

Um Modelo de Referência para Sistemas Híbridos Inteligentes voltados à Avicultura 4.0

Renato Vasconcelos Mendes
Programa de Pós-Graduação em
Informática Aplicada (PPGIA),
Universidade Federal Rural de
Pernambuco (UFRPE)
Recife, PE, Brasil
renato.mendes@ufrpe.br

Obionor de Oliveira Nóbrega
Departamento de Computação (DC),
Universidade Federal Rural de
Pernambuco (UFRPE)
Recife, PE, Brasil
obionor.nobrega@ufrpe.br

Ricardo André Cavalcante de
Souza
Departamento de Computação (DC),
Universidade Federal Rural de
Pernambuco (UFRPE)
Recife, PE, Brasil
ricardo.souza@ufrpe.br

Resumo

A Avicultura 4.0 consolidou o uso de infraestruturas IoT e modelos de Inteligência Artificial para monitoramento ambiental e predição de indicadores produtivos. Entretanto, apesar da maturidade alcançada nas camadas de sensoriamento e inferência analítica, sistemas atuais permanecem predominantemente orientados à geração de alertas e *dashboards* isolados, mantendo a interpretação operacional concentrada no especialista humano. Este trabalho propõe um modelo de referência para integração entre monitoramento ambiental, inferência analítica e suporte interpretativo em sistemas inteligentes aplicados à avicultura de postura. A principal contribuição da proposta está na definição de um modelo de referência arquitetural baseado em desacoplamento entre suas camadas funcionais e contratos inferenciais. Nesse contexto, define-se a abstração arquitetural *Machine Learning-as-a-Sensor (ML-as-a-Sensor)*, na qual modelos de *Machine Learning* passam a atuar como produtores de sinais inferenciais estruturados reutilizáveis pelas camadas superiores do sistema. A proposta organiza-se em quatro camadas funcionais: Aquisição e Infraestrutura, Processamento Analítico (*ML-as-a-Sensor*), Fusão Contextual e Suporte Interpretativo. Além disso, integra IA preditiva e IA generativa por meio do uso de *Large Language Models* (LLMs), prevenindo a incorporação de mecanismos de recuperação contextual de informações, como *Retrieval-Augmented Generation* (RAG), e da abordagem *Human-in-the-loop* para geração de recomendações contextualizadas de apoio à decisão. Um cenário operacional de estresse térmico em galinhas poedeiras é apresentado para exemplificar o fluxo operacional proposto. Embora o trabalho possua natureza conceitual e não inclua validação experimental, busca contribuir para a discussão sobre modelos de referência para sistemas híbridos inteligentes distribuídos, explorando interoperabilidade, desacoplamento e integração entre IA analítica e IA generativa em ambientes ciberfísicos.

Palavras-chave

Arquitetura de Software, Sistemas Ciberfísicos, Sistemas Híbridos Inteligentes, *ML-as-a-Sensor*, IA Preditiva e Generativa, Avicultura 4.0

1 Introdução

A avicultura de postura desempenha papel estratégico na segurança alimentar e no agronegócio global, com demanda projetada para crescer 39% até 2030 [9]. No Brasil, o setor alcançou produção de aproximadamente 57,7 bilhões de ovos em 2024, consolidando o país como o 5º maior produtor mundial [2]. A rentabilidade e a

sustentabilidade operacional dependem diretamente da precisão e da velocidade de resposta do controle ambiental, visto que variações microclimáticas inadequadas podem reduzir a taxa de postura e elevar a mortalidade do lote [7, 13, 31]. Assim, a gestão de riscos operacionais depende da identificação precoce de alterações ambientais e da adoção de ações de manejo antes que essas condições se materializem em perdas produtivas.

Para mitigar esses riscos, o setor atravessa a transição para a Avicultura 4.0, caracterizada pela aplicação de princípios da Indústria 4.0 e Internet das Coisas (IoT) para promover monitoramento contínuo e manejo de precisão em ambientes avícolas por meio de sistemas ciberfísicos (*Cyber-Physical Systems* – CPS), integrando infraestrutura computacional distribuída e processos físicos do ambiente produtivo [8, 9, 24]. Como parte dessa evolução, consolidou-se o uso de arquiteturas distribuídas no continuum *Edge-Fog-Cloud*, no qual processamento, armazenamento e transmissão de dados são distribuídos entre dispositivos de borda (*Edge*), nós intermediários (*Fog*) e serviços centralizados em nuvem (*Cloud*), viabilizando aquisição contínua e processamento escalável de dados ambientais [4, 20]. Paralelamente, algoritmos de Aprendizado de Máquina (*Machine Learning* – ML), como Random Forest e XGBoost, vêm sendo empregados na predição de indicadores zootécnicos e na detecção de condições ambientais críticas [14, 19].

Contudo, apesar da maturidade alcançada nas camadas de sensoriamento e inferência analítica, persiste uma lacuna arquitetural relacionada à integração entre monitoramento contínuo, inferência analítica e suporte à gestão de riscos operacionais. Os sistemas atuais permanecem predominantemente orientados à geração de alertas e *dashboards* analíticos, exigindo que o produtor interprete dados heterogêneos, correlacione inferências analíticas e converta essas informações em ações práticas de manejo [8, 18, 26]. Como eventos críticos podem ocorrer continuamente ao longo da operação e essa interpretação depende da atuação do especialista humano, a identificação de situações de risco e a adoção de respostas preventivas podem ocorrer de forma tardia.

