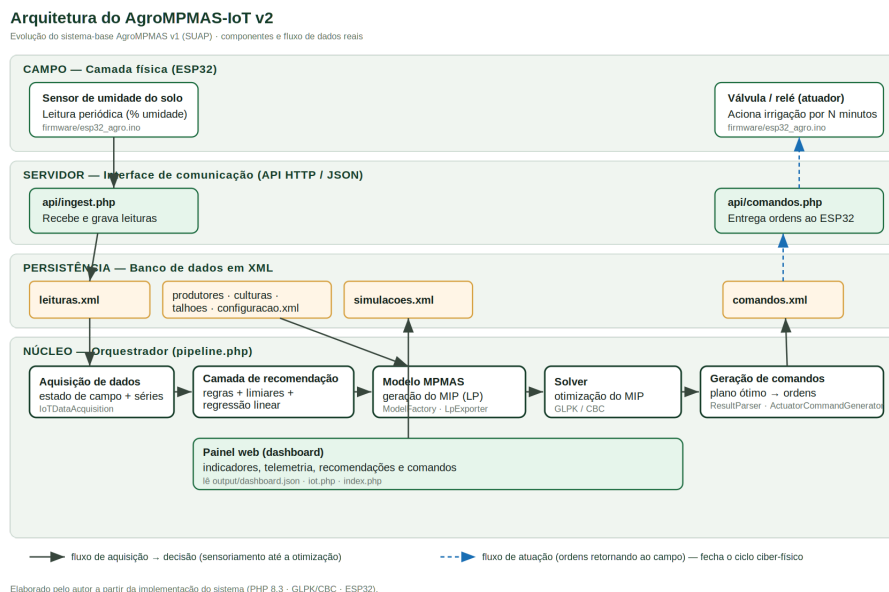


Figura 1. Arquitetura e fluxo operacional do AgroMPMAS-IoT v2.

O sensor envia leituras (api/ingest.php) para a base XML; o orquestrador (pipeline.php) realiza a aquisição, aplica a camada de recomendação baseada em regras e regressão linear, gera e resolve o modelo MPMAS (GLPK/CBC) e produz as ordens de atuação (comandos.xml), entregues ao atuador por api/comandos.php — fechando o ciclo ciberfísico. Elaborado pelo autor a partir da implementação do sistema.

3.2. Componentes da Implementação

A implementação foi organizada em quatro camadas. A camada de campo reúne o ESP32, o sensor de umidade e o atuador. A camada de comunicação disponibiliza endpoints HTTP para recebimento das leituras e consulta aos comandos. A camada de persistência armazena dados de produtores, culturas, talhões, telemetria, cenários e ordens em arquivos XML. Por fim, a camada de aplicação contém o orquestrador, a recomendação baseada em regras, a geração do modelo LP, a chamada ao solver e o painel web. Essa separação permite substituir componentes sem alterar todo o sistema, como trocar XML por banco relacional ou GLPK por CBC.

O fluxo de dados adota uma sequência simples: o dispositivo envia a leitura; a aplicação valida e persiste os valores; o pipeline recupera a série recente; a camada inteligente calcula tendência e déficit; os parâmetros do modelo são atualizados; o solver produz a solução; e o gerador de comandos traduz a decisão para uma instrução operacional. Cada etapa produz um artefato verificável (leitura XML, cenário, arquivo LP, solução e comando), favorecendo rastreabilidade e diagnóstico de falhas.

A Tabela 1 sintetiza as diferenças entre o sistema-base AgroMPMAS v1 e a evolução AgroMPMAS-IoT v2.

Tabela 1. Comparação entre o sistema-base AgroMPMAS v1 (registrado) e a evolução AgroMPMAS-IoT v2.

Dimensão	AgroMPMAS v1 (base registrada)	AgroMPMAS-IoT v2 (evolução)
Interface	Formulários web (PHP + HTML/CSS)	+ painel ciberfísico (telemetria, IA, comandos)
Entrada de dados	Manual, por formulários web	Automática (telemetria IoT) + formulários
Papel do sensor	Binária de custo (nunca adotada)	Fonte de dado e variável de decisão acoplada a benefício
Camada de recomendação	Ausente	Baseada em regras, limiares e regressão linear (auditável)
Atuação	Ausente	Comandos para atuadores (ciclo fechado)
Persistência (XML)	Dados (produtores, culturas, talhões)	+ leituras, cenários e comandos
Solver	GLPK / CBC via arquivo LP	GLPK / CBC via arquivo LP (reaproveitado)

3.3. Formulação Matemática

O modelo representa a decisão de um produtor que, em um horizonte de planejamento, aloca área entre culturas, define a água aplicada e pode investir em tecnologia de irrigação e sensoriamento. Para explicitar a formulação, consideram-se os conjuntos de culturas $c \in C$, setores $s \in S$ e períodos $t \in T$. A Tabela 2 resume os principais parâmetros e variáveis utilizados.

