doi:10.6041/j.issn.1000-1298.2025.09.022

智慧养殖农业物联网与边缘计算中大模型技术应用综述

薛飞跃[1,2]　周玉玲[3,4]　李俊凯[3,4]　李霄雯[3,4]　黄王军[3,4]　肖易敏[3,4]　沙　瀛[1,2]

(1.农业智能技术教育部工程研究中心,武汉 430070;2.农业农村部智慧养殖技术重点实验室,武汉 430070;
3.湖北省农业大数据工程技术研究中心,武汉 430070;4.华中农业大学信息学院,武汉 430070)

摘要:智慧养殖(Smart farming/livestock farming)指利用现代信息技术和自动化设备,对畜牧等养殖过程进行优化管理,以提高效率、保障动物福利并减少资源浪费。当前已经处于大语言模型时代,大模型技术给智慧养殖带来巨大的改变。本文主要聚焦大模型技术在智慧养殖领域,特别是农业物联网、边缘计算方面的应用、挑战及其展望。主要包括:面向智慧养殖的农业物联网、边缘计算的定义和关键技术;多模态大模型在面向智慧养殖的农业物联网、边缘计算的应用;基于大模型的多智能体协同在智慧养殖农业物联网、边缘计算的应用;大模型技术在智慧养殖农业物联网、边缘计算智能设备上的应用。最后,指出大模型在智慧养殖领域未来的发展方向为:从技术突破、应用场景扩展和政策支持 3 个维度推动行业发展。

关键词:智慧养殖;农业物联网;边缘计算;大模型;多智能体协同

中图分类号:S126　　**文献标识码**:A　　**文章编号**:1000-1298(2025)09-0291-21　　**OSID**:

Application of Foundation Model Technology for Smart Farming in Edge Computing and Agricultural Internet of Things (Agri-IoT)

XUE Feiyue[1,2]　ZHOU Yuling[3,4]　LI Junkai[3,4]　LI Xiaowen[3,4]　HUANG Wangjun[3,4]　XIAO Yimin[3,4]　SHA Ying[1,2]

(1. *Engineering Research Center of Intelligent Technology for Agriculture*, *Wuhan* 430070, *China*
2. *Key Laboratory of Smart Farming Technology for Agricultural Animals*, *Ministry of Agriculture and Rural Affairs*, *Wuhan* 430070, *China*
3. *Hubei Engineering Technology Research Center of Agricultural Big Data*, *Wuhan* 430070, *China*
4. *College of Informatics*, *Huazhong Agricultural University*, *Wuhan* 430070, *China*)

Abstract: Smart farming refers to the application of modern information technologies and automation systems to optimize livestock production management, thereby enhancing efficiency, ensuring animal welfare, and reducing resource consumption. With the rapid advancement of artificial intelligence, particularly large language models (LLMs), smart agriculture is undergoing a new phase of intelligent transformation. The application of LLM technologies in the domain of smart livestock farming was investigated, with a particular focus on their integration with agricultural internet of things (Agri-IoT) and edge computing technologies. The fundamental concepts and key enabling technologies of Agri-IoT and edge computing were firstly defined within the context of smart agriculture. Then the integration strategies of multimodal LLMs into Agri-IoT and edge computing systems were explored. Furthermore, the mechanisms by which LLM-driven multi-agent collaboration enabled intelligent coordination and adaptive responses among distributed edge devices were analyzed. Representative application scenarios of LLM-based intelligent terminals in smart farming environments were also presented. Finally, the future development direction of large language models in the field of smart farming was model lightweighting and the optimization of edge computing architecture.

Key words: smart farming; agricultural internet of things; edge computing; large language models; multi-agent collaboration

收稿日期:2025-07-04　修回日期:2025-07-24

基金项目:中央高校基本科研业务费专项资金项目(2662025XXPY006)

作者简介:薛飞跃(1997—),男,博士生,主要从事计算机视觉和大模型研究,E-mail:xuefeiyue@webmail.hzau.edu.cn

通信作者:沙瀛(1973—),男,教授,博士生导师,主要从事人工智能和机器学习研究,E-mail:shaying@mail.hzau.edu.cn

0 引言

随着全球人口增长和资源环境压力加剧,传统养殖模式难以为继,智慧养殖(Smart farming/livestock farming)应运而生,旨在利用先进信息技术来提高养殖效率、保障食品安全和动物福利,促进可持续发展的生产方式[1]。在智慧养殖系统中,传感器、摄像头、无人机、自动饲料机、智能健康项圈、机器人挤奶等技术被广泛应用,用于实时监测动物体温、活动、饲料与水耗、环境参数等信息,并通过数据分析与决策支持,实现精细化管理[2]。这些技术可以帮助养殖场减少饲料和水的消耗,降低疫病和环境污染风险,提高畜产品质量和生产效率。总体而言,智慧养殖融合了物联网、大数据、边缘计算和人工智能等技术,使传统养殖业向高效、智能、可追溯的方向发展。

然而,当前智慧养殖系统在实际应用中仍面临诸多挑战。例如,物联网设备采集的数据类型多样、结构复杂,存在数据孤岛与异构融合困难;云端处理机制难以满足养殖现场的实时性要求,且存在通信延迟和数据隐私泄露的风险;同时,传统模型对复杂多模态数据的理解能力有限,难以支撑高精度、高可靠性的智能决策。针对上述问题,本文梳理大模型技术,特别是多模态大语言模型在智慧养殖中的应用价值,探讨其与农业物联网、边缘计算的融合路径,提升智慧养殖系统的智能化水平与实际落地能力。总结已有研究与典型应用场景,以期为构建高效、可靠、可扩展的智慧养殖体系提供理论参考与技术借鉴。

1 技术原理概述

1.1 农业物联网

农业物联网(Agricultural IoT, Agri - IoT)是指将物联网技术应用于农业生产。农业物联网通过部署各种感知设备(如环境传感器、RFID 标签、GPS 定位器、无人机等)对农田、作物、温室和牲畜等进行实时监测;并通过无线网络将采集到的数据上传到云平台或本地网关,实现远程监控与智能决策。农业物联网是将农作物、动物、环境因素、生产工具等农业系统中的物理组件,以及各种虚拟对象,通过信息感知设备在特定协议下接入互联网,以进行信息交换和通信[3],从而实现精准灌溉、作物健康诊断、牲畜跟踪与防疫、农业机械自动化等功能。

农业物联网在智慧养殖中涵盖从数据采集到处理、再到控制的全流程,其核心技术主要包括感知技术、无线通信与网络技术、数据处理与分析技术、智能控制技术以及系统集成与平台技术。

感知技术是智慧养殖的基础,通过各类传感器实时采集养殖环境、动物生理健康和生长信息等数据,为后续的智能决策提供依据。环境感知技术可监测温度、湿度、光照、氨气浓度等参数,为动物提供适宜的生长环境;生理健康感知技术通过监测动物的体温、心率、呼吸频率等指标,实现疾病的早期预警;生长信息感知技术则通过体质量、体长等数据采集,精准掌握动物生长发育情况[4]。

无线通信与网络技术是智慧养殖中数据传输的关键支撑,包括无线传感器网络(WSN)和低功耗广域网(LPWAN)。WSN 能够实现传感器设备的自组织组网和数据传输,适用于复杂养殖环境下的设备连接;LPWAN 则凭借其低功耗、长距离传输的特点,满足了养殖场内大面积设备的连接需求。例如,有研究者提出将基于 LoRa 和 LoRaWAN 协议的物联网系统应用于智慧农业,其系统框架如图 1 所示[5]。

数据处理与智能控制技术通过大数据分析和人工智能技术,对海量数据进行挖掘和分析,实现精准决策、智能控制,通过环境调控、精准饲喂和疾病防控等手段,实现养殖过程的自动化和智能化[6]。环境调控技术能够根据实时监测数据自动调节养殖环境参数;精准饲喂技术根据动物的生长需求自动调整饲料量;疾病防控技术则通过智能诊断系统实现疾病的早期预警和精准治疗。

系统集成与平台技术是智慧养殖的中枢神经系统,通过物联网平台实现数据采集、传输、处理、分析和控制的全流程管理。物联网平台能够实现设备的互联互通和数据的集中管理,提升养殖生产的智能化水平;云平台与边缘计算技术则结合了云计算强大处理能力和边缘计算快速响应优势,进一步优化了数据处理效率。然而,系统集成与平台技术开发和应用仍面临成本高、兼容性差、安全性不足等问题,需要进一步优化以满足智慧养殖实际需求。

1.2 边缘计算

边缘计算(Edge computing)是一种去中心化的数据处理架构,其核心思想是在数据产生源头附近(网络边缘)进行计算和分析,而不完全依赖远程云端服务器。边缘计算被视为云计算的补充,旨在解决物联网等场景下对实时性、带宽与隐私等的需求。边缘计算指的是去中心化的数据处理范式,即将计算和分析嵌入到数据源,而不是依赖于远程、集中式的云基础设施[7]。在农业场景中,边缘计算节点通常部署在田间设备、温室网关或养殖设施中,它们能够在现场实时处理传感器数据。通过在网络边缘进行数据过滤、预处理与分析,边缘计算可显著降低延

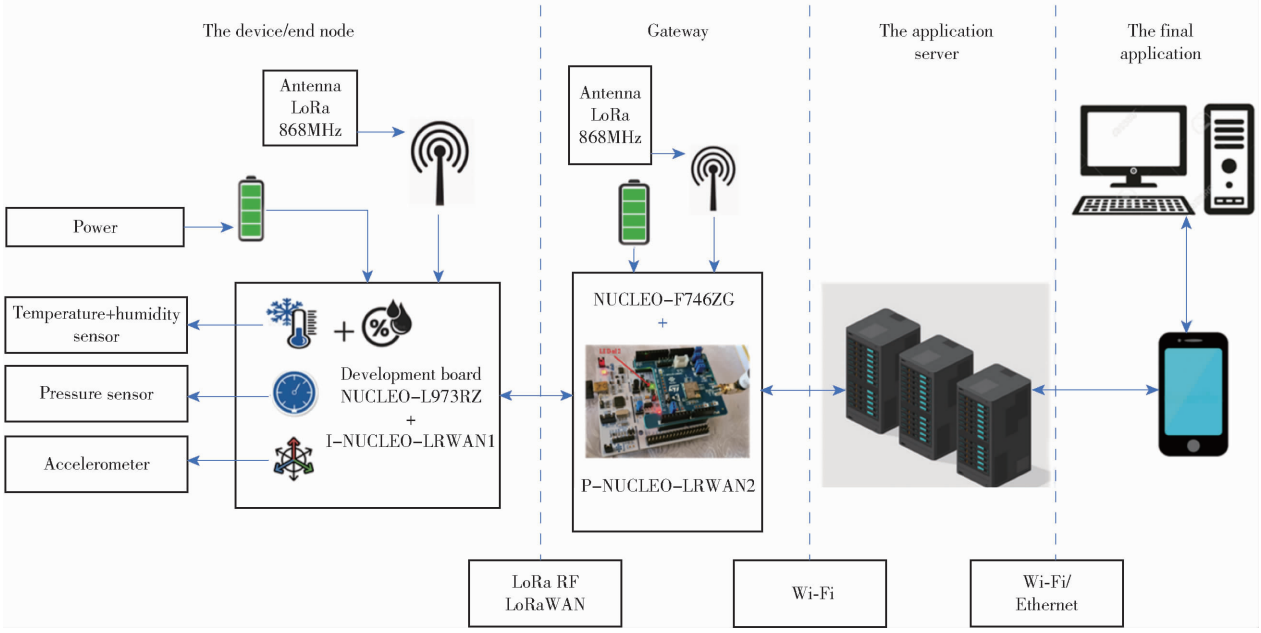


图 1　智慧农业中基于 LoRa 和 LoRaWAN 协议的物联网系统架构图

Fig. 1　Application of IoT systems based on LoRa and LoRaWAN protocols in smart agriculture

迟、减轻通信网络负担，并为无人值守环境提供可靠的服务。具体而言，边缘计算能力包括：实时洞察生成、决策自主性、数据去重过滤和可视化运营监控等。这些特性使得部署在农场现场的“智慧网关”或边缘设备能够及时响应环境变化，实现例如精确灌溉、病虫害早期预警或自动饲喂等智能功能。边缘计算拓扑还提高了系统的可扩展性和可靠性，在网络或云服务不稳定的情况下仍能保证农业系统的持续运行。

边缘计算其核心在于将计算能力从云端下沉到靠近数据源的边缘设备，从而实现数据的快速处理与分析。边缘计算在智慧养殖中的关键技术主要包括边缘计算设备、数据预处理与分析、低延迟通信技术、安全与隐私保护以及模型部署与优化等方面。常用的边缘计算设备包括树莓派、Nvidia Jetson 系列等。树莓派因其低功耗和高便携性，适合部署轻量级的深度学习模型，可用于水质监测、疾病诊断等。Nvidia Jetson 系列则适合需要高计算能力的复杂任务，如生猪识别和杂草识别[8]。边缘计算在数据预处理方面具有显著优势。通过在边缘设备上对采集到的大量数据进行预处理，如数据清洗、特征提取等，可以减少数据传输量，提高系统效率[9]。在数据分析方面，边缘计算能够结合人工智能算法对数据进行实时分析和决策，基于边缘计算的智能算法可以根据实时数据自动调整养殖环境参数，还可以对动物行为数据（如活动量、进食量、饮水量等）进行实时分析，识别异常行为，提前预警疾病。边缘计算需要与物联网传感器、摄像头等设备进行低延迟通信，4G/5G 等无线通信技术为边缘计算提供了稳定的数据传输通道。

典型的智能养殖环境监测与控制系统如图 2 所示。

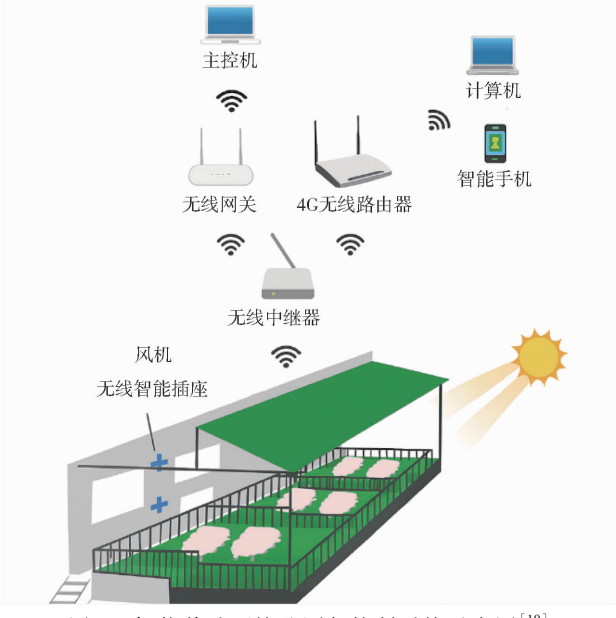


图 2　智能养殖环境监测与控制系统示意图[10]