Para endereçar essa lacuna, este trabalho propõe um modelo de referência para sistemas híbridos inteligentes. Em vez de introduzir um novo modelo preditivo ou uma nova plataforma de monitoramento, a proposta concentra-se na organização arquitetural da integração entre aquisição de dados, inferência analítica, contextualização operacional e suporte interpretativo. O modelo de referência atua como um pipeline arquitetural intermediário entre a infraestrutura de monitoramento e os sistemas de apoio ao manejo.

O modelo organiza-se em quatro camadas funcionais: (i) Aquisição e Infraestrutura; (ii) Processamento Analítico (*ML-as-a-Sensor*); (iii) Fusão Contextual; e (iv) Suporte Interpretativo baseado em *Large Language Models* (LLMs). Sua principal contribuição científica consiste na definição da abstração arquitetural *ML-as-a-Sensor*, que reposiciona modelos preditivos como sensores lógicos produtores de sinais inferenciais estruturados para consumo pelas camadas superiores do modelo de referência [15, 29].

Sob a perspectiva arquitetural, a proposta organiza essas capacidades em um modelo de referência em camadas, preservando a separação entre aquisição de dados, processamento analítico, contextualização operacional e suporte interpretativo. Sob a perspectiva operacional, busca integrar inferências analíticas e contexto operacional para apoiar o processo de tomada de decisão, mantendo o especialista humano na malha de controle (*Human-in-the-loop*) [26].

1.1 Contribuições

Este trabalho apresenta as seguintes contribuições:

- Um modelo de referência em camadas para sistemas híbridos inteligentes aplicados à Avicultura 4.0, integrando IA preditiva e IA generativa para suporte operacional contextualizado;
- A definição da abstração arquitetural *ML-as-a-Sensor* para produção de sinais inferenciais estruturados.

O restante deste artigo está organizado da seguinte forma: a Seção 2 discute as limitações das abordagens atuais na Avicultura 4.0; a Seção 3 apresenta o modelo de referência proposto e suas camadas funcionais; a Seção 4 descreve um cenário operacional ilustrativo para exemplificar o fluxo de suporte à decisão; a Seção 5 discute as implicações, limitações e desafios da proposta; por fim, a Seção 6 apresenta as conclusões e perspectivas futuras do trabalho.

2 Limitações das Abordagens Atuais

A literatura recente demonstra elevada maturidade técnica na Avicultura 4.0, especialmente nas camadas de monitoramento ambiental e inferência analítica. Infraestruturas distribuídas baseadas no continuum *Edge-Fog-Cloud* consolidaram o monitoramento contínuo de variáveis biometeorológicas, enquanto modelos de *Machine Learning* vêm sendo utilizados com elevada acurácia para previsão de indicadores produtivos e detecção de condições ambientais críticas [4, 9, 14, 19, 20].

Apesar desses avanços, a literatura evidencia soluções predominantemente orientadas à geração de alertas técnicos, *dashboards* e inferências isoladas [8, 18, 26]. Nesses cenários, a interpretação contextual das informações continua concentrada no especialista humano, responsável por correlacionar variáveis heterogêneas e converter diagnósticos analíticos em ações práticas de manejo [11]. Como consequência, a gestão de riscos operacionais permanece fortemente dependente dessa interpretação humana, que normalmente ocorre de forma pontual ao longo da operação. Essa limitação amplia a lacuna entre a identificação de situações críticas e a adoção oportuna de ações preventivas. Embora abordagens recentes indiquem potencial para utilização de IA Generativa em ambientes agroindustriais [23], ainda não se observam abordagens estruturadas voltadas à integração entre modelos preditivos e mecanismos

interpretativos de apoio à decisão. Falta uma camada intermediária capaz de tratar inferências de *Machine Learning* como sinais lógicos reutilizáveis e integrá-los a processos interpretativos contextualizados [15, 29].

A Tabela 1 sintetiza essa evolução ao comparar sistemas tradicionais baseados em limiares, soluções preditivas orientadas a modelos analíticos e a abordagem híbrida proposta neste trabalho.

3 Modelo de Referência Proposto

A Figura 1 apresenta a visão geral do modelo proposto para integração entre monitoramento ambiental, inferência analítica e suporte à decisão na Avicultura 4.0. Seu objetivo é estabelecer um modelo de referência para sistemas híbridos inteligentes capazes de transformar dados ambientais e operacionais em recomendações contextualizadas de manejo [8, 23].




Figura 1: Modelo de referência proposto.

A proposta opera como um *pipeline* intermediário de suporte interpretativo consumido por sistemas operacionais de manejo, separando aquisição de dados, inferência analítica, contextualização operacional e interação humana em componentes independentes.

Tabela 1: Evolução dos sistemas de monitoramento e suporte operacional na Avicultura 4.0.