Tabela 2. Símbolos principais da formulação de otimização.

Símbolo	Tipo	Descrição
x_{cst}	Variável contínua	Área destinada à cultura c , no setor s e período t
w_{st}	Variável contínua	Água aplicada no setor s e período t
$wsav_{st}$	Variável contínua	Economia de água habilitada pela irrigação de precisão
$qvenda_{ct}$	Variável contínua	Quantidade comercializada da cultura c no período t
z_s	Variável binária	Adoção da tecnologia de irrigação no setor s
iot_s	Variável binária	Adoção do sensor/telemetria no setor s
A_{st}	Parâmetro	Área disponível no setor e período
W_t	Parâmetro	Oferta total de água no período
n_{cst}	Parâmetro	Necessidade hídrica por unidade de área
ρ	Parâmetro	Taxa máxima de economia de água da irrigação de precisão

M	Parâmetro	Limite superior usado nas restrições de ativação
---	-----------	--

A função objetivo maximiza a renda líquida esperada, descontada no tempo, considerando receitas de venda e custos de produção, água, energia, tecnologia e sensoriamento:

$$\max Z = \sum_t \delta_t \left[\sum_c p_{ct}^{\text{venda}} q_{\text{venda}_{ct}} - \sum_c p_{ct}^{\text{compra}} q_{\text{compra}_{ct}} - \sum_{c,s} C_{cst}^{\text{prod}} x_{cst} - \sum_s C_{st}^{\text{água}} w_{st} - \sum_s C_s^{\text{tec}} \right]$$

1. Terra: $\sum_c x_{cst} \leq A_{st}$, para todo setor s e período t.
2. Disponibilidade hídrica: $\sum_s w_{st} \leq W_t$, para todo período t.
3. Demanda hídrica por setor: $w_{st} + \text{wsave}_{st} \geq \sum_c n_{cs} x_{cs}$
4. Produção e vendas: a produção é limitada pela produtividade por hectare e as vendas
5. Capital: os custos de produção, água, tecnologia e sensores não podem exceder

As variáveis x , w , wsave e quantidades comercializadas são não negativas; z e iot são binárias. O problema resultante é um programa inteiro misto (MIP) resolvido por GLPK ou CBC. Embora o protótipo represente uma propriedade, a estrutura multi-índice preserva a possibilidade de extensão para agentes e múltiplos períodos.

3.3.1. Acoplamento Entre IoT e Benefício Econômico

Na formulação inicial, sensores e tecnologia de irrigação entram apenas pelo lado do custo. Sem um benefício associado, a solução ótima tende a rejeitar ambos, ainda que a interface exiba telemetria. Trata-se de uma limitação estrutural da modelagem: o solver não reconhece valor econômico na informação captada pelo sensor.

Para corrigi-la, introduz-se a irrigação de precisão como um benefício endógeno. Define-se, por setor e período, uma variável contínua não negativa de água economizada, w_{save} , que reduz a necessidade líquida de irrigação na restrição de demanda hídrica. A economia é limitada por duas condições lineares:

$$0 \leq w_{save_{st}} \leq \rho \cdot \sum_c (n_{cst} \cdot x_{cst})$$

$$w_{save_{st}} \geq M \cdot iot_s \quad \text{e} \quad w_{save_{st}} \leq M \cdot z_s$$

A primeira desigualdade limita a economia a uma fração ρ da demanda bruta. As duas restrições de ativação exigem simultaneamente sensor e tecnologia de irrigação: se $iot_s = 0$ ou $z_s = 0$, a economia é forçada a zero. O valor de M deve ser suficientemente alto para não cortar soluções válidas, mas tão ajustado quanto possível para evitar relaxamentos numéricos fracos. Assim, a adoção passa a ser determinada pelo equilíbrio entre o custo fixo dos equipamentos e o valor econômico da água economizada, incluindo o efeito indireto de liberar recurso hídrico para ampliar a área cultivada.