Fig. 2　Schematic diagram of intelligent livestock farming environment monitoring and control system[10]

在饲喂管理中，可以利用物联网传感器实时监测动物的采食量、饮水量等数据，并结合动物的生长阶段、体质量等信息，精准控制饲料和水的投放量，实现精准饲喂，提高饲料利用率，降低养殖成本[10]。对于养殖的健康监测和疾病预警，可以借助可穿戴设备或植入式传感器，实时监测动物体温、心率、呼吸频率、活动量等生理参数。一旦发现异常数据，系统会自动发出警报，提醒养殖者及时采取措施，实现

疾病的早期诊断和防控,减少疾病传播风险,保障动物健康。同时可以通过部署在养殖舍内的传感器网络,实时监测温度、湿度、氨气浓度、二氧化碳浓度等养殖环境参数。根据预设的阈值,自动控制通风系统、加热设备、喷雾降温系统等,为动物创造舒适、适宜的生长环境,减小环境应激对动物的影响,提高动物的生长性能和健康水平[11]。还可以利用视频监控和图像识别技术,对动物的行为进行实时监测和分析,如动物的活动范围、休息时间、采食行为等。通过对这些行为数据的分析,评估动物的福利状况,及时发现动物的异常行为,以采取相应的措施改善动物的福利条件。在养殖的繁殖管理中,可以借助物联网技术,对动物的发情周期、配种时间、妊娠期等进行精准监测和管理。通过实时监测动物的生理指标和行为变化,准确判断发情期,提高配种成功率;同时,对妊娠期动物进行重点监控,确保胎儿的健康发育,提高仔畜的成活率[12]。

边缘计算技术则进一步提升了智慧养殖系统的效率和可靠性。通过在养殖现场部署边缘计算设备,对传感器采集的数据进行实时处理和分析,能够快速做出决策并执行相应操作,减少数据传输到云端的延迟。例如,在水质监测中,边缘计算设备可以实时分析溶氧量和水质参数,及时启动增氧机,确保水产养殖环境的稳定,其系统总体构成如图 3 所示[13]。此外,边缘计算还支持数据的本地预处理和筛选,降低数据传输成本,提高数据安全性,并支持离线运行,保障在网络不稳定或中断时养殖系统的正常运作[14]。结合人工智能算法,边缘计算设备能够实现智能巡检和病害预警,进一步提升养殖管理的智能化水平。

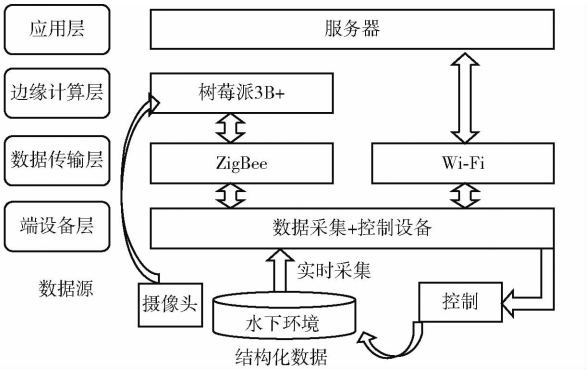


图 3 水质监测系统总体构成[13]

Fig. 3 Overall composition of water quality monitoring system[13]

1.3 大语言模型

传统的信息采集手段各有局限,例如,单一类型的传感器或摄像头往往难以全面刻画养殖场景:空气传感器可提供环境参数但无法直接识别动物健康,视频监控能观察行为却受制于光照和视角,音频监测可捕捉动物咳嗽声但易受背景噪声干扰[15]。过去研究往往各自聚焦于某一技术领域,存在数据难以整合、系统不可扩展等问题。为克服这些挑战,近年来兴起的多模态大模型为智慧养殖带来了革命性契机[16]。

大语言模型是一种包含数百亿及以上参数的深度神经网络构建的语言模型[17]。2018 年以来,Google、OpenAI、Meta 等相继发布了 BERT[18]、GPT[19]等多种语言模型。2022 年 11 月 ChatGPT[20]的发布,引起了全世界的广泛关注,人工智能技术由此迎来了新的重要发展阶段。大语言模型具有以下的能力:丰富的世界知识,较强的通用任务解决能力,较强的人类指令遵循能力,较好的人类对齐能力,可拓展的工具使用能力,以及长程对话的语义一致性、新任务的快速适配、对人类行为的准确模拟等。多模态大模型指能够同时处理多种类型数据(如图像、声音、时间序列)的大语言模型,通常基于深度学习并具有海量参数和知识。目前多模态大语言模型已经广泛应用于数学、化学、物理等多个领域。最新研究表明,在农业领域多模态大模型有望简化复杂的养殖难题,提升决策能力和分析效率,成为未来智慧养殖的重要工具。

多模态大模型可以融合视觉、听觉等多源信息,从而比单一模型获取更全面的洞察。如图 4 所示,多模态大模型可以同时分析牛的体表图像和喂养数据,综合多模态信息判断其健康和情绪状态[21]。此外,大型预训练模型还具备对知识的迁移能力,可以将在其他领域学到的模式用于养殖场景,减少对大规模标注数据的依赖。有研究指出,养殖数据通常分散且有限,很难集中获取足够样本训练传统模型,多模态大模型通过利用预训练和多源数据融合,有助于缓解农业数据孤岛和样本稀缺问题[22]。多模态模型可同时关注动物个体与群体行为,实现对复杂养殖环境的全面感知和理解,为智能决策提供支持[23]。

将多模态大模型融入智慧养殖,是在当前背景下满足畜产品安全高效生产需求的关键路径。大模型 + 农业物联网 + 边缘计算的融合,将使养殖业从经验驱动转向数据与智能驱动,带来生产方式的深刻变革。

大语言模型通过海量知识预训练获得的语义解析能力,为养殖环境的多模态数据处理提供了认知基础。基于大模型的多智能体协同机制也得到了广泛的应用。多智能体系统则通过分布式架构实现传感器网络的高效协同,其任务分解与联盟形成机制

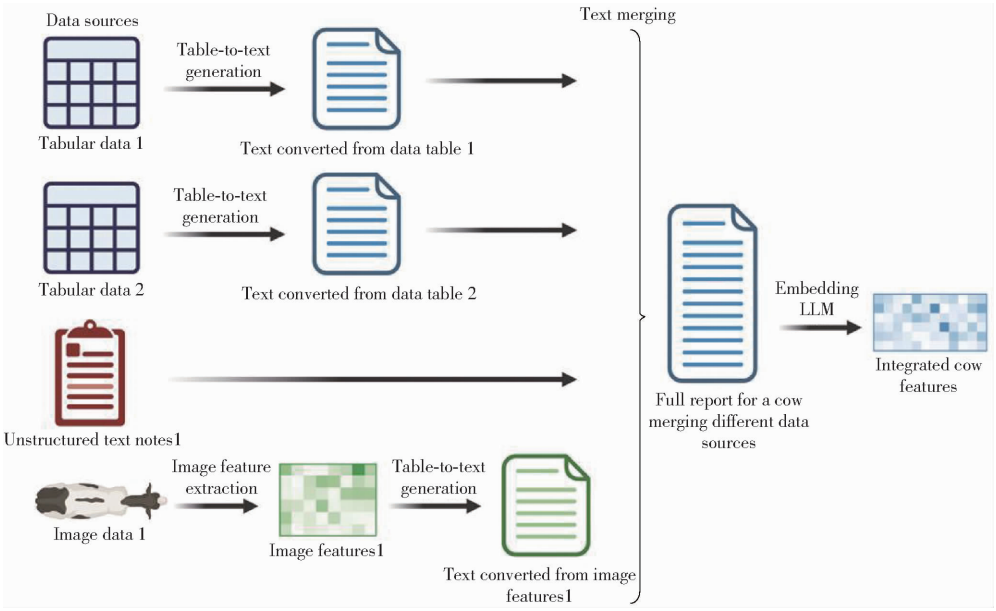


图 4　多模态大模型整合自不同来源和格式的数据示意图

Fig. 4　Integration of data from diverse sources and formats by multimodal large model

已在 SMART－LLM 等框架中得到验证[24]。近期的应用案例也表明这一融合路径具有现实可行性。例如，欣农互联推出的智能养殖助手“小欣”利用大模型与智能体系统协同实现感知、分析与决策的自动闭环；苏州“作物云”平台则结合农业补贴数据构建农业大模型，并引入智能体实现农事管理流程的自动化。这些实践进一步验证了大模型赋能下的多智能体系统结合农业物联网与边缘计算，将成为突破传统养殖技术瓶颈、实现智慧养殖高质量发展的关键路径。

综上所述，农业物联网赋予了养殖场数字化感知能力，而边缘计算赋予其实时智能反应能力。它们共同构成智慧养殖的“数字神经系统”，使养殖场从过去的信息孤岛变为数据高度互联、自主调节的智能环境。在此基础上，引入先进的多模态大语言模型，可以进一步释放物联网数据价值，提升智慧养殖智能化水平[25]。

2　大模型技术在智慧养殖中的应用

多模态大模型为智慧养殖的数据处理和决策支持开辟了新路径。在智慧养殖中，养殖环境和动物个体产生的数据本身就是多模态的：视频监控提供视觉信息，拾音器采集声音信号，可穿戴设备记录生理参数，环境传感器输出数值读数，此外还有饲养日志等文本记录[26]。如何将这些异构数据融合起来加以智能分析，是提升养殖智能化水平的关键技术难题。多模态大模型凭借其跨模态数据融合能力，可有效整合视觉、声音及环境传感器等多源异构数据，为养殖行为分析、疾病预测和环境调控提供智能化决策支持，如图 5 所示[27]。

2.1　感知数据多模态融合处理

在智慧养殖感知层，来自不同传感器的数据需要经过清洗、特征提取和融合，才能转化为对养殖过程有意义的知识。传统做法通常是分通道处理：例如图像用卷积神经网络处理，声音用语音识别模型处理，环境数据用时间序列算法处理，最后再人工或简单算法整合。这种方式不仅流程繁琐，且各模态之间的信息关联难以充分利用。多模态大模型提供了一种端到端融合思路。它可以在同一模型框架下接收多源输入，通过共享的深层神经网络提取跨模态的关联特征，从而实现对复杂情景的整体理解。例如，针对奶牛的健康监测，有研究构建了一个融合音频、视频和生理数据的 AI 系统，实时“解码”奶牛的行为和状况（图 6）[28]。该系统采集牛的叫声录音、视频画面以及可穿戴设备的心率等数据，利用生成式 AI 和大型语言模型对这些多模态信息进行深度挖掘分析。模型能够识别出奶牛进食行为及细微的异常叫声模式，并将声音信号与应激、健康和环境条件关联起来进行解释。这种融合使得系统可以提前发现奶牛进食异常或压力迹象，并通过仪表盘界面向农场主提供直观的实时洞见。相比仅靠人工观察或单一传感器，此多模态 AI 框架显著增强了信息获取的广度和深度，实现了对动物状态全方位感知。

在智慧水产养殖中，高效精准的饵料投放可以提升水产产量、降低人员劳动强度、减少养殖成本，对实现智能养殖具有重大意义。然而，传统的投喂方法主要依赖人工经验或机械投饵机定时定量投喂，无法实现智能且精准的鱼类投喂。王昊等[29]提

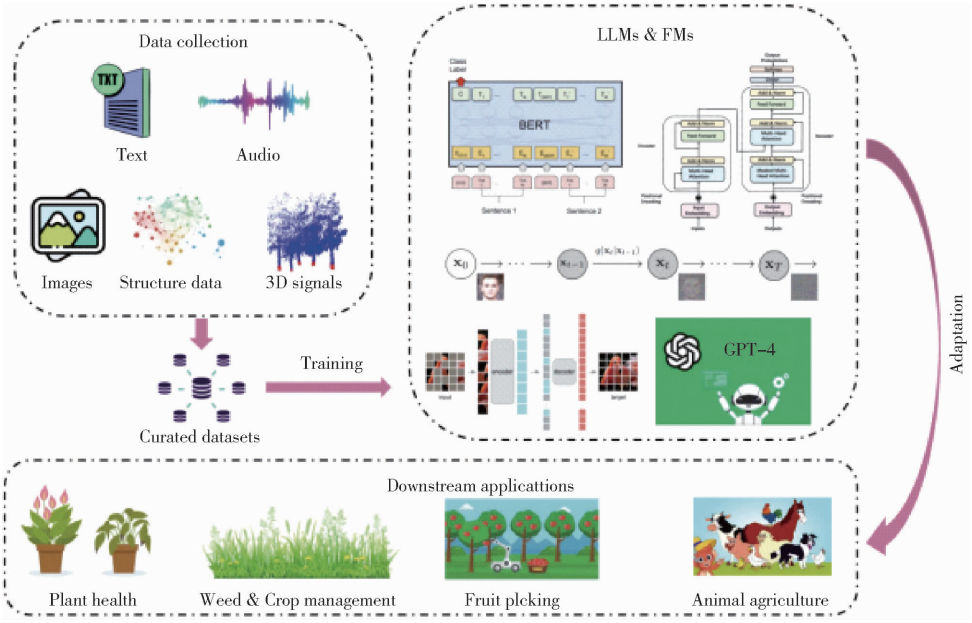


图 5 多模态大模型在农业领域训练和下游适配过程[27]

Fig. 5 Multimodal foundation model training and domain adaptation in agriculture[27]