Atributo	Sistemas Tradicionais	Sistemas Preditivos (ML)	Modelo Proposto
Lógica de Controle	Reativa, fundamentada em limiares técnicos fixos e regras “se-então” determinísticas [18, 23].	Análítica, baseada na detecção de padrões estatísticos e séries temporais [9, 14].	Interpretativa, baseada em integração contextual e suporte operacional assistivo [23, 30].
Natureza da Saida	Alertas técnicos binários, notificações de violação de limites e gatilhos simples de automação [11, 18].	Previsões de indicadores zootécnicos (HDEP, FCR) e <i>dashboards</i> analíticos [10, 25].	Recomendações contextualizadas em linguagem natural para apoio à decisão [23, 30].
Papel do Modelo de IA	Frequentemente inexistente ou restrito a lógicas de controle reativas [23, 26].	Atua predominantemente como mecanismo analítico para previsão e visualização [8].	Componente inferencial reutilizável (<i>ML-as-a-Sensor</i>) integrado ao fluxo operacional do modelo [3, 29].
Integração de Contexto	Baixa: focada em variáveis biometeorológicas isoladas [13, 18].	Média: correlaciona múltiplas variáveis ambientais e produtivas, mas com baixa integração contextual [1, 14].	Alta: integração entre dados ambientais, inferências analíticas e eventos operacionais [8, 30].
Interoperabilidade	Baixa: dependência de hardwares proprietários e protocolos fechados [4, 6].	Média: integração via serviços em nuvem e APIs estruturadas [10, 20].	Baseada em desacoplamento estrutural por meio de sinais inferenciais padronizados [29].
Carga Cognitiva	Elevada: exige monitoramento manual constante e interpretação empírica do produtor [11, 26].	Moderada: o especialista ainda precisa correlacionar inferências analíticas para definir ações [18, 26].	Reduzida: suporte interpretativo assistivo mantendo o humano na malha de controle (<i>Human-in-the-loop</i>) [23, 26].

3.1 Visão Geral

Esse pipeline é organizado em quatro camadas funcionais responsáveis pela aquisição de dados, geração de inferências analíticas, consolidação contextual e suporte interpretativo. Essa estrutura favorece a separação de responsabilidades, a modularidade e a evolução independente dos componentes arquiteturais, alinhando-se aos princípios de projeto adotados em arquiteturas para sistemas de gerenciamento agrícola baseados em IoT (*Farm Management Information Systems – FMIS*) [16].

Cada camada é representada por uma cor distinta na Figura 1 – marrom (Aquisição e Infraestrutura), vermelho (Processamento Analítico – *ML-as-a-Sensor*), amarelo (Fusão Contextual) e verde (Suporte Interpretativo) – apenas para facilitar sua identificação visual.

O principal diferencial da proposta está no desacoplamento entre infraestrutura de monitoramento, modelos analíticos e mecanismos interpretativos. Em vez de consumir diretamente dados brutos dos sensores, a camada superior opera sobre um contexto operacional previamente consolidado pelas camadas intermediárias.

3.2 Camada 1 – Aquisição e Infraestrutura

A primeira camada é responsável pela coleta contínua das variáveis ambientais e de consumo do aviário, utilizando infraestruturas IoT distribuídas e arquiteturas *Edge-Fog-Cloud* [4, 20]. Inserida no contexto de sistemas ciberfísicos aplicados à Avicultura 4.0, essa camada integra sensores e infraestrutura computacional distribuída para aquisição contínua de dados ambientais.

3.3 Camada 2 – Processamento Analítico (*ML-as-a-Sensor*)

Nessa camada, modelos de *Machine Learning* passam a atuar como componentes intermediários responsáveis pela geração de sinais

inferenciais reutilizáveis dentro do fluxo operacional do sistema. Algoritmos como Random Forest, XGBoost e Redes Neurais vêm sendo utilizados na Avicultura 4.0 para previsão de indicadores produtivos e detecção de condições ambientais críticas [9, 14, 19]. Os modelos processam continuamente os dados ambientais para produzir inferências associadas a eventos operacionais, como risco de estresse térmico ou redução da taxa de postura.

A abordagem aproxima-se conceitualmente dos *Soft Sensors* utilizados na indústria de processos, nos quais modelos analíticos inferem estados operacionais a partir de variáveis observáveis [15]. Trabalhos recentes vêm ampliando esse paradigma com integração de técnicas de *Machine Learning* e arquiteturas híbridas voltadas ao monitoramento operacional [22]. Nesse contexto, a camada *ML-as-a-Sensor* aplica essa lógica ao domínio avícola ao tratar inferências analíticas como sinais reutilizáveis dentro do fluxo operacional do sistema.

Os modelos deixam de atuar apenas como mecanismos finais de análise e passam a disponibilizar sinais inferenciais estruturados consumidos pelas camadas superiores da proposta. Esses sinais encapsulam informações relacionadas ao evento inferido, nível de confiança, impacto estimado e horizonte temporal da predição.

A Listagem 1 mostra um exemplo de sinal inferencial padronizado da camada *ML-as-a-Sensor*.

A padronização desses sinais inferenciais permite que diferentes modelos analíticos interoperem com as camadas superiores da proposta por meio de contratos inferenciais independentes da implementação específica dos modelos preditivos [27]. Essa abordagem favorece modularidade e evolução incremental dos componentes analíticos.

Enquanto a proposta de *Machine Learning Sensors* apresentada por [29] enfatiza a integração entre sensores físicos e processamento embarcado, a camada *ML-as-a-Sensor* concentra-se no papel

estrutural das inferências produzidas pelos modelos dentro do fluxo operacional do sistema.

Listagem 1: Exemplo de sinal inferencial estruturado produzido pela camada *ML-as-a-Sensor*

```
{
  "event": "production_drop_risk",
  "confidence": 0.85,
  "predicted_impact": "-15%",
  "horizon": "48h"
}
```

3.4 Camada 3 – Fusão Contextual

A Camada de Fusão Contextual é responsável por integrar dados ambientais, sinais inferenciais e informações operacionais em um contexto estruturado para suporte à decisão.