Em termos econômicos, a tecnologia é atraente quando o ganho marginal proporcionado pela redução de água e pela recuperação de produção supera os custos de adoção. De forma simplificada, a condição pode ser expressa por $\Delta\pi = \text{benefício hídrico} + \text{margem da área adicional} - \text{custo do sensor} - \text{custo da tecnologia}$. Essa relação orienta análises de sensibilidade futuras e explica por que a mesma solução pode ser adotada em cenário de escassez e rejeitada quando a água é abundante ou barata.

3.4. Camada Inteligente Baseada em Regras e Previsão

No pipeline, a expressão camada inteligente designa um módulo de apoio à decisão baseado em regras, limiares configuráveis e previsão estatística da umidade do solo. O protótipo não utiliza redes neurais nem modelos supervisionados complexos. Essa escolha preserva transparência, baixo custo computacional e possibilidade de auditoria, características importantes em contextos com poucos dados rotulados e conectividade limitada.

Operacionalmente, a camada executa em PHP puro e realiza quatro procedimentos: (i) ordena e valida a série recente de leituras; (ii) estima a tendência por regressão linear de mínimos quadrados; (iii) projeta a umidade para um horizonte de curto prazo e converte o déficit em fator de ajuste da demanda hídrica; e (iv) classifica a recomendação de irrigação e calcula um índice de confiança proporcional à quantidade de observações válidas. A previsão pode ser representada por $\hat{u}(t+h) = \beta_0 + \beta_1(t+h)$, em que β_0 e β_1 são estimados a partir das leituras e h é o horizonte configurado.

As regras separam previsão e decisão. A regressão informa a direção e a intensidade da mudança; os limiares definem quando a situação requer irrigação; e o modelo de otimização decide se a adoção tecnológica é economicamente coerente com o conjunto de restrições. Essa separação evita atribuir à regressão uma função prescritiva que ela não possui e facilita substituir o método preditivo sem alterar o restante da arquitetura.

3.5. Geração de Comandos e Atuação

Após a otimização, um gerador de comandos combina a solução matemática e a recomendação da camada inteligente. O resultado é traduzido em uma ordem com ação, duração e justificativa, gravada

em XML e disponibilizada por endpoint. O dispositivo de campo consulta esse endpoint periodicamente e aciona a válvula ou o relé. A decisão física permanece condicionada às regras de segurança do atuador, de modo que ausência de comando válido, dado inconsistente ou falha de comunicação deve conduzir ao estado seguro de desligamento.

3.6. Ambiente Computacional e Verificações

A plataforma foi implementada em PHP 8.3, com persistência em XML, geração de arquivo LP e resolução por GLPK (glpsol) ou CBC. O firmware de campo foi escrito para ESP32 em C/Arduino, enviando leituras por HTTP e acionando uma válvula solenoide conforme os comandos recebidos. A distribuição foi preparada para ambiente local XAMPP ou Ubuntu/LAMP. Na verificação do protótipo foram observados: sintaxe dos módulos PHP, criação dos arquivos XML, geração do LP, retorno de solução pelo solver, leitura dos valores ótimos, produção do comando e disponibilidade do endpoint para o ESP32.

Para favorecer a reprodutibilidade, cada execução do pipeline mantém os dados de entrada, o cenário calculado, o modelo LP, a saída do solver e a ordem de atuação. Esses artefatos permitem repetir o experimento, identificar em qual etapa ocorreu uma falha e comparar resultados entre versões do modelo. A equivalência entre GLPK e CBC deve ser verificada pela função objetivo, valores das principais variáveis e status de otimalidade, admitindo pequenas diferenças numéricas decorrentes de tolerâncias dos solvers.

3.7. Delineamento do Experimento Controlado

O experimento foi desenhado para isolar o efeito do acoplamento IoT-benefício. Utilizou-se uma propriedade-exemplo com 10 ha, capital de R\$ 3.000, oferta de 40 unidades de água por período e duas culturas, tomate e alface. A telemetria simulada representou secagem progressiva do solo, com leituras decrescentes de 48% a 20%. A camada inteligente projetou umidade de 10,4%, déficit de 89,6%, fator de ajuste de demanda de 1,43 e recomendação de irrigação por 54 minutos.