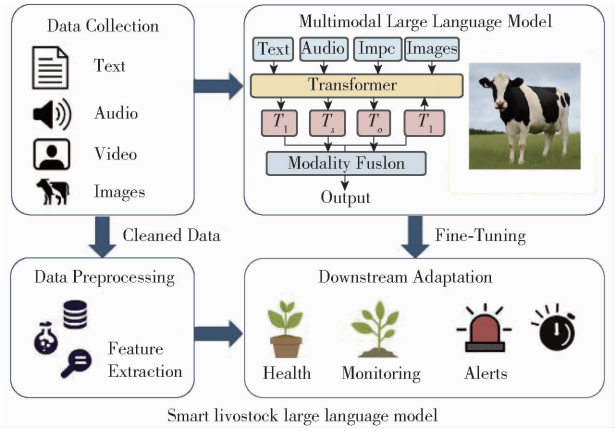


图 6 多模态大模型结合物联网技术监测奶牛状态[28]

Fig. 6 Multimodal large models combined with IoT technology for monitoring dairy cow status[28]

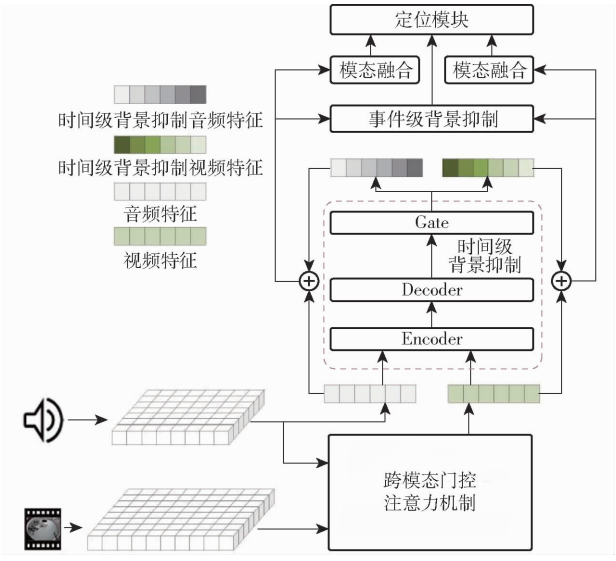


图 7 基于多模态背景抑制网络的鱼类摄食强度识别方法[29]

Fig. 7 Fish feeding intensity recognition method based on multimodal background suppression network[29]

出了一种基于多模态背景抑制网络(Cross-modal background suppression network, CMBS)的鱼类摄食强度识别方法,如图 7 所示,CMBS 网络基于多模态协同注意力机制、多头注意力融合模块和时间级、事件级的背景抑制模块,提高模型对重要特征区域的关注程度,降低单模态中存在的突发性噪声及视听信息不同步等问题对预测结果的影响。

目前在智慧养殖中实现真正多模态融合 AI 仍面临挑战,一些领域研究还局限于单一模态或简单组合[30]。例如在水产养殖领域,关于多模态 AI 系统开发还相对不足,模型泛化能力有待提高,且大多有关多模态融合的应用都是基于输入级融合、特征级融合以及决策级融合进行的,这些基于拼接式或手动选择权重的方式不能充分利用模态互补性,导致融合的效果不佳[31]。未来应加强这方面的探索,构建能综合处理图像、声音、气候等多源数据的统一模型,提高模型对不同养殖场景的适应性。多模态大模型为养殖数据融合处理提供了强大工具,能够将物联网感知层海量异构数据转化为有用信息和知识,这是智慧养殖实现全面智能化的基础。

2.2 动物健康监测

动物个体健康是养殖场管理的重中之重。传统方式主要依赖人工巡栏观察、定期体检采样等,不仅费力且滞后。借助物联网和多模态大模型技术,可以实现连续的自动化健康监测,及时发现疾病征兆和异常情况。在物联网感知层,各类生物传感器和摄像设备能够获取反映动物健康状态的多种信号。例如,猪场常用环境拾音器监听猪咳嗽声来监测呼

吸道疾病；牛舍中安装的红外相机可测量牛体表温度识别发热个体。多模态大模型可以将这些不同来源的信息汇总分析，提供更可靠的健康评估。

在奶牛和肉牛养殖中，常规会给牛佩戴智能项圈或耳标传感器，实时记录反刍次数、采食时间、运动步数、体温心率等生理数据。这些数据可以作为评估牛健康和繁殖状态的关键指标。例如，健康牛只每天反刍次数有一定规律，若反刍显著减少往往预示反刍紊乱或疾病。多模态大模型可以结合可穿戴数据和视频行为来全面监测牛群健康。有研究利用大语言模型结合传感器数据，为奶牛场构建知识服务模式，简化复杂数据的解读，帮助牧场主发现异常（如 GPT－4 模型结合牛只数据库提供养殖建议）[32]。

对于大规模养殖场，及时预警疫病暴发尤为关键，多模态大模型可以结合环境病原监测数据和动物异常表现并进一步地利用边缘计算实现主动预警。例如，在智慧鱼类养殖中，利用多模态大模型对通过物联网技术获取到的水质和鱼行为数据进行分析，能够提前预测鱼病发生风险，一旦发现异常指标组合（如溶氧下降＋鱼游动异常），系统立即多渠道通知养殖户并给出防控建议，并通过边缘计算技术，及时调整水质或投喂药饵。这使养殖者有时间采取措施，将疾病扼杀在初期，显著降低了疾病发生率和经济损失（图 8）[33]。同理，在鸡场如果通过多模态大模型检测到鸡群采食量下降、精神不振且伴随环境中有害气体上升等多因素迹象，可能预示禽病苗头，会触发报警和防疫操作建议。

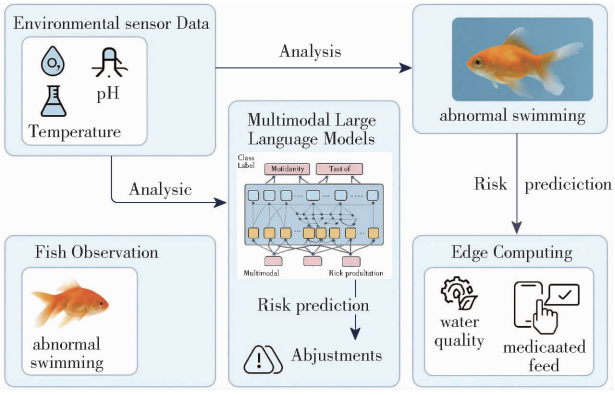


图 8　多模态大模型结合物联网、边缘计算的大型鱼类养殖场预警方案[33]

Fig. 8　Early warning scheme for large-scale fish farms based on multimodal large models integrated with IoT and edge computing[33]

2.3　环境控制优化

良好的饲养环境对动物健康生长至关重要。智慧养殖通过物联网设备实现对环境的精细化监测与调控，而多模态大模型则进一步优化了控制策略，使环境管理更高效、精准和智能。传统的环境控制多采用固定阈值和定时器的方法，例如温度高于阈值就开风机。然而养殖环境具有复杂动态性，例如温度、湿度、氨气浓度等参数相互影响，不同生长阶段动物对环境要求也不同。多模态大模型可以综合多种传感器数据和动物反应信息，对环境控制进行智能决策。例如，在鸡舍环境控制中，大模型不仅参考温湿度传感器数据，还可结合鸡群行为（如是否扎堆）、呼吸声音频率等，判断鸡只是否感到热应激。当检测到鸡只呼吸加快且集中远离热源，便会认为当前温度偏高，随即指令边缘控制器降低温度（增加通风或喷雾降温），具体流程如图 9 所示[34]。这种基于多模态反馈的调控比单纯靠温度阈值更加灵敏和以动物为中心，能够优化动物福利。

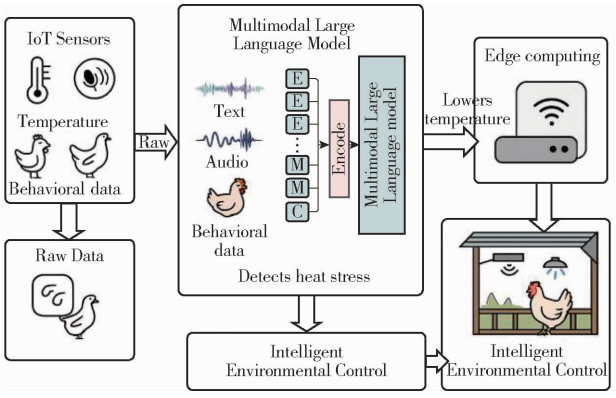


图 9　多模态大模型结合物联网传感器、边缘计算在智能养鸡场中的应用[34]

Fig. 9　Application of multimodal large models integrated with IoT sensors and edge computing in smart poultry farms[34]

2.4　行为识别与预测

动物行为包含了丰富的信息，例如反映健康状况、情绪压力、群体动态等。精准识别和分析畜禽行为，是智慧养殖实现自动管理和异常预警的重要环节之一。多模态大模型和深度学习算法，已经取得了令人瞩目的进展，使行为分析从定性走向定量、从事后走向实时预测。传统上，识别动物的具体行为（如站立、躺卧、进食、饮水、异常挣扎等）需要耗费大量人力观察记录。如今，通过安装摄像头并应用计算机视觉技术，可以自动识别每只动物在视频中的行为状态。例如，QAZI 等[35] 提出的“AnimalFormer”多模态视觉框架，将多个最先进的计算机视觉模型组合，用于非接触式地全面分析家畜行为。如图 10 所示，该框架利用 GroundingDINO 模型自动侦测圈舍视频中每只动物的位置并画出边界框，用高精度分割模型 HQSAM 将个体从背景中分割出来，再用 ViTPose 姿态估计模型提取每只动

物的骨骼关键点。借助这一系列模型，AnimalFormer 能够在没有任何动物身上标记的情况下，从视频中获取详细的行为指标，包括活动模式（如进食、行走、躺卧）、互动动态以及姿态变化等。该框架在绵羊行为数据上进行了示范，可识别羊的吃草、奔跑、坐卧、站立、行走等多种行为，并提取出每只羊的活动和采食模式、社群交互频次、体态姿势评估等信息。这些以前需要耗时人工观察才能获得的数据，如今借助多模态视觉大模型可以自动化、定量化地记录和分析。AnimalFormer 等方法的出现，使得非侵入式的精准行为监测成为现实，为后续的健康评估和异常检测提供了强有力的支撑。

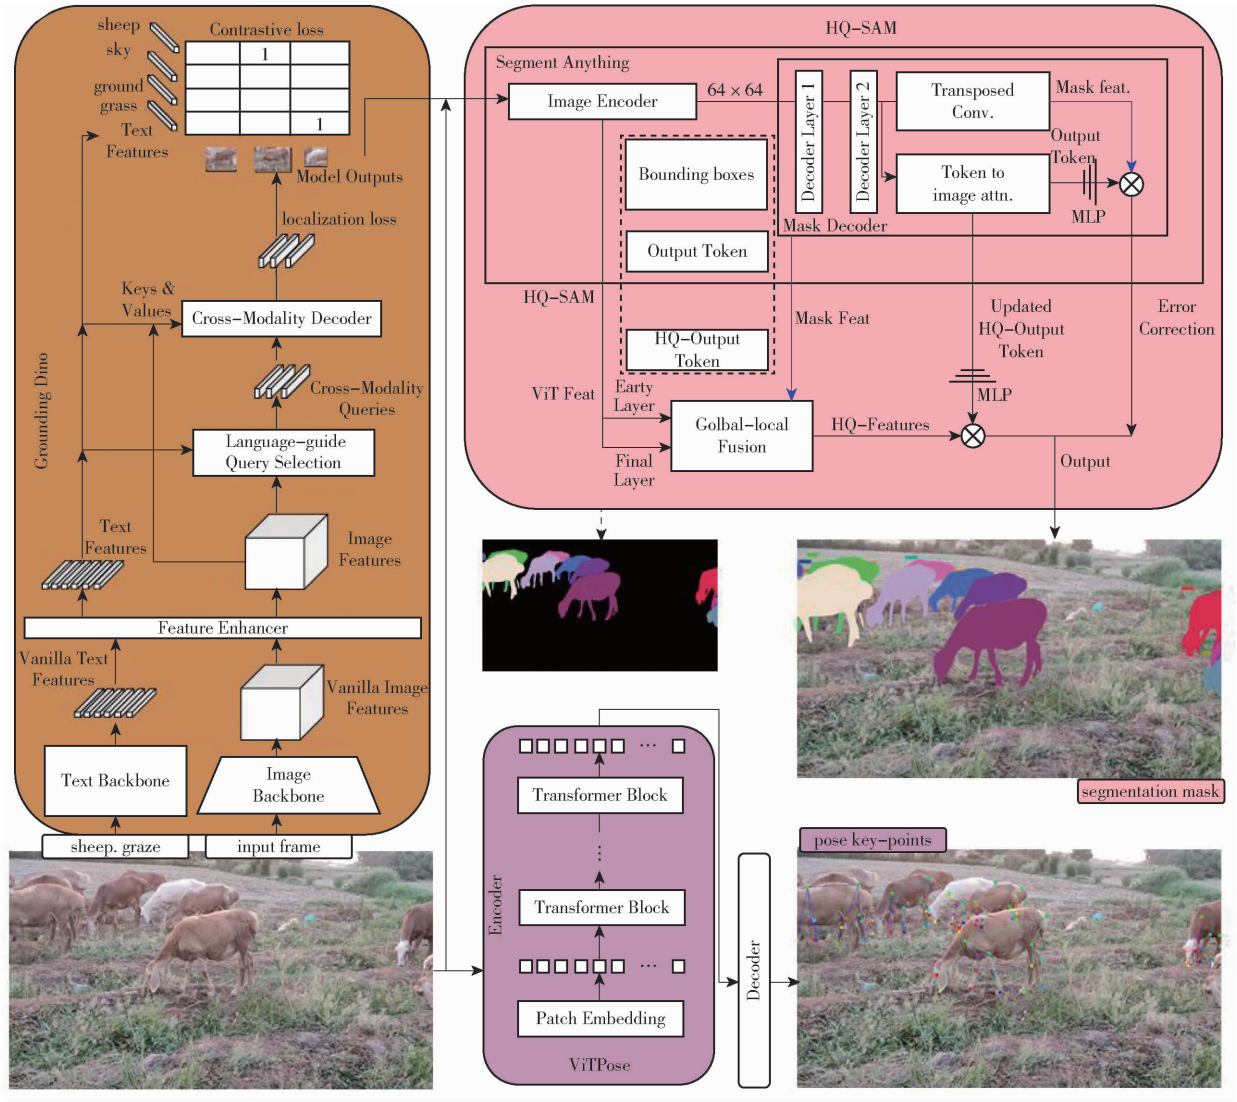


图 10 AnimalFormer 多模态绵羊行为识别模型示意图[35]