A integração ocorre por meio da consolidação de leituras ambientais, sinais inferenciais produzidos pela camada *ML-as-a-Sensor* e metadados provenientes dos sistemas de manejo, incluindo idade do lote, linhagem, histórico produtivo e eventos operacionais relevantes [8]. Nessa etapa, diferentes sinais, indicadores contextuais e informações operacionais são organizados em um contexto operacional estruturado, preservando sua origem, nível de confiança e informações contextuais para consumo pelas camadas superiores.

Como resultado, a camada produz um contexto operacional compartilhado consumido pela Camada de Suporte Interpretativo, permitindo correlacionar simultaneamente variáveis ambientais, inferências preditivas e informações operacionais do aviário. Mecanismos de representação do conhecimento, como ontologias de domínio, podem ser empregados para estruturar esse contexto e explicitar relações entre seus elementos.

3.5 Camada 4 – Suporte Interpretativo

A Camada de Suporte Interpretativo recebe o contexto operacional consolidado produzido pela Camada 3 e utiliza LLMs para correlacionar variáveis ambientais, sinais inferenciais e metadados operacionais [23, 30]. Como resultado, produz recomendações contextualizadas em linguagem natural para apoio ao manejo avícola, preservando a interpretação integrada do contexto operacional.

Para aumentar confiabilidade e reduzir respostas inconsistentes, a arquitetura pode incorporar mecanismos de recuperação contextual de informações, como *Retrieval-Augmented Generation* (RAG) [17], restringindo a geração das recomendações a bases previamente validadas, incluindo protocolos de manejo, manuais de linhagem, diretrizes de bem-estar animal e documentos técnicos especializados. Com isso, a camada interpretativa passa a operar sobre conhecimento contextualizado ao domínio avícola, reduzindo dependência de conhecimento genérico dos LLMs e contribuindo para diminuir a fragmentação entre monitoramento ambiental, inferência analítica e suporte operacional à decisão.

4 Cenário Operacional

Esta seção apresenta um cenário operacional construído a partir de evidências reportadas na literatura recente sobre monitoramento

ambiental e predição de desempenho produtivo em Avicultura 4.0 [9, 14]. O objetivo é exemplificar como o modelo proposto integra monitoramento ambiental, inferência analítica e suporte interpretativo em um fluxo contínuo de apoio à decisão.

4.1 Predição de Desempenho Produtivo

A predição da taxa de postura (*Hen-Day Egg Production* – HDEP) é amplamente utilizada como indicador crítico de desempenho produtivo. Abordagens recentes baseadas em *Machine Learning*, como LSTM e XGBoost, vêm incorporando múltiplas variáveis ambientais e produtivas para reduzir erros de predição em ambientes avícolas dinâmicos [9, 14]. Apesar dos avanços analíticos, essas soluções ainda produzem inferências predominantemente isoladas, exigindo interpretação manual por parte do produtor ou especialista [8, 26].

4.2 Fluxo Operacional do Modelo Proposto

A Figura 2 apresenta o cenário operacional utilizado para exemplificar o funcionamento do modelo de referência proposto em uma situação de estresse térmico em galinhas poedeiras. O fluxo ilustra a integração entre monitoramento ambiental, inferência analítica, fusão contextual e suporte interpretativo no processo de apoio à decisão.

Considere um galpão de postura contendo 10.000 aves da linhagem Dekalb White, em fase de pico produtivo, equipado com ventilação por pressão negativa e sistema de resfriamento evaporativo.

O fluxo inicia-se na Camada 1 – Aquisição e Infraestrutura, responsável pelo monitoramento contínuo do ambiente aviário. Sensores IoT distribuídos no galpão registram temperatura ambiente de 34,2°C, umidade relativa de 78% e concentração de amônia (NH₃) em 25 ppm, indicando degradação das condições térmicas e da qualidade do ar [4, 7]. Simultaneamente, o sistema de monitoramento registra um consumo hídrico total de 4.262 L/dia no galpão monitorado.

Na Camada 2 – Processamento Analítico (*ML-as-a-Sensor*), modelos preditivos processam continuamente os dados ambientais provenientes da infraestrutura IoT. Um modelo XGBoost utilizado para previsão de desempenho produtivo [14] gera sinais inferenciais associados ao risco de queda da HDEP, incluindo probabilidade estimada, impacto produtivo e horizonte temporal da predição.

Em seguida, a Camada 3 – Fusão Contextual integra leituras ambientais, sinais inferenciais e informações operacionais provenientes do sistema de manejo, incluindo idade do lote, linhagem, histórico produtivo e eventos recentes de alteração nutricional. Nessa etapa, também é calculado o Índice de Temperatura e Umidade (THI), cujo valor atinge 89, indicando condição severa de estresse térmico para o lote analisado [23]. O processo de fusão contextual correlaciona os sinais ambientais, produtivos e operacionais com os padrões esperados para a linhagem e fase produtiva monitoradas, identificando que o consumo hídrico registrado de 4.262 litros/dia representa aumento aproximado de 28% em relação à média esperada para aves Dekalb White com 32 semanas, excedendo o incremento normalmente esperado para a condição de estresse térmico identificada. O contexto operacional consolidado passa então a correlacionar simultaneamente o risco preditivo de queda produtiva, o aumento no consumo hídrico e a troca recente da formulação nutricional.