Tabela 3. Configuração do experimento controlado.

Elemento	Configuração
Área total	10 ha
Culturas	Tomate e alface
Capital disponível	R\$ 3.000
Oferta hídrica	40 unidades por período
Série de umidade	Queda de 48% para 20%
Previsão de curto prazo	10,4% de umidade
Fator de ajuste da demanda	1,43
Taxa máxima de economia	25% da demanda
Recomendação da camada	Irrigar por 54 minutos
Cenários comparados	Sem acoplamento e com acoplamento IoT-benefício

O procedimento de comparação foi composto por cinco etapas: carregar os mesmos dados de propriedade e telemetria; executar o

pipeline sem permitir economia associada à adoção; registrar lucro, água, área e comando; repetir a execução com as restrições de acoplamento ativadas; e calcular as diferenças relativas. Como todos os demais parâmetros foram preservados, a variação observada é atribuída ao mecanismo que torna o benefício da irrigação de precisão reconhecível pelo otimizador.

Os indicadores escolhidos representam dimensões complementares: o lucro mede o efeito econômico; a água utilizada expressa o resultado ambiental e a folga da restrição hídrica; a área cultivada mostra o impacto sobre o plano produtivo; a adoção revela a decisão de investimento; e a ordem de atuação confirma se a solução matemática foi traduzida para o componente físico.

4. RESULTADOS

4.1. Resposta da Camada Inteligente

A série de umidade em queda produziu inclinação negativa e projeção de 10,4% para o horizonte configurado. A camada inteligente classificou o cenário como crítico, estimou déficit de 89,6% e aplicou fator 1,43 à demanda hídrica. O comando preliminar foi irrigar por 54 minutos, com confiança alta em razão do conjunto de leituras disponível. Esse resultado evidencia que a telemetria não foi apenas exibida no painel: ela alterou um parâmetro de entrada do modelo de otimização.

4.2. Comparação Entre Cenários

Foram comparadas duas configurações: (a) sem o acoplamento de precisão, reproduzindo a lógica em que sensores e tecnologia geram custos, mas não habilitam economia; e (b) com o acoplamento

ativado, no qual a adoção conjunta permite reduzir a demanda efetiva de água. A Tabela 4 apresenta os resultados.

Tabela 4. Efeito do acoplamento IoT–otimização sobre a decisão ótima em cenário de escassez hídrica.

Indicador	Sem precisão	Com precisão	Variação
Lucro ótimo (R\$)	32.224,50	34.396,20	+6,7%
Água utilizada (un.)	40,00	32,11	-19,7%
Área plantada (ha)	9,34	10,00	+7,1%
Adoção (sensor + tecnologia)	não	sim	—
Ordem de atuação	irrigar 54 min	irrigar (precisão) 54 min	—

4.3. Efeito Sobre a Solução Ótima e a Atuação

Sem o acoplamento, a restrição hídrica tornou-se ativa. A oferta de 40 unidades foi integralmente utilizada e, ainda assim, não foi possível cultivar toda a área. A solução reduziu a área plantada para 9,34 ha e rejeitou sensor e tecnologia, pois esses componentes aumentariam o custo sem produzir benefício dentro da formulação. O comportamento é coerente com o modelo, mas revela que a tecnologia permaneceria economicamente invisível.

Com o acoplamento, o solver adotou sensor e tecnologia de irrigação e habilitou economia de 25% da demanda. O consumo caiu para 32,11 unidades, gerando folga de 7,89 unidades em relação ao limite. A área cultivada foi restaurada para 10 ha e o lucro aumentou

para R\$ 34.396,20. A ordem de atuação passou de irrigação convencional para irrigação em modo de precisão por 54 minutos. Assim, a mudança não se restringiu ao indicador financeiro: alterou investimento, alocação de terra, uso de água e ação física.

5. DISCUSSÃO

5.1. Mecanismo Econômico do Acoplamento

O resultado evidencia que o acoplamento não é cosmético. Quando o benefício técnico não aparece nas equações, o solver interpreta sensor e tecnologia como despesas evitáveis. Ao introduzir *wsave*, a informação de campo passa a modificar a região factível do problema: a mesma oferta de água sustenta maior produção, e parte do valor dessa produção remunera o investimento. O aumento de 6,7% no lucro decorre, portanto, da remoção parcial da restrição que limitava a área cultivada.