Fig. 10 AnimalFormer: multimodal framework for sheep behavior recognition[35]

3 智慧养殖中基于大模型的多智能体协同系统技术

3.1 基于大模型的多智能体协同理论

大语言模型凭借其强大的规划与推理能力，已逐步应用于自主智能体系统中，以自动执行复杂任务。近期，研究从“单一 LLM 作为规划或决策代理”的模式拓展至基于 LLM 的多智能体系统（Multi-agent systems，MAS），在复杂问题求解与真实世界模拟方面取得了显著进展。大模型为多智能体系统提供了零样本条件下的规划能力，并通过上下文学习与状态反馈重提示（Re-prompting）显著提升了任务规划的表现[36]。此外，智能体之间的经验共享机制也有助于加速集体学习过程。

与由单个 LLM 驱动的智能体系统相比，基于多智能体的架构展现出更强的功能优势，主要体现在：通过为 LLM 分配不同角色构建具备功能分工的多个智能体，从而实现协同协作与高效任务分解；通过整合智能体之间的交互，能够有效模拟复杂的、动态变化的现实环境。在此框架下，多个自主智能体围绕规划、讨论与决策展开协同工作，模拟了人类团队在任务执行过程中的合作行为。这种方法不仅充分

利用了 LLM 强大的语言生成与理解能力，还体现出其在不同知识领域的广泛泛化能力与对特定任务的专注能力。最近的研究表明，基于 LLM 的多智能体系统在多个应用领域展现出巨大潜力，包括：软件开发[37]、多机器人系统、社会行为建模[37]以及游戏环境模拟[38]等。

基于大语言模型的多智能体（LLM－MA）系统强调智能体之间的差异化配置、交互机制以及集体决策过程。从这一视角出发，多个自主智能体的协同合作能够有效应对更加动态且复杂的任务环境。每个智能体具备独立的策略与行为模式，并通过通信机制实现信息共享与协同推理。图 11 展示了此类多智能体系统通用结构，系统设计重点聚焦于 4 个关键组成部分：①智能体-环境接口，用于感知环境状态并进行反馈。②智能体分析，即各个代理的角色设定与行为偏好。③智能体通信机制，支持智能体间信息交互与协调。④智能体能力获取，包括通过学习或预设获得完成任务所需的知识与技能[39]。

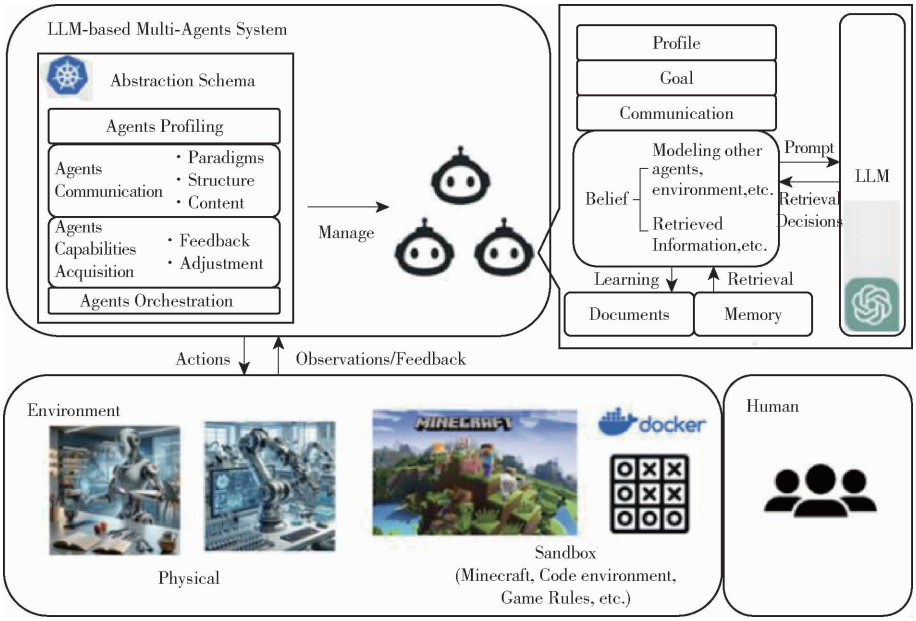


图 11　基于 LLM 的多智能体结构[39]

Fig. 11　Multi-agent architecture based on large language models (LLMs)[39]

（1）智能体环境接口

智能体环境接口定义了 LLM－MA 系统部署和交互的特定上下文或设置。基于 LLM 的智能体在环境中的感知和行动，又会影响其自身的行为和决策。智能体环境接口是指代理与环境交互和感知环境的方式。正是通过这个接口，智能体了解周围环境，做出决策，并从其行动结果中学习。LLM－MA 系统中的当前接口可分为 3 种类型，即 Sandbox、Physcial 和 None。Sandbox 是指由人类构建的模拟或虚拟环境，代理可以在其中更自由地交互并尝试各种动作和策略。这种接口广泛应用于软件开发、游戏（使用游戏规则作为模拟环境）[38]等。物理（Physical）是一个真实环境，代理在其中与物理实体交互并遵守真实世界的物理特性和约束。在物理空间中，代理也不需要采取可以直接产生物理结果的行动。例如，在扫地、制作三明治、包装杂货和安排出租车内线等任务中，机器人代理需要灵活地执行动作，观察物理环境，并不断完善其动作[40]。None 是指没有特定外部环境，并且代理不与任何环境交互的场景。

（2）智能体分析

在 LLM－MA 系统中，智能体由特征、行为和技能定义，这些特征、技能和技能是为满足特定目标而量身定制的。在各种系统中，智能体承担不同的角色，每个角色都有全面的描述，包括特征、能力、行为和约束。例如，在游戏环境中，智能体可能被描述为具有不同角色和技能的玩家，每个玩家对游戏目标的贡献不同。在软件开发中，智能体可以担任产品经理和工程师的角色，每个人都承担指导开发过程的职责和专业知识。同样，在辩论平台中，智能体可能被指定为支持者、反对者或评委，每个人都具有独特的功能和策略来有效地履行其角色。这些配置文件对于定义智能体在各自环境中的交互性和有效性至关重要。

（3）智能体通信机制

在 LLM－MA 系统中，代理之间的通信构成了支撑集体智能的关键基础设施。从 3 个方面对智能体通信进行剖析：通信范式，即代理之间互动的方式与模式；通信结构，指多智能体系统内部通信网络的组织形式与架构设计；通信内容，即代理之间交换的

信息类型与具体内容。

当前 LLM－MA 系统主要采用 3 种通信范式：协作式、辩论式和竞争式。协作式指智能体围绕共同目标协同工作，通常通过信息交换优化集体解决方案。辩论式是智能体通过论证性互动展开交流，包括阐述和捍卫自身观点、批判他人观点或方案，该范式适用于达成共识或形成更完善的解决方案。竞争式指智能体以自身目标为导向，可能与其他智能体的目标存在冲突。

LLM－MA 系统中 4 种典型通信结构如图 12 所示。分层通信：该结构具有层级性，不同层级的代理扮演不同的角色，主要在同一层或相邻层之间进行交互。例如 LIU 等[41]提出的 DyLAN（Dynamic LLM-agent network）框架，将代理组织为多层前馈网络。该结构支持推理时动态代理选择和提前终止机制，有助于提升多代理协作的效率。去中心化通信：该结构基于点对点网络，代理之间直接通信，常用于世界模拟等应用中，强调代理的自主性和相互协作。中心化通信：该结构通过一个中心代理或一组中心代理协调整个系统的通信，其他代理主要通过这一中心节点进行信息传递。共享消息池：MetaGPT[42]提出了这种通信结构以提高通信效率。该结构维护一个共享消息池，代理可以根据其配置向其中发布消息，或订阅与自身相关的消息，从而有效促进信息流通。

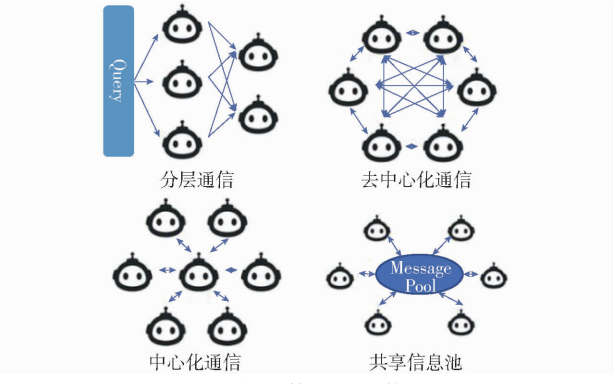


图 12 智能体 4 种通信结构

Fig. 12 Four communication architectures of agents

在 LLM－MA 系统中，通信内容通常采用文本形式。具体内容差异很大，具体取决于特定的应用程序。例如，在软件开发中，代理可能会就代码段相互通信。

（4）智能体能力获取

在 LLM－MA 系统中，智能体能力获取是实现其持续学习与进化的关键环节，核心在于智能体如何从反馈中学习以及如何调整自身以应对复杂任务。反馈包含智能体从行动结果中获得的关键信息，帮助其了解行动的潜在影响并适应复杂动态问题。可分为 4 类：环境反馈，来源于真实或虚拟环境，如软件开发中的代码解释器或具身系统中的感知输入；智能体交互反馈，来自其他智能体的判断与交流，常用于科学辩论或游戏模拟场景；人类反馈，直接由人类提供，确保系统与人类价值观对齐；无反馈，通常用于分析模拟结果的任务中，如信息传播建模。

为适应复杂任务，智能体可通过 3 种方式增强能力：①使用记忆模块储存和调用历史经验，以指导当前行为。智能体将先前交互和反馈的信息存储在记忆中，执行动作时可检索相关的宝贵记忆，尤其是包含过去类似目标成功动作的记忆[43]，该过程有助于提升当前动作的有效性。②自我进化，通过修改目标、策略或结构进行自我优化，并利用通信日志持续训练。NASCIMENTO 等[44]提出自我控制循环过程，允许多智能体系统中的每个智能体自我管理并自适应动态环境，从而提高多智能体的合作效率。③动态生成，根据任务需求在运行时创建新智能体以增强系统适应性[45]。此能力使系统能够有效扩展和适应，因为它可引入专门设计用于解决当前需求和挑战的智能体。

3.2 面向智慧养殖场景下多智能体协同与农业物联网融合

多智能体系统与农业物联网的融合为精准农业提供了全新的协同优化范式。通过分布式智能体的自主决策与协作，农业物联网中的任务分配、资源调度与数据整合效率得到显著提升。例如，SERIÑO 等[46]提出的多智能体模型通过协调无人机与地面传感器网络，实现了对作物生长异常区域的实时监测与预警，其核心在于利用智能体间的上下文感知能力整合异构数据源，包括光谱图像与物候学特征，从而构建动态知识库以支持协同决策。这种基于上下文的数据融合机制，有效解决了传统农业物联网中因设备异构性导致的信息孤岛问题。

在任务分配优化方面，多智能体系统通过强化学习与进化算法的结合展现出显著优势。ZHU 等[47]开发的 GAPPO 框架将遗传算法全局搜索能力与近端策略优化稳定性相结合，算法框架如图 13 所示。该算法结合遗传算法与近端策略优化，通过 Actor－Critic 框架实现智能体状态估计、任务分配与策略更新，其中智能体在每个时间步观察环境状态并执行动作，经验样本存储于回放缓冲区用于训练，遗传算法通过选择、交叉和变异操作优化策略网络参数，以实现高效的多智能体任务分配。GAPPO 算法使农业无人机群在资源受限条件下仍能高效完成大规模农田巡检任务，其试验表明该算法在 500

个智能体协同场景中任务完成时间缩短 37%。

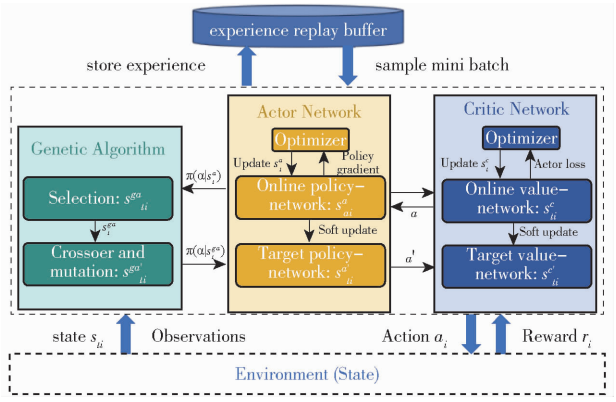


图 13　面向智能体群的自适应任务导向 GAPPO 算法框架图[47]

Fig. 13　Adaptive task-oriented GAPPO algorithm for agent populations[47]

资源调度层面，多智能体协同显著提升了农业物联网的能效与实时性。PHAM 等[48] 基于 O－RAN 架构的 UTRA 优化方案，通过联合优化无人机轨迹与计算资源分配，使无线传感器网络的数据传输延迟降低至毫秒级，这对于灌溉控制等时效性要求高的农业应用至关重要。同时，智能灌溉系统的研究表明，多智能体协同能动态调整土壤湿度传感器的采样频率与通信周期，在干旱预警场景下显著提升系统能效。

除了在资源调度中的应用，多智能体系统也在农业装备智能感知方面展现出巨大潜力。针对农业车辆在复杂农田环境中识别精度不足的问题，郭文强等[49] 提出了一种基于多连片贝叶斯网（MSBN）的多智能体协同推理算法。该方法将多智能体图像采集系统获取的局部观测信息嵌入 MSBN 模型，在观测信息不完备的条件下，通过子域间的重叠与局部推理实现信息传播与融合，从而显著提升目标识别的准确性与鲁棒性，优于传统神经网络与单一贝叶斯方法。在更宏观的土地利用优化领域，多智能体系统同样展现出强大的建模与多目标决策能力。袁满等[50] 将多智能体系统与遗传算法相结合，构建了一种面向土地空间优化配置的决策框架，实现了土地利用方案的全局协同优化。刘敬杰等[51] 基于多智能体建模，深入分析了自然区位因子与主体决策行为之间的互动机制，揭示了农村土地变化的内在驱动规律。王越等[52] 则结合多智能体系统与粒子群优化算法，提出了一种兼顾粮食安全、生态保护与社会经济发展的土地利用格局优化模型，为实现多目标协调管理提供了高效的技术路径。