Figura 2: Cenário operacional utilizando o modelo proposto.

O contexto consolidado é então encaminhado para a Camada 4 – Suporte Interpretativo, que utiliza LLMs associados a mecanismos de RAG para correlacionar sinais inferenciais com protocolos de manejo, manuais nutricionais e diretrizes de bem-estar animal previamente validados [23, 30].

Como resultado, o sistema pode gerar uma recomendação interpretativa como:

“ALERTA DE MANEJO: risco elevado de queda na taxa de postura identificado no galpão A1. O modelo preditivo estima redução de até 15% na produção nas próximas 48 horas, representando perda potencial aproximada de 1.500 ovos por dia para o lote monitorado. O aumento no consumo de água após a troca recente da ração sugere possível excesso de sódio na nova formulação nutricional. Recomenda-se análise

da amostra da ração, revisão dos níveis de ventilação e antecipação do acionamento do sistema evaporativo.”

A recomendação é então disponibilizada ao produtor por meio do sistema de manejo e interface operacional. Seguindo o paradigma *Human-in-the-loop*, a decisão final permanece sob responsabilidade do operador humano [26].

4.3 Integração entre Modelo de Referência e Sistema Operacional

A proposta desacopla monitoramento ambiental, inferência analítica e geração de recomendações. Nesse contexto, a camada de Suporte Interpretativo não acessa diretamente sensores físicos nem executa ações de manejo, produzindo recomendações consumidas pelo sistema operacional utilizado pelo produtor.

Essa separação em camadas permite substituir sensores, atualizar modelos analíticos ou incorporar novas fontes de contexto sem necessidade de modificar a lógica interpretativa das camadas superiores [18, 26].

5 Discussão

O modelo de referência proposto organiza a integração entre aquisição de dados, inferência analítica, contextualização operacional e suporte interpretativo por meio de uma arquitetura em camadas, evidenciando implicações relevantes para a Engenharia de Software. Em vez de acoplar sensores, modelos preditivos e aplicações operacionais em fluxos monolíticos, a arquitetura organiza essas responsabilidades em componentes independentes, favorecendo modularidade, extensibilidade e evolução incremental do sistema.

Dentro dessa organização em camadas, a abstração arquitetural *ML-as-a-Sensor* estabelece um contrato inferencial entre os componentes analíticos e as camadas superiores, permitindo incorporar, substituir ou especializar modelos preditivos sem alterar os mecanismos interpretativos. Sob a perspectiva da Engenharia de Software, essa organização favorece modularidade, interoperabilidade e desacoplamento entre componentes distribuídos, alinhando-se aos princípios clássicos de decomposição modular de sistemas [5, 21].

A arquitetura proposta separa explicitamente a organização do sistema das regras específicas da aplicação. Enquanto sensores, variáveis monitoradas e regras de manejo dependem da aplicação, a organização em camadas e os contratos inferenciais permanecem estáveis independentemente do domínio.

Diferentemente de abordagens centradas em *Soft Sensors* e *Machine Learning Sensors*, a contribuição deste trabalho não está na proposição de novos mecanismos de inferência. A novidade científica reside na definição de um modelo de referência arquitetural baseado em contratos inferenciais e desacoplamento entre suas camadas funcionais.

A integração entre IA preditiva e IA generativa representa outra implicação relevante dessa organização em camadas. Enquanto modelos analíticos permanecem responsáveis pela detecção de padrões e geração de estimativas probabilísticas, os LLMs atuam como mecanismos interpretativos capazes de correlacionar simultaneamente sinais ambientais, eventos operacionais e sinais inferenciais produzidos pelas camadas inferiores.

Quando aplicada em ambientes produtivos reais, essa organização arquitetural poderá ampliar a interpretação contextual do

ambiente, antecipando situações de risco e produzindo recomendações de apoio ao especialista, que permanece responsável pela decisão final.

Essa separação arquitetural também favorece a evolução tecnológica da solução ao longo do tempo. Além disso, a organização arquitetural proposta está alinhada às tendências recentes de arquiteturas para agricultura inteligente, que buscam integrar fontes heterogêneas de dados, modelos analíticos e mecanismos avançados de apoio à decisão em estruturas modulares e evolutivas [16, 28]. O modelo de referência permanece independente de tecnologias específicas, permitindo incorporar diferentes mecanismos de aquisição, processamento e representação das informações sem alterações em sua organização arquitetural [12].

Em ambientes biologicamente dinâmicos, decisões operacionais dependem simultaneamente de variáveis ambientais, produtivas, nutricionais e estruturais. Nesse cenário, mecanismos interpretativos baseados em LLMs permitem produzir recomendações contextualizadas sem necessidade de representar explicitamente todas as combinações possíveis de estados operacionais por meio de regras determinísticas rígidas. Assim, a camada interpretativa atua como mecanismo de orquestração contextual das inferências produzidas pelos modelos analíticos, e não como substituição dos mecanismos preditivos ou do especialista humano.

Por outro lado, a utilização de LLMs em sistemas de suporte operacional introduz desafios relacionados à confiabilidade, rastreabilidade e controle das recomendações produzidas. Para mitigá-los, a arquitetura pode incorporar mecanismos de RAG [17], restringindo a geração das recomendações a protocolos de manejo, documentos técnicos e diretrizes previamente validadas, reduzindo a dependência de conhecimento genérico dos LLMs.