5.2. Explicabilidade e Adequação a Pequenos Produtores

A opção por regras explícitas e regressão linear é deliberada. Em pequenas propriedades, a capacidade de explicar por que o sistema recomendou irrigar, quais leituras sustentaram a previsão e de que maneira a decisão afetou o resultado econômico pode ser mais importante do que a adoção imediata de modelos opacos. A literatura sobre ferramentas de apoio à decisão destaca que facilidade de uso, credibilidade, transparência e participação do usuário influenciam a adoção (Rose et al., 2016; Lacoste e Powles, 2016).

A arquitetura também separa funções que frequentemente aparecem misturadas. O sensor mede; a regressão prevê; as regras

classificam a situação; o MIP otimiza; e o atuador executa um comando validado. Essa divisão reduz o risco de tratar uma previsão estatística como decisão automática e permite que cada componente seja testado isoladamente. Em versões futuras, um modelo de aprendizado de máquina poderá substituir a regressão, desde que preserve interfaces, rastreabilidade e critérios de segurança.

5.3. Relação com os Trabalhos Existentes

Mössinger, Troost e Berger (2022) mostraram que uma interface leve favorece sessões interativas de modelagem com agricultores e extensionistas. O AgroMPMAS-IoT v2 parte dessa preocupação com acessibilidade, mas avança em outra dimensão: substitui parte da entrada manual por telemetria e conecta o plano ótimo a uma ordem de atuação. Em relação aos FMIS tradicionais, a contribuição é incorporar um núcleo de otimização de fazenda inteira; em relação aos controladores locais de irrigação, é considerar simultaneamente custos, área, água, culturas e investimento.

A comparação não implica que a plataforma substitua sistemas comerciais ou modelos consolidados. O protótipo demonstra um padrão de integração: dados físicos devem ser convertidos em parâmetros economicamente interpretáveis, e a decisão ótima deve retornar ao campo de forma controlada. Esse padrão pode ser reutilizado em outros problemas, como energia, fertilização ou manejo de recursos, desde que o benefício tecnológico seja representado por relações verificáveis.

5.4. Sensibilidade Esperada da Decisão

A adoção não deve ser interpretada como resultado universal. Mantidos os demais parâmetros, maior escassez ou maior custo da água tende a aumentar o valor de w_{save} ; custos mais altos de sensor e tecnologia tendem a reduzir a adoção; e taxas menores de economia diminuem o benefício. Há, portanto, um ponto de equilíbrio em que o ganho gerado pela água economizada e pela área adicional se iguala ao custo fixo do investimento. O cenário analisado situa-se acima desse ponto, mas a sua localização deve ser estimada com dados reais em estudos posteriores.

Uma análise de sensibilidade completa deverá variar, ao menos, preço e disponibilidade de água, custo dos equipamentos, taxa de economia, capital disponível e margem das culturas. Além de testar robustez, essa análise permitirá identificar para quais perfis de propriedade a solução é economicamente relevante e em quais condições o modelo deve recomendar não investir.

6. LIMITAÇÕES E TRABALHOS FUTUROS

O estudo possui limitações que delimitam o alcance dos resultados. O experimento representa uma única propriedade, utiliza parâmetros estilizados e não constitui validação agrônômica ou de campo. A taxa de economia de 25% foi definida externamente e precisa ser calibrada por cultura, tipo de solo, sistema de irrigação e condições climáticas. Da mesma forma, a transformação do déficit previsto em fator de demanda requer validação com especialistas e séries observadas.

A implementação prioriza simplicidade e uso local e acadêmico. Persistência em XML, permissões abertas, chamadas de processo e comunicação HTTP simplificam a instalação, mas exigem

endurecimento antes de qualquer uso produtivo. São necessários autenticação, controle de acesso, validação rígida de entradas, proteção contra injeção de comandos, comunicação segura, registro de auditoria, tratamento de concorrência e políticas de estado seguro para os atuadores. Os resultados devem ser tratados como apoio à discussão e não como recomendação agronômica definitiva.

Como agenda futura, destacam-se: validação de campo com sensores calibrados; análise de sensibilidade e incerteza de preços, clima e eficiência; horizonte multiperíodo para culturas perenes; migração para banco de dados transacional; protocolo MQTT com operação offline-first; testes de usabilidade com agricultores e extensionistas; comparação entre regressão e métodos de aprendizado de máquina; e evolução de uma propriedade para simulação multiagente, capacidade originalmente associada ao MPMAS.