在智慧养殖领域中，PINOTTI 等[53] 开发的 EPINEST 模型通过模拟养殖场、运输节点等多智能体网络交互，精准预测禽流感传播路径，为生物安全决策提供数据支撑。EPINEST 模型框架如图 14 所示，图中呈现了合成的家禽生产与分销网络（PDN）结构及家禽移动路径。其中，红色农场作为肉鸡生产源头，鸡群由黄色中间商运输至橙色活禽市场（LBM），再由供应商处理交易，最终售予终端消费者，形成完整供应链。鸡群按疾病状态以不同颜色区分，包括易感（S）、暴露（E）、感染（I）和恢复/免疫（R），且假设同一环境内鸡群均匀混合。图中还聚焦单个 LBM，展示了供应商交易导致鸡群在不同 LBM 间移动的情况，直观呈现了模型中病原体传播的关键节点与动态过程。

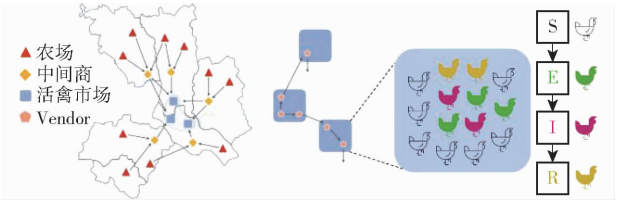


图 14　EPINEST 模型原理图[53]

Fig. 14　Schematic of EPINEST model[53]

在智慧养殖的具体实现中，多智能体协同与农业物联网、边缘计算的结合展现了显著的技术优势。以生猪养殖为例，部署在养殖场的物联网传感器网络（包括温湿度、氨气浓度等传感器）通过多智能体协同机制实现高效数据采集。其中，环境监测智能体基于深度 Q 学习算法动态调整采样频率，优先传输异常数据至边缘节点[54]。边缘计算节点对原始数据进行实时滤波和特征提取后，环境调控智能体协同通风、喂食等设备智能体进行分布式决策，将环境参数维持在最佳区间。这种实现方式使响应延迟降低至毫秒级，同时减少人工干预频次达 40%。

智慧养殖中多智能体协同与大模型等技术的应用虽然前景广阔，但在实际落地过程中仍面临多重挑战。数据隐私问题是首要障碍，农业物联网设备采集的养殖环境数据、动物健康信息等涉及商业机密，现有数据保护机制尚不完善。多智能体系统需要跨设备的数据共享，这种开放性加剧了隐私保护难度，如何在协作中实现数据可用性与安全的平衡成为关键问题。

3.3　边缘计算支持下的多智能体协同农业物联网

边缘计算通过其低延迟与分布式特性，显著提升了多智能体协同农业物联网系统的性能。在农业场景中，传感器节点与智能设备产生的海量数据需要实时处理，而传统云计算模式因网络延迟难以满足时效性需求。边缘计算将计算能力下沉至网络边缘，使得数据在本地即可完成预处理与分析。例如，

LIU 等[55]提出的多智能体强化学习框架,通过分布式决策优化任务卸载策略,降低了系统整体能耗,同时避免了集中式网关的信道估计开销。物联网框架中的计算卸载模型如图 15 所示,包含云平台、边缘层和本地终端设备 3 层。考虑一个多用户 IoT 边缘计算网络,由 U 个单天线终端用户(如传感器、移动设备,仅能处理少量计算任务)和 1 个单天线边缘服务器(集成于网关,计算能力更强)组成。假设终端用户静止且随机分布在网关周围,其处理数据的方式有两种:在本地进行计算;将计算任务卸载至网关的边缘服务器处理。由于计算能力有限且生成的计算任务有延迟约束,终端用户会从无线接入技术集 RA 中选择一种,并从每个无线接入技术对应的 M 个正交子信道集合 CH 中选取子信道,将部分计算任务卸载到网关。每个终端用户持续生成不同的计算任务,第 j 个任务表示为 $T_{i,j}(d_{i,j},L_{i,j})$,其中 $d_{i,j}$ 为任务大小,$L_{i,j}$ 为任务执行延迟约束。这种模式特别适用于农田环境监测、无人机协同作业等对实时性要求严苛的场景。

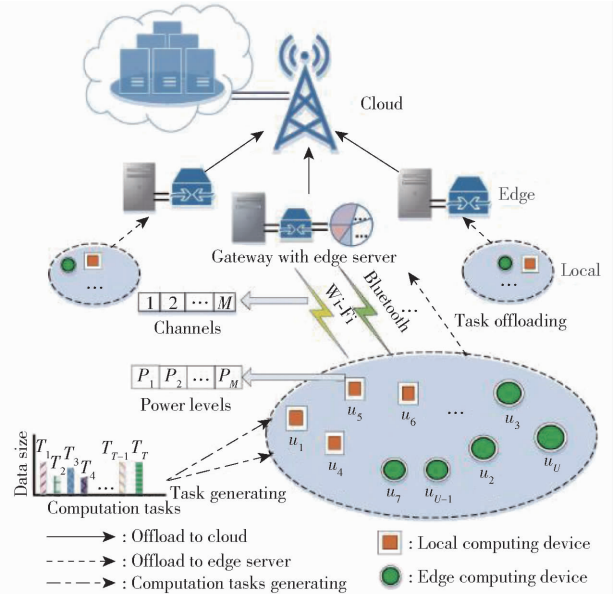


图 15 IoT 网络中的计算卸载模型[55]

Fig. 15 Computation offloading model in IoT networks[55]

多智能体系统与边缘计算的融合显著提升了农业物联网中资源调度与任务执行的智能化水平。BOUBIN 等[56]提出的 MARbLE 平台(如图 16 所示)覆盖从离线开发到边缘部署的完整流程。开发者通过提供 Map()和 Eval()两个核心函数,分别用于将传感器数据转换为特征向量和评估任务完成度,并配置任务的目标阈值与资源预算。平台结合代表性数据自动训练多智能体强化学习(MARL)模型,并生成智能体容器用于实际部署。在线上执行阶段,系统包含传感器容器、智能体容器和在线学习容器:传感器容器采集环境信息,通过 HDFS 分布式存储传输至智能体容器,后者进行状态评估与动作决策;在线学习容器则持续获取数据,实时优化 MARL 模型。Kubernetes 被用于调度容器和边缘计算资源,平台还引入基于工作负载的节点休眠机制与基于任务优先级的模型更新策略,以提升能效和执行效率。实验结果显示,MARbLE 在农业任务中将执行速度提升了 2.1 倍,并使边缘能耗降低 50%。例如,在作物病虫害识别任务中,系统能够根据传感器数据的区域优先级自主调配计算资源,实现无需依赖云端指令的本地智能响应。

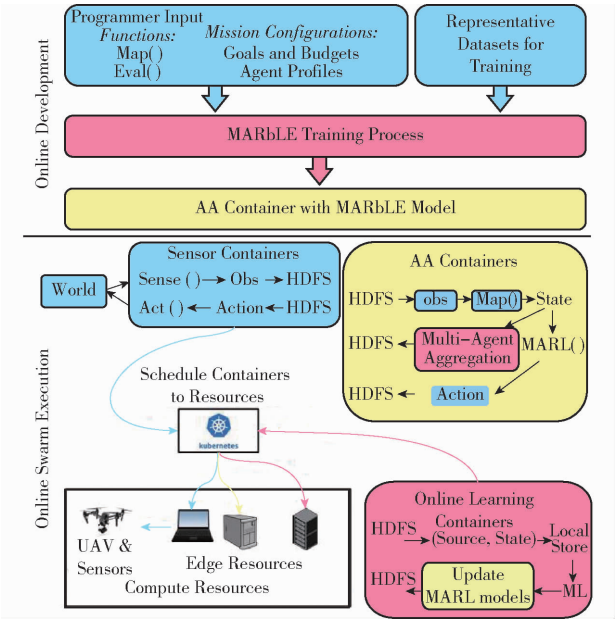


图 16 MARbLE 平台架构[56]

Fig. 16 Architecture of MARbLE[56]

技术融合与未来发展趋势揭示了多智能体协同、大模型、物联网和边缘计算在智慧养殖中的协同增效作用。未来智慧养殖发展将呈现 3 大技术路径:算法层面将涌现新型风险感知模型,如基于条件风险价值 CVaR 的任务卸载算法可降低关键任务失败概率达 43%[57];架构层面将优化云-雾-边缘协同机制,通过多智能体系统实现计算资源的弹性调度;应用层面将深化数字孪生与语义网技术的融合,支持跨平台农业知识图谱构建[58]。政策支持需重点关注农业数据确权与边缘计算基础设施标准化建设,而跨学科合作将推动养殖专用大模型的垂直领域优化。这些发展将系统性解决当前面临的隐私保护、资源约束和模型可解释性等核心挑战。然而,计算资源限制制约了系统性能表现。边缘计算节点部署在资源受限环境中,其计算能力与能源供应有限。当多个智能体同时请求处理高优先级任务时,资源竞争会导致响应延迟。异构设备间的能耗差异(如无人机与地面传感器)进一步增加了资源调度算法

的设计复杂度。

4　大模型技术、农业物联网、边缘计算融合框架及应用场景

作为信息技术与养殖业深度融合的产物，智慧养殖通过农业物联网 IoT 构建全要素感知网络，依托边缘计算实现近源数据处理，最终借助大模型的智能分析能力形成闭环决策系统。这种技术融合有效解决了传统养殖中环境调控粗放、疫病防控滞后等痛点，为农业可持续发展提供了新的技术范式。

农业物联网通过部署温湿度传感器、视频监控设备和动物可穿戴装置等异构终端，构建覆盖养殖全流程的立体感知网络。边缘计算则将这些海量数据的处理任务下沉至网络边缘，显著降低了云计算架构固有的传输延迟。而大模型凭借其强大的跨模态理解能力和知识迁移特性，能够整合环境参数、动物行为等多维数据，实现从数据感知到智能决策的端到端优化。大模型技术、农业物联网、边缘计算三者的协同应用形成了“感知-计算-决策”的完整技术链条。

4.1　整体融合框架

农业物联网作为现代智慧农业的核心技术体系，通过部署温湿度传感器、土壤墒情监测仪、动物可穿戴设备等异构终端，构建覆盖养殖环境与生物行为的全维度感知网络[59]。其技术特点主要体现在 3 方面：多源数据采集能力，可同步获取环境参数、动物生理指标及行为特征等结构化与非结构化数据；广域覆盖特性，通过 LoRa、NB－IoT 等低功耗广域网络实现大范围监测；实时反馈机制，为精准饲喂、疫病预警等场景提供数据支撑[60]。

边缘计算技术的引入有效解决了传统农业物联网的云端处理瓶颈。该技术通过分布式架构将计算任务迁移至靠近数据源的边缘节点（如智能网关、嵌入式设备），显著降低了网络传输延迟与带宽消耗。WAN 等[61]基于树莓派的边缘计算模块实现猪只行为识别的端侧处理，响应时间缩短至 200 ms 以内。

JIANG 等[62]提出了一个以边缘为中心的多模态农业物联网数据综合分析框架 Farm－LightSeek，该框架整合轻量级大语言模型与边缘计算，通过收集农田多源实时数据，在边缘节点进行跨模态推理、疾病检测和低延迟决策，并支持云端模型更新。如图 17 所示，整体网络流程主要包括多模态数据采集、模型蒸馏训练、推理部署与边缘-云协同优化 4 个阶段。在农业场景中，传感器、无人机等设备用于采集图像、温湿度等多模态种子知识数据。随后，通过蒸馏预训练，并结合特征对齐数据，利用包含大语言模型（LLM）的教师模型引导学生模型进行初步学习。在此基础上，引入指令调节机制对数据进行指令重构，通过监督微调与蒸馏微调进一步强化学生模型的学习效果，使其在视觉特征、响应分布和自相关矩阵等方面更好地对齐教师模型。在多模态建模阶段，将文本信息与预处理后的图像特征拼接输入模型，经过深度融合计算，生成可用于农业生产决策的响应结果。在模型部署阶段，结合云端与边缘的协同能力：云端可进行知识提炼与模型优化，边缘节点则通过网关与云端交互，实现低延迟、高可靠的本地推理与决策。最终，田间机器人依据模型输出

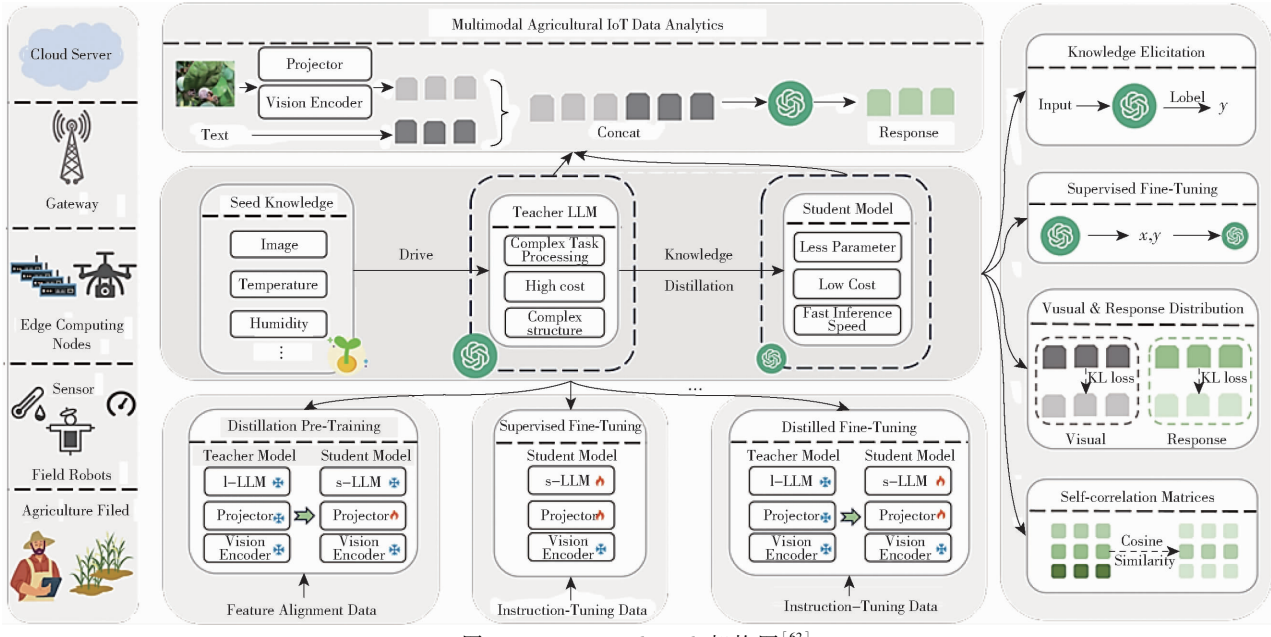


图 17　Farm－LightSeek 架构图[62]