Além disso, a separação entre inferência analítica e geração de recomendações favorece maior auditabilidade do fluxo decisório, permitindo rastrear quais sinais inferenciais e elementos contextuais contribuíram para determinada recomendação operacional. A adoção do paradigma *Human-in-the-loop* reforça esse aspecto ao manter a decisão final sob responsabilidade do produtor ou especialista humano, equilibrando automação analítica e supervisão humana em ambientes caracterizados por elevada variabilidade operacional e biológica.

Embora o presente trabalho tenha foco predominantemente arquitetural, a proposta não se limita a uma construção puramente conceitual. A implementação e a avaliação experimental do modelo de referência constituem as próximas etapas da pesquisa, permitindo avaliar a aplicabilidade da arquitetura em ambientes produtivos reais e investigar aspectos relacionados aos contratos inferenciais, incluindo sua evolução, rastreabilidade e interoperabilidade entre componentes.

O cenário operacional apresentado demonstra a aplicabilidade do fluxo arquitetural proposto, evidenciando a integração entre monitoramento ambiental, inferência analítica, fusão contextual e suporte interpretativo. Entretanto, aspectos relacionados à qualidade e consistência das recomendações geradas, latência operacional, sincronização de eventos, persistência contextual e impacto efetivo sobre indicadores zootécnicos permanecem como desafios em aberto, cuja investigação depende de experimentação em condições reais de produção avícola.

6 Conclusão

Este trabalho apresentou um modelo de referência para sistemas híbridos inteligentes aplicados à Avicultura 4.0, estruturado para integrar monitoramento ambiental, inferência analítica e suporte interpretativo em um fluxo arquitetural desacoplado.

Entre as contribuições do trabalho, destacam-se a proposição de um modelo de referência arquitetural para integração de IA preditiva e IA generativa em sistemas híbridos inteligentes e a definição da abstração arquitetural *ML-as-a-Sensor* como mecanismo de integração entre modelos preditivos e as camadas superiores do sistema. Essa organização arquitetural favorece o desacoplamento entre modelos analíticos e mecanismos interpretativos, criando condições para a evolução independente desses componentes em sistemas híbridos inteligentes.

Como trabalhos futuros, pretende-se avançar na implementação de um protótipo funcional integrado ao modelo proposto e realizar validações experimentais em ambientes produtivos reais. Essas investigações buscarão responder questões como: em que medida a abstração *ML-as-a-Sensor* favorece modularidade, evolutibilidade e rastreabilidade em comparação com arquiteturas fortemente acopladas? Qual abordagem baseada em modelos de linguagem é mais adequada ao suporte interpretativo da arquitetura proposta? Como mecanismos de recuperação contextual, persistência contextual e representação do conhecimento podem ampliar a qualidade, a interoperabilidade e a auditabilidade das recomendações produzidas? Como incorporar o feedback de especialistas ao refinamento contínuo da base de conhecimento sem comprometer a rastreabilidade e a confiabilidade do processo decisório? Como aspectos relacionados à sincronização de eventos, latência operacional e impacto sobre indicadores zootécnicos influenciam a aplicação do modelo em cenários biologicamente sensíveis?

Embora o cenário ilustrativo esteja centrado na Avicultura 4.0, o modelo de referência foi concebido de forma independente das regras específicas da aplicação. Assim, seus princípios arquiteturais podem ser adaptados a diferentes sistemas ciberfísicos baseados em IoT, especialmente em cenários que demandem integração entre monitoramento contínuo, inferência analítica, fusão contextual e suporte operacional contextualizado, contribuindo para o desenvolvimento de sistemas híbridos inteligentes mais modulares, evolutivos e interoperáveis.

Disponibilidade de Artefatos

Não há artefatos disponíveis para este trabalho.

Agradecimentos

Ferramentas de Inteligência Artificial generativa foram utilizadas para elaboração preliminar de elementos textuais e visuais deste manuscrito. As contribuições científicas, decisões técnicas e conteúdo final permaneceram sob responsabilidade integral dos autores.

Referências

- [1] Danung Nur Adli, Tirana Noor Fatyanosa, Fais Al Huda, Mohammad Miftakhus Sholikin, and Sugiharto Sugiharto. 2025. Modelling the growth performance and thermal environment of broiler chicken houses via different machine learning algorithms assisted by a customized Internet of Things. *Smart Agricultural Technology* 12 (2025), 101421. doi:10.1016/j.atech.2025.101421