Também é necessário estabelecer um protocolo experimental que registre precisão do sensor, latência de transmissão, tempo de solução, disponibilidade do serviço e correspondência entre comando e atuação. Esses indicadores complementarão os resultados econômicos e permitirão avaliar se a arquitetura atende aos requisitos de um sistema ciberfísico em condições reais.

7. CONCLUSÃO

Este trabalho apresentou o AgroMPMAS-IoT v2, plataforma web de código aberto que integra sensores, recomendação baseada em regras, otimização de fazenda inteira e atuadores. A contribuição central foi formalizar a relação entre telemetria e benefício

econômico da irrigação de precisão, convertendo o sensor de elemento informativo em variável de decisão endógena.

No experimento controlado de escassez hídrica, o acoplamento elevou o lucro ótimo em 6,7%, reduziu o uso de água em 19,7%, restaurou o cultivo integral dos 10 ha e alterou a ordem de atuação para o modo de precisão. Esses resultados respondem à questão de pesquisa ao mostrar que transportar o benefício medido no campo para a formulação matemática modifica efetivamente a solução ótima.

Os achados sustentam a viabilidade conceitual da integração IoT-MPMAS como base para sistemas de apoio à decisão voltados a pequenos produtores. A aplicação prática, entretanto, depende de calibração agronômica, validação de campo, segurança da infraestrutura e avaliação com usuários. A arquitetura modular oferece um caminho para essas extensões sem perder explicabilidade e rastreabilidade.

REFERÊNCIAS BIBLIOGRÁFICAS

ANTLE, J. M.; JONES, J. W.; ROSENZWEIG, C. Next generation agricultural system models and knowledge products: synthesis and strategy. *Agricultural Systems*, v. 155, p. 179-185, 2017. DOI: 10.1016/j.agry.2017.05.006.

ATZORI, L.; IERA, A.; MORABITO, G. The Internet of Things: a survey. *Computer Networks*, v. 54, n. 15, p. 2787-2805, 2010. DOI: 10.1016/j.comnet.2010.05.010.

AYAZ, M.; AMMAD-UDDIN, M.; SHARIF, Z.; MANSOUR, A.; AGGOUNE, E.-H. M. Internet-of-Things (IoT)-based smart agriculture: toward

making the fields talk. IEEE Access, v. 7, p. 129551-129583, 2019. DOI: 10.1109/ACCESS.2019.2932609.

BERGER, T.; TROOST, C. Agent-based modelling of climate adaptation and mitigation options in agriculture. Journal of Agricultural Economics, v. 65, n. 2, p. 323-348, 2014. DOI: 10.1111/1477-9552.12045.

BERNARDI, A. C. C. et al. (org.). Agricultura de precisão: resultados de um novo olhar. Brasília, DF: Embrapa, 2014.

BRITZ, W. A new graphical user interface generator for economic models and its comparison to existing approaches. German Journal of Agricultural Economics, v. 63, n. 4, p. 271-285, 2014. DOI: 10.52825/gjae.v63i4.1964.

CAROLAN, M. Publicising food: big data, precision agriculture, and co-experimental techniques of addition. Sociologia Ruralis, v. 57, n. 2, p. 135-154, 2017. DOI: 10.1111/soru.12120.

COX, P. G. Some issues in the design of agricultural decision support systems. Agricultural Systems, v. 52, n. 2-3, p. 355-381, 1996. DOI: 10.1016/0308-521X(96)00063-7.

FOUNTAS, S. et al. Farm management information systems: current situation and future perspectives. Computers and Electronics in Agriculture, v. 115, p. 40-50, 2015. DOI: 10.1016/j.compag.2015.05.011.

HAZELL, P. B. R.; NORTON, R. D. Mathematical programming for economic analysis in agriculture. New York: Macmillan, 1986.

JANSSEN, S.; VAN ITTERSUM, M. K. Assessing farm innovations and responses to policies: a review of bio-economic farm models. *Agricultural Systems*, v. 94, n. 3, p. 622-636, 2007. DOI: 10.1016/j.agsy.2007.03.001.

KAMILARIS, A.; KARTAKOULLIS, A.; PRENAFETA-BOLDÚ, F. X. A review on the practice of big data analysis in agriculture. *Computers and Electronics in Agriculture*, v. 143, p. 23-37, 2017. DOI: 10.1016/j.compag.2017.09.037.