Fig. 17　Architecture diagram of Farm－LightSeek[62]

执行相应作业，构建“感知-决策-行动”的智能闭环。经实验验证，该流程在 Chatbot - Bench 测评中，参数规模降至 1B 时 GPT - 4 评分为 51.5 分，接近大模型性能；VQA - Bench 闭集准确率达 85.9%，能可靠识别农业病虫害等，有效助力智慧农业高效、智能运行，在边缘计算资源受限场景下，平衡了性能与效率，为农业数字化转型提供有力支撑。

由此可见，大模型在农业物联网中发挥着数据处理与智能决策支持的双重核心作用。通过整合温湿度传感器、动物行为监测设备等多源异构数据，大模型能够完成高效的数据清洗、特征提取和模式识别，有效解决传统农业物联网系统在实时分析精度和数据处理效率方面的瓶颈问题[63]。这种能力为精准养殖建立了高质量的数据基础，同时通过边缘计算节点的本地化处理优化了数据传输效率。

在智能决策支持层面，大模型依托深度学习架构实现了复杂农业场景的动态建模与优化。LIU 等[64]基于边缘设备部署的轻量化模型可实时分析畜禽体温、活动量等生物特征，结合时序预测模型实现疾病风险预警。这种协同机制显著提升了饲料配比决策的响应速度，并通过分布式学习框架增强了数据隐私保护。

大模型与边缘计算的协同架构设计需要解决资源受限环境下的高效部署问题。分层设计是核心策略之一，例如，ZHANG 等[65]提出的两级推理架构，通过在边缘设备执行轻量化一级推理，同时将特征上传至边缘服务器进行二级推理，显著降低了延迟并提升灵活性。这种分层思想在 FAN 等[66]的 3 层云-雾-边缘（Fog - Edge - Cloud，FEC）网络中进一步扩展，如图 18 所示。系统划分为设备层、FEC 和云层 3 个层级，支持多种计算模式以适应不同场景下算力与时延需求。其中，缓存辅助计算模式（a）利用雾边层的缓存资源，在无需上行计算的情况下直接将结果回传至设备，在处理缓存匹配任务时，相比无缓存常规计算流程，任务平均响应时间缩短约 35%，有效缩短整体响应时间；云辅助计算模式（b）则通过分阶段卸载机制完成任务的逐级上行传输，b① 表示任务从设备上传至雾边节点，b②表示再由雾边节点上传至云端，由云服务器完成高负载任务的计算并将结果返回设备端，在处理大规模数据处理任务时，该模式下任务完成时延相较于设备本地独立计算降低 42%，充分释放云端算力价值；设备-雾边联合计算模式（c）通过任务分片与协同卸载（c①、c②）在设备与雾边层之间协同处理，整合结果后回传设备，在多设备协同的典型场景中，设备侧能耗相较于纯本地计算降低 28%，任务完成效率（以单位时间完成任务量衡量）提升 30%，实现边缘高效协同计算。

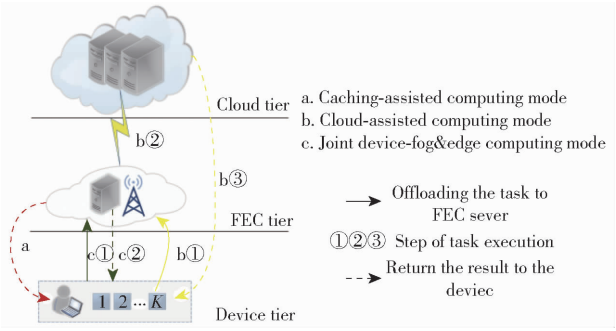


图 18 分层云雾和边缘计算网络图示

Fig. 18 Illustration of hierarchical cloud - fog - edge computing network

在智慧养殖应用中，该架构需要特别关注环境监测和动物行为识别等任务的实时性要求。通过动态调整计算任务在边缘层和云端的分配比例，可以平衡响应速度与计算精度。同时，结合农业物联网设备采集的多模态数据，该架构能够实现更精准的养殖环境调控和动物健康预警。

大模型在边缘设备部署时面临的核心挑战可归纳为：计算资源限制、延迟敏感性和模型压缩需求。边缘设备的有限计算能力、存储空间和能耗预算与大模型的高内存占用、浮点运算需求形成尖锐矛盾，这种资源不匹配导致直接部署困难[67]。在智慧养殖场景中，环境监测和动物行为识别等任务对实时性要求极高，通常需要毫秒级响应，而大模型的推理延迟难以满足此类需求。

针对边缘设备的大模型优化策略，模型轻量化技术是解决计算资源限制的关键途径。量化技术通过降低模型参数的精度（如从 32 位浮点转为 8 位整数），显著减少存储需求和计算复杂度，同时保持可接受的精度损失[68]。例如，在电力设备智能检测场景中，SHANG 等[69]提出的自动化剪枝与量化组合方法无需人工设置各层压缩率，有效降低了边缘服务的计算复杂度和工作负载。在分布式场景下，PRAKASH 等[70]提出的 GWEP 框架联合剪枝与量化技术可使联邦学习的训练速度提升 10.23 倍，同时保持高模型压缩率和学习性能。WU 等[71]提出的自适应压缩技术 FedComp 通过张量索引共享和残差压缩，在资源受限设备上实现高达 28.5 倍的通信压缩率。

实际部署时需结合场景特性动态调整。WANG 等[72]通过上下文感知模型树适应网络波动，使边缘计算系统决策延迟降低 30% ~50%。隐私保护方面，JIANG 等[73]混合差分隐私与自适应压缩能有效防御工业边缘计算中的推理攻击，在保证模型精度

的前提下实现 ε^2 的隐私预算。这些技术的协同优化是解决边缘设备资源约束与业务需求间矛盾的有效方案。

未来研究应重点关注大模型与边缘计算的协同优化机制。在技术层面，可探索多智能体强化学习在农业物联网中的动态资源分配策略。同时，结合大语言模型的领域知识建模能力，可构建面向养殖场景的实时决策支持系统，有效解决数据异构性与模型可解释性等关键问题。

4.2　智慧养殖应用场景

大模型在养殖环境监测中的应用主要体现在对温湿度、空气质量等关键参数的实时监控与预警，从而保障动物健康并提升养殖效率。通过农业物联网传感器网络，大模型能够整合多源异构数据，利用无线传感器节点部署实现环境数据的采集与传输，并结合生物神经网络算法优化节点布局，减少监测盲区。例如，MA 等[74]开发的非接触式体温预测系统通过分析环境温湿度与红外图像数据，实现了对牛只深部体温的精准估计，为早期疾病预警提供了技术支撑。

在动物行为分析的智能化实践中，大模型通过解析摄像头采集的动物活动轨迹和进食行为数据，显著提升了养殖行为管理的精准度。基于 LoTE - Animal 数据集的大规模视频标注，大模型能够识别进食频率、活动范围等关键行为指标，并通过时间序列分析建立行为异常检测模型[75]。其中，视频基础模型对异常行为的泛化识别能力可与穿戴式传感器采集的生理参数形成互补，从而实现跨模态联合验证[76]。这种融合分析在禽流感早期预警中召回率达 92.3%，显著优于单一模态检测方法。同时，边缘节点部署的轻量化模型通过知识蒸馏技术压缩参数量达 67%，疾病分类准确率仍能保持 89% 以上。

在实际养殖场景中，大模型可整合环境传感器数据、视频行为数据及个体生理数据，实现对猪群健康状况的多维度监测。以母猪体况评分为例，传统人工依赖观察评分点的方法存在主观性强、效率低下的问题。近年来，结合大模型、物联网与边缘计算的自动化评分系统逐渐成为研究热点。例如，XUE 等[77]提出的母猪体况评分数据收集和处理系统如图 19 所示。由履带式机器人、图像采集模块和数据处理单元组成，通过摄像头获取母猪臀部图像，并利用大模型完成评分分析，实现了自动化评分与适配母猪筛选。实验结果表明，该系统平均评分精度达 91.06%，单头评分时间为 0.8 s，评分效率较人工方法提升约 50 倍。

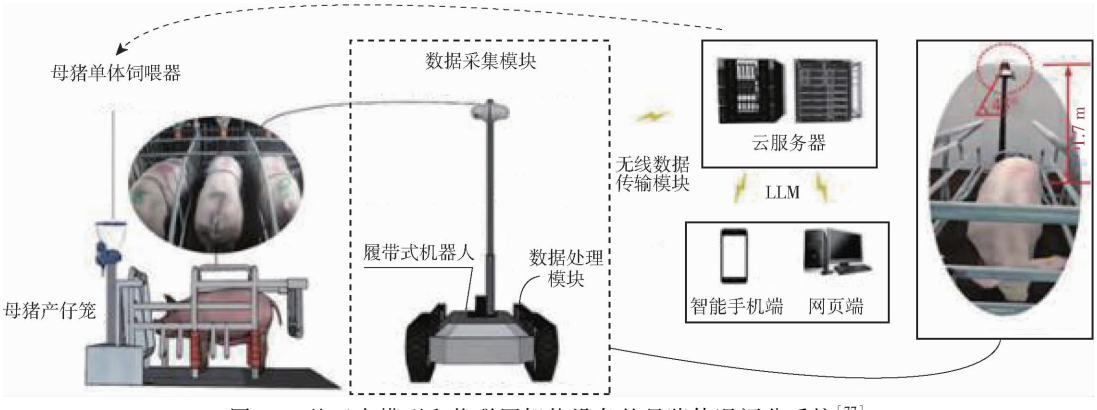


图 19　基于大模型和物联网智能设备的母猪体况评分系统[77]

Fig. 19　Sow body condition scoring system based on large models and IoT smart devices[77]

除体况评分外，母猪体质量也是衡量其发育状况与健康水平的重要生理指标，对于精准饲喂与健康干预同样具有关键价值。然而，传统地磅称量方式因误差大、应激强、效率低等问题，在现代养殖场景中难以满足实际需求。近年来，无接触式体质量估测技术逐步发展，结合物联网传感器与大模型，可实现实时、高效的自动化监测，显著减少人工干预，提升动物福利与数据质量[78]。此类系统通常具备数据自动采集、分析和管理等功能，已在多个养殖场景中得到应用。如图 20 所示，该系统集成深度相机与大模型推理模块，部署于工业控制平台，可自动采集点云数据并完成实时体质量估测，进一步提升了智能养殖的自动化与数字化水平[79]。

大模型在动物疾病预测中的应用主要体现在通过多源数据融合与智能分析实现早期预警。例如，JIN 等[80]提出的 Health - LLM 框架展示了检索增强生成技术对疾病预测的改进效果，如图 21 所示。Health - LLM 主要包括特征生成、信息检索、特征融合与疾病预测等关键环节。首先，系统利用 LLM 的强大的上下文理解能力，在“疾病-症状”示例的引导下生成症状特征，并通过（检索增强生成）RAG 机制从医学知识库中检索相关信息，提升特征表达的

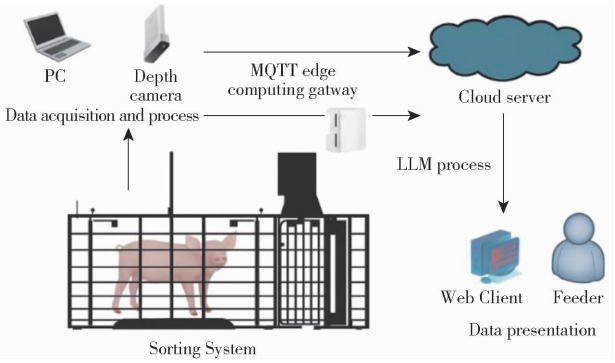


图 20 基于大模型和边缘计算的无接触式体质量估测系统[79]

Fig. 20 Contactless body mass estimation system based on large models and edge computing[79]

准确性与丰富性。随后,采用 Llama Index 框架对健康报告进行结构化处理,将文本块转化为向量表示并存储于向量数据库中。在接收到用户查询后,系统可高效检索相关文本块并进行融合推理,输出 0~1 之间的置信度评分。同时,集成的上下文感知自适应特征增强(CAAFE)技术支持特征的动态更新,以增强系统在多场景下的泛化能力。在疾病预测阶段,系统引入 XGBoost 模型对融合后的特征进行拟合,支持对包括精细化子类在内的 61 种疾病标签进行多分类预测。最终,系统结合大语言模型生成个性化的健康建议,用户可通过提交健康报告或自然语言问题与系统进行交互,实现闭环式健康管理。实验结果显示,Health-LLM 在 IMCS-21 医学对话数据集上的疾病预测准确率达到 83.3%,F1 分数为 76.2%,显著优于 GPT-4(准确率 68%,F1 分数 71%)等现有方法,展现出卓越的疾病识别与建议生成能力。