- [2] Associação Brasileira de Proteína Animal (ABPA). 2025. Relatório Anual ABPA 2025. 67 pages. <https://abpa-br.org/wp-content/uploads/2025/04/ABPA-Relatorio-Anual-2025.pdf> Acesso em: 23 maio 2026.
- [3] Glauber da Rocha Balthazar, Robson Mateus Freitas Silveira, and Iran José Oliveira da Silva. 2024. Use of Multi-Agent Systems and the Internet of Things to Monitor the Environment of Commercial Broiler Poultry Houses Through Specific Air Enthalpy. *Journal of Animal Behaviour and Biometeorology* 12, 2 (May 2024), 2024012. doi:10.31893/jabb.2024012
- [4] Vandirleya Barbosa, Arthur Sabino, Luiz Nelson Lima, Carlos Brito, Leonel Feitosa, Paulo Pereira, Paulo Maciel, Tuan Anh Nguyen, and Francisco Airton Silva. 2024. Performance Evaluation of IoT-Based Industrial Automation Using Edge, Fog, and Cloud Architectures. *Journal of Network and Systems Management* 33, 1 (12 Dec. 2024), 15. doi:10.1007/s10922-024-09893-x
- [5] Len Bass, Paul Clements, and Rick Kazman. 2021. *Software Architecture in Practice* (4 ed.). Addison-Wesley Professional, Boston, MA, USA. 464 pages.
- [6] Adrian Batuto, Timothy Bryan Dejeron, Paolo Dela Cruz, and Mary Jane C. Samonte. 2020. e-Poultry: An IoT Poultry Management System for Small Farms. In *2020 IEEE 7th International Conference on Industrial Engineering and Applications (ICIEA)*. IEEE, Bangkok, Thailand, 738–742. doi:10.1109/ICIEA49774.2020.9102040
- [7] Sejal Bhattad, Ahmed Abdelmoamen Ahmed, Ahmed A. A. Abdel-Wareth, and Jayant Lohakare. 2025. An IoT-Based System for Measuring Diurnal Gas Emissions of Laying Hens in Smart Poultry Farms. *AgriEngineering* 7, 8 (2025), 267. doi:10.3390/agriengineering7080267
- [8] Nikolajs Bumanis, Irina Arhipova, Liga Paura, Gatis Vitols, and Liga Jankovska. 2022. Data Conceptual Model for Smart Poultry Farm Management System. *Procedia Computer Science* 200 (2022), 517–526. doi:10.1016/j.procs.2022.01.249
- [9] Nikolajs Bumanis, Armands Kviesis, Liga Paura, Irina Arhipova, and Mihails Adjutovs. 2023. Hen Egg Production Forecasting: Capabilities of Machine Learning Models in Scenarios with Limited Data Sets. *Applied Sciences* 13, 13 (2023), 7607. doi:10.3390/app13137607
- [10] Nikolajs Bumanis, Armands Kviesis, Anastasiya Tjukova, Irina Arhipova, Liga Paura, and Gatis Vitols. 2023. Smart Poultry Management Platform with Egg Production Forecast Capabilities. *Procedia Computer Science* 217 (2023), 339–347. doi:10.1016/j.procs.2022.12.229
- [11] Ederlyn Dollente and Ibrahim Hanbal. 2024. IoT-Based Decision Support System for Poultry Care for Ilocos Sur Polytechnic State College. *Nanotechnology Perceptions* 20, S2 (May 2024), 149–161. doi:10.62441/nano-ntp.vi.462
- [12] Marc Escribà-Gelonch, Shu Liang, Pieter van Schalkwyk, Ian Fisk, Nguyen Van Duc Long, and Volker Hessel. 2024. Digital Twins in Agriculture: Orchestration and Applications. *Journal of Agricultural and Food Chemistry* 72, 19 (2024), 10737–10752. doi:10.1021/acs.jafc.4c01934
- [13] Andrés F. Gonzalez-Mora, Alain N. Rousseau, Araceli D. Larios, Stéphane Godbout, and Sébastien Fournel. 2022. Assessing Environmental Control Strategies in Cage-Free Aviary Housing Systems: Egg Production Analysis and Random Forest Modeling. *Computers and Electronics in Agriculture* 196 (2022), 106854. doi:10.1016/j.compag.2022.106854
- [14] Hengyi Ji, Yidan Xu, and Guanghui Teng. 2025. Predicting Egg Production Rate and Egg Weight of Broiler Breeders Based on Machine Learning and Shapley Additive Explanations. *Poultry Science* 104, 1 (2025), 104458. doi:10.1016/j.psj.2024.104458
- [15] Petr Kadlec, Bogdan Gabrys, and Sibylle Strandt. 2009. Data-Driven Soft Sensors in the Process Industry. *Computers & Chemical Engineering* 33, 4 (2009), 795–814. doi:10.1016/j.compchemeng.2008.12.012
- [16] Ömer Köksal and Bedir Tekinerdogan. 2019. Architecture design approach for IoT-based farm management information systems. *Precision Agriculture* 20 (2019), 926–958. doi:10.1007/s11119-019-09637-0
- [17] Patrick Lewis, Ethan Perez, Aleksandra Piktus, Fabio Petroni, Vladimir Karpukhin, Naman Goyal, Heinrich Küttler, Mike Lewis, Wen-tau Yih, Tim Rocktäschel, Sebastian Riedel, and Douwe Kiela. 2020. Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks. In *Proceedings of the 34th International Conference on Neural Information Processing Systems (Vancouver, BC, Canada) (NeurIPS '20)*. Curran Associates Inc., Red Hook, NY, USA, Article 793, 16 pages. <https://proceedings.neurips.cc/paper/2020/hash/6b493230205f780e1bc26945df7481e5-Abstract.html>