LACOSTE, M.; POWLES, S. B. Beyond modelling: considering user-centred and post-development aspects to ensure the success of a decision support system. *Computers and Electronics in Agriculture*, v. 121, p. 260-268, 2016. DOI: 10.1016/j.compag.2016.01.003.

MÖSSINGER, J.; TROOST, C.; BERGER, T. Bridging the gap between models and users: a lightweight mobile interface for optimized farming decisions in interactive modeling sessions. *Agricultural Systems*, v. 195, art. 103315, 2022. DOI: 10.1016/j.agsy.2021.103315.

PAHMEYER, C.; KUHN, T.; BRITZ, W. "Fruchtfolge": a crop rotation decision support system for optimizing cropping choices with big data and spatially explicit modeling. *Computers and Electronics in Agriculture*, v. 181, art. 105948, 2021. DOI: 10.1016/j.compag.2020.105948.

ROSE, D. C. et al. Decision support tools for agriculture: towards effective design and delivery. *Agricultural Systems*, v. 149, p. 165-174, 2016. DOI: 10.1016/j.agsy.2016.09.009.

ROSE, D. C.; BRUCE, T. J. A. Finding the right connection: what makes a successful decision support system? *Food and Energy*

Security, v. 7, n. 1, art. e00123, 2018. DOI: 10.1002/fes3.123.

SCHREINEMACHERS, P.; BERGER, T. An agent-based simulation model of human-environment interactions in agricultural systems. *Environmental Modelling & Software*, v. 26, n. 7, p. 845-859, 2011. DOI: 10.1016/j.envsoft.2011.02.004.

SØRENSEN, C. G.; PESONEN, L.; BOCHTIS, D. D.; VOUGIOUKAS, S. G.; SUOMI, P. Functional requirements for a future farm management information system. *Computers and Electronics in Agriculture*, v. 76, n. 2, p. 266-276, 2011. DOI: 10.1016/j.compag.2011.02.005.

TUMMERS, J.; KASSAHUN, A.; TEKINERDOGAN, B. Obstacles and features of farm management information systems: a systematic literature review. *Computers and Electronics in Agriculture*, v. 157, p. 189-204, 2019. DOI: 10.1016/j.compag.2018.12.044.

TZOUNIS, A.; KATSOULAS, N.; BARTZANAS, T.; KITTAS, C. Internet of Things in agriculture, recent advances and future challenges. *Biosystems Engineering*, v. 164, p. 31-48, 2017. DOI: 10.1016/j.biosystemseng.2017.09.007.

VAN WIJK, M. T. et al. Farm household models to analyse food security in a changing climate: a review. *Global Food Security*, v. 3, n. 2, p. 77-84, 2014. DOI: 10.1016/j.gfs.2014.05.001.

WEERSINK, A.; FRASER, E.; PANNELL, D.; DUNCAN, E.; ROTZ, S. Opportunities and challenges for big data in agricultural and environmental analysis. *Annual Review of Resource Economics*, v. 10, p. 19-37, 2018. DOI: 10.1146/annurev-resource-100516-053654.

WOLFERT, S.; GE, L.; VERDOUW, C.; BOGAARDT, M.-J. Big data in smart farming: a review. *Agricultural Systems*, v. 153, p. 69-80, 2017. DOI: 10.1016/j.agsy.2017.01.023.

ZHANG, N.; WANG, M.; WANG, N. Precision agriculture: a worldwide overview. *Computers and Electronics in Agriculture*, v. 36, n. 2-3, p. 113-132, 2002. DOI: 10.1016/S0168-1699(02)00096-0.

¹ E-mail: [acesse o artigo original para visualizar o e-mail](#). ORCID: <https://orcid.org/0009-0000-1411-5173>

² E-mail: [acesse o artigo original para visualizar o e-mail](#). ORCID: <https://orcid.org/0009-0008-0122-9639>

³ E-mail: [acesse o artigo original para visualizar o e-mail](#). ORCID: <https://orcid.org/0009-0008-6383-4834>

⁴ E-mail: [acesse o artigo original para visualizar o e-mail](#). ORCID: <https://orcid.org/0009-0007-6864-2332>

⁵ E-mail: [acesse o artigo original para visualizar o e-mail](#)

⁶ E-mail: [acesse o artigo original para visualizar o e-mail](#)