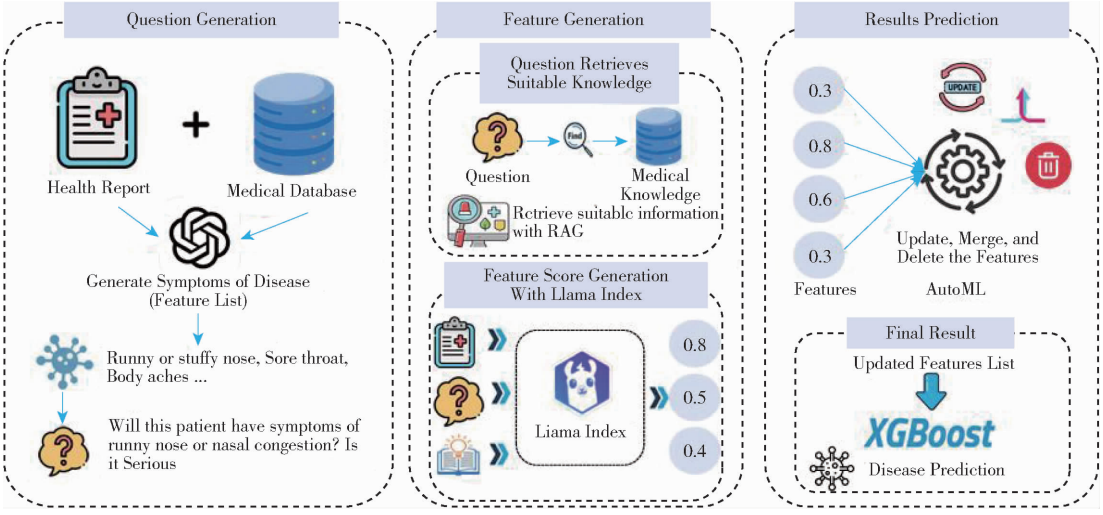


图 21 Health-LLM 整体工作流程[80]

Fig. 21 Overall workflow of Health-LLM[80]

综合分析表明,大模型与物联网、边缘计算智能设备的结合显著提升了养殖效率和效益增收。在效率方面,大模型通过边缘计算架构实现了实时数据处理,将环境监测响应时间从传统方法的分钟级缩短至秒级,同时自动化决策流程使饲料投喂效率提升 30% 以上[81]。准确性上,基于多模态数据融合的大模型在动物行为识别中表现出显著优势,其时间序列预测能力使疾病早期预警准确率得到明显提升。

然而,大模型在智慧养殖中的应用仍面临一定的技术瓶颈。首先,异构感知数据的融合需要依赖定制化的预处理流程,不仅增加了模型部署复杂性,也带来了额外的计算负担;其次,当前在模型压缩与精度保持之间仍难以实现理想平衡,压缩后的模型在边缘部署中可能存在特征丢失或性能下降的问题;此外,实时推理性能受限于网络基础设施,在偏远或设备条件有限的中小型养殖场中容易出现通信延迟,影响模型稳定运行。

5 大模型技术在智慧养殖领域面临的主要挑战

5.1 数据隐私

在智慧养殖过程中产生的大量数据涉及养殖企业的核心商业机密和动物的健康信息等隐私数据。多模态大模型、农业物联网和边缘计算的集成应用虽然提升了养殖效率,但大量敏感数据的采集、传输和存储过程也带来了显著的隐私泄露风险。养殖场的环境监测数据、动物生理特征及行为记录等敏感信息在传输过程中可能遭受中间人攻击,而存储在边缘节点或云端的原始数据则面临数据推断和逆向工程等威胁。如何确保这些数据在传输、存储和使用过程中的安全性和隐私性,防止数据泄露和被恶意利用,是智慧养殖面临的重要挑战之一。

现有加密技术在智慧养殖场景中存在明显局限

性。传统对称加密算法虽然计算效率较高，但密钥管理复杂且难以抵御量子计算攻击。此外，现有哈希函数和数字签名方案无法有效应对数据聚合场景下的隐私保护需求[82]。这些技术缺陷使得养殖数据在共享过程中容易遭受篡改或泄露，特别是在多方参与的农业数据共享生态中。

针对上述挑战，新兴隐私保护技术展现出应用潜力。基于区块链的分布式认证框架通过智能合约实现了数据访问的细粒度控制，同时确保操作记录的不可篡改性。轻量级隐私增强技术如差分隐私和同态加密，可以在数据预处理阶段实现敏感信息保护，而不会显著影响后续分析模型的准确性。特别是椭圆曲线密码学的创新应用，在保证安全性的同时大幅降低了计算资源消耗，更适合农业物联网环境。

5.2　资源受限下模型优化

在智慧养殖中应用大模型面临的首要挑战是计算资源的限制。边缘设备的计算能力和存储容量通常有限，而大模型的高计算复杂度和庞大的参数量使得直接部署变得困难。DANTAS 等[83]指出，模型压缩技术如量化、剪枝和知识蒸馏是解决这一问题的关键方法，能够显著降低模型的计算和存储需求。然而，这些技术在实际应用中仍面临模型精度损失和泛化能力下降的问题。

5.3　算力不足与延迟

在智慧养殖的实际应用中，边缘设备算力不足与云端资源调度延迟是制约实时监测效能的核心瓶颈。多模态大模型的高计算需求与边缘设备的有限处理能力之间存在显著矛盾，例如，一些图卷积网络动物追踪系统需在 22 f/s 实时性要求下运行，而传统 DeepSORT 算法因计算复杂度高导致处理速度下降[84]。这验证了轻量化模型通过结构优化可同时提升速度与精度，其 ID 关联准确率提高 1.72% 且 ID 切换错误减少 93%。

分布式计算架构为解决延迟问题提供了技术路径。例如，GONÇALVES 等[85]在山羊分娩监测中采用边缘计算方案，将机器学习模型部署于本地设备实现实时报警，避免了云端通信的固有延迟。该案例表明任务分层分配（如边缘节点处理数据预处理和简单分类）可使系统响应时间缩短 66%，但异构设备间的数据融合仍依赖标准化资源调度框架。

5.4　模型可解释性

模型可解释性在智慧养殖中同样至关重要。养殖户和农业专家需要理解模型的决策依据，以建立信任并指导实际应用。可解释 AI 技术如特征重要性分析和反事实解释能够提升模型透明度，但这些方法在边缘设备上的实现面临计算资源限制。EZZEDDINE[86]指出，解释性增强可能加剧隐私风险，例如通过模型提取攻击获取敏感信息，这要求在设计时平衡解释性与安全性。

5.5　实时性要求和技术整合

实时性要求和技术整合的复杂性也为技术落地带来了额外压力。智慧养殖中的环境监测和疾病预警等场景需要低延迟响应，而大模型在边缘设备上的推理速度往往难以满足需求。虽然 WANG 等[87]提出的数据-模型-系统三重优化框架通过流式计算和硬件加速技术改善了实时性能，但其部署成本较高，且对网络稳定性依赖性强。此外，大模型与农业物联网、边缘计算的结合涉及多层次技术栈，包括数据预处理、模型优化、硬件适配等环节。混合压缩方法和智能框架选择是未来发展方向，但目前缺乏统一的标准化方案，导致实际部署效率低下。

6　展望

随着大模型、农业物联网和边缘计算技术的快速发展，智慧养殖领域正迎来前所未有的变革机遇。未来研究应重点从技术突破、应用场景扩展和政策支持 3 个维度推动行业发展，并进一步推动三者的深度融合。

在技术突破方面，模型轻量化和边缘计算架构优化仍是核心研究方向。新兴硬件如神经形态芯片与量子计算的结合，有望突破当前计算瓶颈。多模态大模型的发展将增强对图像、声音等多源数据的融合处理能力，而联邦学习技术的改进有助于解决数据孤岛问题。

在应用场景拓展方面，应鼓励多样化的智慧养殖模式与系统形态的发展，从传统猪牛羊等规模化畜禽养殖，逐步延伸至水产、昆虫、特种养殖等细分领域，并结合不同区域的生态环境与经济条件，开发定制化、模块化的智慧养殖解决方案。此外，应重点推进“数字牧场”“边缘养殖网关”“智能行为识别系统”“无人化巡检系统”等场景的深度落地，通过端-边-云协同机制，提高养殖过程的自动化和预警能力。针对中小养殖户，发展低成本、即插即用的轻量级边缘 AI 方案，进一步地推动智慧养殖普惠化。

在政策支持方面，建议国家从产业战略高度加强智慧农业基础设施建设与数据要素治理。例如：出台智慧养殖数据确权机制，规范传感数据与动物生理数据的采集、传输和使用权限；建立统一的数据交换标准和 AI 模型接口规范，推动设备厂商、平台企业和科研机构之间的数据互通；完善农业 AI 模型评估与认证机制，推动大模型透明性、可解释性、安

全性的持续优化;设立“智能养殖先导区”或“边缘智能试验基地”,以政府牵引方式鼓励示范应用落地和技术成果转化。

综上所述,大语言模型、农业物联网与边缘计算的融合不仅是智慧养殖智能化升级的关键路径,更代表着未来农业从“感知驱动”迈向“认知驱动”的范式转变。在这一过程中,模型能力的不断增强、计算架构的持续优化以及场景落地的深入拓展将共同驱动智慧养殖系统从“单点智能”走向“系统协同智能”。未来研究需在算法与系统、技术与应用、创新与治理之间形成多维协同,构建以数据为基础、以智能为核心的农业新范式。

参 考 文 献

[1] NAVARRO E, COSTA N, PEREIRA A. A systematic review of IoT solutions for smart farming[J]. Sensors, 2020, 20(15): 4231.

[2] DAYOUB M, SHNAIGAT S, TARAWNEH R A, et al. Enhancing animal production through smart agriculture: possibilities, hurdles, resolutions, and advantages[J]. Ruminants, 2024, 4(1): 22 - 46.

[3] XU J, GU B, TIAN G. Review of agricultural IoT technology[J]. Artificial Intelligence in Agriculture, 2022, 6: 10 - 22.

[4] 滕光辉. 畜禽设施精细养殖中信息感知与环境调控综述[J]. 智慧农业,2019,1(3):1 - 12.
TENG Guanghui. Information sensing and environment control of precision facility livestock and poultry farming[J]. Smart Agriculture, 2019, 1(3): 1 - 12. (in Chinese)

[5] PITU F, GAITAN N C. Implementing a wide-area network and low power solution using long-range wide-area network technology [J]. Technologies, 2025, 13(1): 36.

[6] 杨飞云,曾雅琼,冯泽猛,等. 畜禽养殖环境调控与智能养殖装备技术研究进展[J]. 中国科学院院刊,2019,34(2):163 - 173.
YANG Feiyun, ZENG Yaqiong, FENG Zemeng, et al. Research status on environmental control technologies and intelligent equipment for livestock and poultry production[J]. Bulletin of Chinese Academy of Sciences, 2019, 34(2): 163 - 173. (in Chinese)

[7] HE Q, ZHAO H, FENG Y, et al. Edge computing-oriented smart agricultural supply chain mechanism with auction and fuzzy neural networks[J]. Journal of Cloud Computing, 2024, 13(1): 66.

[8] 黄成龙,柯宇曦,华向东,等. 边缘计算在智慧农业中的应用现状与展望[J]. 农业工程学报,2022,38(16):224 - 234.
HUANG Chenglong, KE Yuxi, HUA Xiangdong, et al. Application status and prospect of edge computing in smart agriculture [J]. Transactions of the CSAE, 2022, 38(16): 224 - 234. (in Chinese)

[9] CAI F, YUAN D, YANG Z, et al. Edge-llm: a collaborative framework for large language model serving in edge computing[C]// 2024 IEEE International Conference on Web Services (ICWS). IEEE, 2024: 799 - 809.

[10] 肖培,宫鹤,孟楚,等. 基于物联网的梅花鹿精准养殖监控系统设计与应用[J]. 黑龙江畜牧兽医,2020(24):141 - 145, 178 - 179.
XIAO Pei, GONG He, MENG Chu, et al. Design and application of sika deer (*Cervus nippon*) precision farming monitoring system based on internet of things[J]. Heilongjiang Animal Science and Veterinary Medicine, 2020(24): 141 - 145, 178 - 179. (in Chinese)

[11] GAVRILESCU M. Water, soil, and plants interactions in a threatened environment[J]. Water, 2021, 13(19): 2746.

[12] VELUSAMY P, RAJENDRAN S, MAHENDRAN R K, et al. Unmanned aerial vehicles (UAV) in precision agriculture: applications and challenges[J]. Energies, 2021, 15(1): 217.

[13] 张锋, 黄自强, 申启杨, 等. 边缘算力在智能水产养殖方面研究与应用[J]. 渔业现代化, 2024, 51(2): 53 - 60.
ZHANG Feng, HUANG Ziqiang, SHEN Qiyang, et al. Application of edge computing power in intelligent aquaculture[J]. Fishery Modernization, 2024, 51(2): 53 - 60. (in Chinese)

[14] FATHONI H, YANG C T, HUANG C Y, et al. Empowered edge intelligent aquaculture with lightweight Kubernetes and GPU-embedded[J]. Wireless Networks, 2024, 30(9): 7321 - 7333.

[15] SCHUKAT S, HEISE H. Smart products in livestock farming—an empirical study on the attitudes of German farmers[J]. Animals, 2021, 11(4): 1055.

[16] 李道亮,赵晔,杜壮壮. 农业领域多模态融合技术方法与应用研究进展[J]. 农业机械学报,2025,56(1):1 - 15.
LI Daoliang, ZHAO Ye, DU Zhuangzhuang. Advances in multi-modal fusion techniques and applications in agricultural field [J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 1 - 15. (in Chinese)

[17] 张奇, 桂韬, 郑锐,等. 大规模语言模型:从理论到实践[M]. 北京: 电子工业出版社, 2023.

[18] KOROTEEV M V. BERT: a review of applications in natural language processing and understanding[J]. arXiv preprint arXiv:2103.11943, 2021.

[19] LIU X, ZHENG Y, DU Z, et al. GPT understands, too[J]. AI Open, 2024, 5: 208 - 215.

[20] LO C K. What is the impact of ChatGPT on education? A rapid review of the literature[J]. Education Sciences, 2023, 13(4): 410.

[21] MENEZES G L, MAZON G, FERREIRA R E P, et al. Artificial intelligence for livestock: a narrative review of the

applications of computer vision systems and large language models for animal farming[J]. Animal Frontiers, 2024, 14(6): 42 – 53.

[22] FABIAN Z, MIAO Z, LI C, et al. Multimodal foundation models for zero-shot animal species recognition in camera trap images [J]. arXiv preprint arXiv:2311.01064, 2023.

[23] FRIHA O, FERRAG M A, SHU L, et al. Internet of things for the future of smart agriculture: a comprehensive survey of emerging technologies[J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(4): 718 – 752.

[24] KANNAN S S, VENKATESH V L N, MIN B C. Smart-LLM: smart multi-agent robot task planning using large language models[C]//2024 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2024: 12140 – 12147.