- [18] Angel Antonio Gonzalez Martinez, Irenilza de Alencar Nääs, Thayla Morandi Roldi de Carvalho-Curi, Jair Minoru Abe, and Nilsa Duarte da Silva Lima. 2021. A Heuristic and Data Mining Model for Predicting Broiler House Environment Suitability. *Animals* 11, 10 (2021), 2780. doi:10.3390/ani11102780
- [19] G. A. D. Nawod, R. M. D. A. Rathnayake, P. N. Dodangoda, N. A. M. P. Deshitha, A. J. Vidanaralage, and W. A. C. Pabasara. 2025. Predictive Modelling of Egg Production Yields on Farms Based on Environmental Factors. In *2025 International Conference on Information and Communication Technology (ICICT)*. IEEE, Bandung, Indonesia, 1–6. doi:10.1109/ICICT66265.2025.11193017
- [20] Felipe Oliveira, Paulo Pereira, Jamilson Dantas, Jean Araujo, and Paulo Maciel. 2024. Dependability Evaluation of a Smart Poultry House: Addressing Availability Issues Through the Edge, Fog, and Cloud Computing. *IEEE Transactions on Industrial Informatics* 20, 2 (Feb. 2024), 1304–1312. doi:10.1109/TII.2023.3275656
- [21] David Lorge Parnas. 1972. On the Criteria To Be Used in Decomposing Systems into Modules. *Commun. ACM* 15, 12 (Dec. 1972), 1053–1058. doi:10.1145/361598.361623
- [22] Yasith S. Perera, Asanga C. Ratnaweera, Chamila H. Dasanayaka, and Chamil Abeykoon. 2023. The Role of Artificial Intelligence-Driven Soft Sensors in Advanced Sustainable Process Industries: A Critical Review. *Engineering Applications of Artificial Intelligence* 121 (2023), 105988. doi:10.1016/j.engappai.2023.105988 Received 17 June 2022; Accepted 9 February 2023; Available online 11 March 2023.
- [23] Al Momen Pranta, Sharmeen Md Ariful Islam, and Rokibul Islam Khan. 2025. Development of a Sensor-Integrated AI Automation Model for Decision-Based Heat Stress Management in Layer Chickens Under Subtropical Climate Conditions. *Smart Agricultural Technology* 12 (2025), 101306. doi:10.1016/j.atech.2025.101306
- [24] Ragunathan Rajkumar, Insup Lee, Lui Sha, and John Stankovic. 2010. Cyber-Physical Systems: The Next Computing Revolution. In *Proceedings of the 47th Design Automation Conference (Anaheim, California) (DAC '10)*. Association for Computing Machinery, New York, NY, USA, 731–736. doi:10.1145/1837274.1837461
- [25] Rodrigo Romero, Marcelo Fabian, and Lenis Wong. 2025. Predictive Model for Assets Control in a Peruvian Poultry Farm Applying Machine Learning. In *2025 IEEE 4th International Conference on Computing and Machine Intelligence (ICMI)*. IEEE, MI, USA, 1–6. doi:10.1109/ICMI65310.2025.11141201
- [26] Lucas Schmidt, Dalcimar Casanova, Richardson Ribeiro, Marcelo Teixeira, and Heitor M. Gomes. 2021. A Combined Solution for Flexible Control of Poultry Houses. *International Journal of Computer Applications in Technology* 67, 2–3 (2021), 232–243. doi:10.1504/IJCAT.2021.121539
- [27] Matthew Stewart, Yuke Zhang, Pete Warden, Yasmine Omri, Shvetank Prakash, Jacob Huckelberry, Joao Henrique Santos, Shawn Hymel, Benjamin Yeager Brown, Jim MacArthur, Nat Jeffries, Emanuel Moss, Mona Sloane, Brian Plancher, and Vijay Janapa Reddi. 2025. Datasheets for Machine Learning Sensors. arXiv:2306.08848 [cs.LG] <https://arxiv.org/abs/2306.08848> arXiv preprint arXiv:2306.08848.
- [28] Cor Verdouw, Bedir Tekinerdogan, Adrie Beulens, and Sjaak Wolfert. 2021. Digital twins in smart farming. *Agricultural Systems* 189 (2021), 103046. doi:10.1016/j.agsy.2020.103046
- [29] Pete Warden, Matthew Stewart, Brian Plancher, Sachin Katti, and Vijay Janapa Reddi. 2023. Machine Learning Sensors. *Commun. ACM* 66, 11 (Oct. 2023), 25–28. doi:10.1145/3586991
- [30] Zhiheng Xi, Wenxiang Chen, Xin Guo, Wei He, Yiwen Ding, Boyang Hong, Ming Zhang, Junzhe Wang, Senjie Jin, Enyu Zhou, Rui Zheng, Xiaoran Fan, Xiao Wang, Limao Xiong, Yuhao Zhou, Weiran Wang, Changhao Jiang, Yicheng Zou, Xiangyang Liu, Zhangyue Yin, Shihan Dou, Rongxiang Weng, Wensen Cheng, Qi Zhang, Wenjuan Qin, Yongyan Zheng, Xipeng Qiu, Xuanjing Huang, and Tao Gui. 2023. The Rise and Potential of Large Language Model Based Agents: A Survey. arXiv:2309.07864 [cs.AI] <https://arxiv.org/abs/2309.07864>
- [31] Huanhuan Yu, Fang Huang, Haihan Wang, and Wei Wang. 2025. Evaluation of Comfortability of Chicken House Environment and Its Impact on Egg-Laying Performance. In *Proceedings of the 2025 International Conference on Artificial Intelligence and Computational Intelligence (AICI '25) (AICI '25)*. Association for Computing Machinery, New York, NY, USA, 322–327. doi:10.1145/3730436.3730490