[25] BAJIC B, SUZIC N, MORACA S, et al. Edge computing data optimization for smart quality management: industry 5.0 perspective[J]. Sustainability, 2023, 15(7): 6032.

[26] 张梓强. 智慧农业领域人工智能大模型的应用探索[J]. 中国农机装备,2025(2):94 – 96.
ZHANG Ziqiang. Application exploration of artificial intelligent large models in the field of smart agriculture[J]. China Agricultural Machinery Equipment, 2025(2):94 – 96. (in Chinese)

[27] LI J, XU M, XIANG L, et al. Foundation models in smart agriculture: basics, opportunities, and challenges[J]. Computers and Electronics in Agriculture, 2024, 222: 109032.

[28] KATE M, NEETHIRAJAN S. Decoding bovine communication with AI and multimodal systems—advancing sustainable livestock management and precision agriculture[J]. bioRxiv, 2025.

[29] 王昊,汪淼,龙金龙,等. 基于多模态背景抑制的鱼类摄食强度识别[J/OL]. 大连海洋大学学报,http://kns.cnki.net/kcms/detail/21.1575.S.20250527.1851.012.html.

[30] TZACHOR A, DEVARE M, RICHARDS C, et al. Large language models and agricultural extension services[J]. Nature Food, 2023, 4(11): 941 – 948.

[31] 汤文权,王巧华,张浩,等. 基于多模态信息融合的皮蛋溏心沙心分类方法[J]. 农业机械学报,2025,56(1):92 – 101.
TANG Wenquan, WANG Qiaohua, ZHANG Hao, et al. Classification methods for soft-yolk and hard-yolk preserved eggs based on multimodal information fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 92 – 101. (in Chinese)

[32] LEE S A, LAGOS L V, MERRIMAN L A, et al. Digestibility of calcium in calcium-containing ingredients and requirements for digestible calcium by growing pigs[J]. Journal of Animal Science, 2023, 101: skad328.

[33] TINA F W, AFSARIMANESH N, NAG A, et al. Integrating AIoT technologies in aquaculture: a systematic review[J]. Future Internet, 2025, 17(5): 199.

[34] FENG T, SHEN H, YANG X, et al. Integration of large language models with IoT in smart agriculture to improve efficiency, yield, and quality[J]. Ind. Sci. Eng., 2024, 1: 15 – 35.

[35] QAZI A, RAZZAQ T, IQBAL A. AnimalFormer: multimodal vision framework for behavior-based precision livestock farming [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 7973 – 7982.

[36] CHEN H, JI W, XU L, et al. Multi-agent consensus seeking via large language models[J]. arXiv preprint arXiv:2310.20151, 2023.

[37] PARK J S, POPOWSKI L, CAI C, et al. Social simulacra: creating populated prototypes for social computing systems[C]// Proceedings of the 35th Annual ACM Symposium on User Interface Software and Technology, 2022: 1 – 18.

[38] XU Z, YU C, FANG F, et al. Language agents with reinforcement learning for strategic play in the werewolf game[J]. arXiv preprint arXiv:2310.18940, 2023.

[39] MAO S, CAI Y, XIA Y, et al. ALYMPICS: LLM agents meet game theory[C]// Proceedings of the 31st International Conference on Computational Linguistics, 2025: 2845 – 2866.

[40] MANDI Z, JAIN S, SONG S. Roco: dialectic multi-robot collaboration with large language models[C]// 2024 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2024: 286 – 299.

[41] LIU Z, ZHANG Y, LI P, et al. Dynamic LLM-agent network: an LLM-agent collaboration framework with agent team optimization[J]. arXiv preprint arXiv:2310.02170, 2023.

[42] HONG S, ZHENG X, CHEN J, et al. MetaGPT: meta programming for multi-agent collaborative framework[J]. arXiv preprint arXiv:2308.00352, 2023, 3(4): 6.

[43] WANG L, MA C, FENG X, et al. A survey on large language model based autonomous agents[J]. Frontiers of Computer Science, 2024, 18(6): 186345.

[44] NASCIMENTO N, ALENCAR P, COWAN D. Self-adaptive large language model (LLM)-based multiagent systems[C]// 2023 IEEE International Conference on Autonomic Computing and Self-organizing Systems Companion (ACSOS – C). IEEE, 2023: 104 – 109.

[45] CHEN G, DONG S, SHU Y, et al. Autoagents: a framework for automatic agent generation[J]. arXiv preprint arXiv:2309.17288, 2023.

[46] SERIÑO V, CAVALIERE D, SENATORE S. Sensing multi-agent system for anomaly detection on crop fields exploiting the

phenological and historical context[C]//2021 International Conference on Emerging Techniques in Computational Intelligence (ICETCI). IEEE, 2021: 43 - 48.

[47] ZHU Z, YU C, WANG J. A hybrid genetic algorithm and proximal policy optimization system for efficient multi-agent task allocation[J]. Systems, 2025, 13(6): 453.

[48] PHAM C, NGUYEN K K, CHERIET M. Joint optimization of UAV trajectory and task allocation for wireless sensor network based on O - RAN architecture[C]//ICC 2022 - IEEE International Conference on Communications. IEEE, 2022: 329 - 334.

[49] 郭文强, 高晓光, 侯勇严, 等. 采用 MSBN 多智能体协同推理的智能农业车辆环境识别[J]. 智能系统学报, 2013, 8(5): 453 - 458.
GUO Wenqiang, GAO Xiaoguang, HOU Yongyan, et al. Environment recognition of intelligent agricultural vehicles based on MSBN and multi-agent coordinative inference[J]. CAAI Transactions on Intelligent Systems, 2013, 8(5): 453 - 458. (in Chinese)

[50] 袁满, 刘耀林. 基于多智能体遗传算法的土地利用优化配置[J]. 农业工程学报, 2014, 30(1): 191 - 199.
YUAN Man, LIU Yaolin. Land use optimization allocation based on multi-agent genetic algorithm[J]. Transactions of the CSAE, 2014, 30(1): 191 - 199. (in Chinese)

[51] 刘敬杰,夏敏,刘友兆,等.基于多智能体与 CA 结合模型分析的农村土地利用变化驱动机制[J].农业工程学报,2018, 34(6):242 - 252.
LIU Jingjie, XIA Min, LIU Youzhao, et al. Driving mechanism of rural land use change based on multi-agent system and cellular automata[J]. Transactions of the CSAE, 2018, 34(6): 242 - 252. (in Chinese)

[52] 王越, 宋戈, 吕冰. 基于多智能体粒子群算法的松嫩平原土地利用格局优化[J]. 资源科学, 2019, 41(4): 729 - 739.
WANG Yue, SONG Ge, LÜ Bing. Optimization of land-use pattern based on multi-agent particle swarm optimization in the Song-nen plain region[J]. Resources Science, 2019, 41(4): 729 - 739. (in Chinese)

[53] PINOTTI F, LOURENÇO J, GUPTA S, et al. EPINEST, an agent-based model to simulate epidemic dynamics in large-scale poultry production and distribution networks[J]. PLoS Computational Biology, 2024, 20(2): e1011375.

[54] PEREZ-PONS M E, ALONSO R S, GARCIA O, et al. Deep q-learning and preference based multi-agent system for sustainable agricultural market[J]. Sensors, 2021, 21(16): 5276.

[55] LIU X, YU J, FENG Z, et al. Multi-agent reinforcement learning for resource allocation in IoT networks with edge computing [J]. China Communications, 2020, 17(9): 220 - 236.

[56] BOUBIN J, BURLEY C, HAN P, et al. Marble: multi-agent reinforcement learning at the edge for digital agriculture[C]// 2022 IEEE/ACM 7th Symposium on Edge Computing (SEC). IEEE, 2022: 68 - 81.

[57] NGUYEN A C, PAMUKLU T, SYED A, et al. To risk or not to risk: learning with risk quantification for IoT task offloading in UAVs[C]//ICC 2023-IEEE International Conference on Communications. IEEE, 2023: 234 - 240.

[58] KALYANI Y, VORSTER L, WHETTON R, et al. Application scenarios of digital twins for smart crop farming through cloud - fog - edge infrastructure[J]. Future Internet, 2024, 16(3): 100.

[59] MAJUMDER S, PAL A, RAY S, et al. An overview of the role of iot in modern agriculture application[C]//2024 2nd International Conference on Signal Processing, Communication, Power and Embedded System (SCOPES). IEEE, 2024: 1 - 4.

[60] YANG D, WU J, HE Y. Optimizing the agricultural internet of things (IoT) with edge computing and low-altitude platform stations[J]. Sensors, 2024, 24(21): 7094.

[61] WAN S, ZHAO K, LU Z, et al. A modularized IoT monitoring system with edge-computing for aquaponics[J]. Sensors, 2022, 22(23): 9260.

[62] JIANG D, SHEN Z, ZHENG Q, et al. Farm - LightSeek: an edge-centric multimodal agricultural iot data analytics framework with lightweight LLMs[J]. IEEE Internet of Things Magazine, 2025,8(6): 1 - 8.

[63] ZHAO Y, LI Q, YI W, et al. Agricultural IoT data storage optimization and information security method based on blockchain [J]. Agriculture, 2023, 13(2): 274.

[64] LIU J, SHU L, LU X, et al. Survey of intelligent agricultural IoT based on 5G[J]. Electronics, 2023, 12(10): 2336.

[65] ZHANG Z, ZHANG Y, YUAN D, et al. A two-level architecture for deep learning applications in mobile edge computing[C]// Proceedings of the 17th ACM Workshop on Mobility in the Evolving Internet Architecture, 2022: 43 - 48.

[66] FAN X, ZHENG H, JIANG R, et al. Optimal design of hierarchical cloud-fog&edge computing networks with caching[J]. Sensors, 2020, 20(6): 1582.

[67] WANG X, TANG Z, GUO J, et al. Empowering edge intelligence: a comprehensive survey on on-device ai models[J]. ACM Computing Surveys, 2025, 57(9): 1 - 39.

[68] RACHMANTO R D, SUKMA Z, NABHAAN A N L, et al. Characterizing deep learning model compression with post-training quantization on accelerated edge devices[C]//2024 IEEE International Conference on Edge Computing and Communications (EDGE). IEEE, 2024: 110 - 120.

[69] SHANG F, LAI J, CHEN J, et al. A model compression based framework for electrical equipment intelligent inspection on edge computing environment[C]//2021 IEEE 6th International Conference on Cloud Computing and Big Data Analytics

(ICCCBDA). IEEE, 2021: 406 – 410.
[70] PRAKASH P, DING J, CHEN R, et al. IoT device friendly and communication-efficient federated learning via joint model pruning and quantization[J]. IEEE Internet of Things Journal, 2022, 9(15): 13638 – 13650.
[71] WU D, YANG W, JIN H, et al. Fedcomp: a federated learning compression framework for resource-constrained edge computing devices[J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2023, 43(1): 230 – 243.
[72] WANG L, XIANG L, XU J, et al. Context-aware deep model compression for edge cloud computing[C]//2020 IEEE 40th International Conference on Distributed Computing Systems (ICDCS). IEEE, 2020: 787 – 797.
[73] JIANG B, LI J, WANG H, et al. Privacy-preserving federated learning for industrial edge computing via hybrid differential privacy and adaptive compression[J]. IEEE Transactions on Industrial Informatics, 2021, 19(2): 1136 – 1144.
[74] MA S, YAO Q, MASUDA T, et al. Development of noncontact body temperature monitoring and prediction system for livestock cattle[J]. IEEE Sensors Journal, 2021, 21(7): 9367 – 9376.
[75] LIU D, HOU J, HUANG S, et al. LoTE-Animal: a long time-span dataset for endangered animal behavior understanding[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 20064 – 20075.
[76] MCVEY C, HSIEH F, MANRIQUEZ D, et al. Livestock informatics toolkit: a case study in visually characterizing complex behavioral patterns across multiple sensor platforms, using novel unsupervised machine learning and information theoretic approaches[J]. Sensors, 2021, 22(1): 1.
[77] XUE H, SUN Y, CHEN J, et al. CAT – CBAM – net: an automatic scoring method for sow body condition based on CNN and transformer[J]. Sensors, 2023, 23(18): 7919.
[78] 刘龙申,柳荦,周杰,等.母猪精准养殖智能感知技术研究进展[J].华南农业大学学报,2024,45(5):635 – 648.
LIU Longshen, LIU Luo, ZHOU Jie, et al. Research progress on precision breeding and intelligent sensing technologies for sows[J]. Journal of South China Agricultural University, 2024, 45(5): 635 – 648. (in Chinese)
[79] 胡肄农, 仇振升, 朱红宾. 一种牛动态称重系统的研发[J]. 中国畜禽种业, 2023, 19(10): 51 – 54.
[80] JIN M, YU Q, SHU D, et al. Health-LLM: personalized retrieval-augmented disease prediction system[J]. arXiv preprint arXiv:2402.00746, 2024.
[81] ZANGANA H M, LUCKYARDI S, MUSTAFA F M, et al. Enhancing agricultural cybersecurity: leveraging deep learning and large language models for smart farming protection[M]// Revolutionizing cybersecurity with deep learning and large language models. IGI Global Scientific Publishing, 2025:307 – 338.
[82] CHERBAL S. 3s – alddt: a triple security scheme for authenticating lightweight devices and securing data transmission in internet of things[J]. Wireless Personal Communications, 2024, 135(2): 727 – 762.
[83] DANTAS P V, SABINO DA SILVA JR W, CORDEIRO L C, et al. A comprehensive review of model compression techniques in machine learning[J]. Applied Intelligence, 2024, 54(22): 11804 – 11844.
[84] PARMIGGIANI A, LIU D, PSOTA E, et al. Don't get lost in the crowd: graph convolutional network for online animal tracking in dense groups[J]. Computers and Electronics in Agriculture, 2023, 212: 108038.
[85] GONÇALVES P, MARQUES M R, BELO A T, et al. Exploring the potential of machine learning algorithms associated with the use of inertial sensors for goat kidding detection[J]. Animals, 2024, 14(6): 938.
[86] EZZEDDINE F. Privacy implications of explainable AI in data-driven systems[J]. arXiv preprint arXiv:2406.15789, 2024.
[87] WANG X, JIA W. Optimizing Edge AI: a comprehensive survey on data, model, and system strategies[J]. arXiv preprint arXiv:2501.03265, 2025.