



中国人工智能学会  
Chinese Association for Artificial Intelligence

# 中国人工智能学会系列白皮书 ——农业大模型

中国人工智能学会  
二〇二五年十一月



# 中国人工智能学会系列白皮书 ——农业大模型

中国人工智能学会  
二〇二五年十一月

《中国人工智能学会系列白皮书》编委会

主任：戴琼海

执行主任：马华东

副主任：赵春江 何友 王恩东 郑庆华 刘成林  
周志华 孙富春 庄越挺 胡德文 杜军平  
杨强

委员：陈松灿 董振江 付宜利 高新波 公茂果  
古天龙 何清 胡清华 黄河燕 季向阳  
蒋田仔 林浩哲 梁吉业 刘奕群 潘纲  
石光明 孙茂松 孙长银 陶建华 王海峰  
王熙照 王轩 王蕴红 吴飞 于剑  
余有成 张化光 张学工 章毅 周鸿祎  
周杰 祝烈煌

编写组名单（排名分先后）：

赵春江 吴华瑞 陈立平 李道亮 朱华吉  
何勇 杨雨森 刘劼 李静晨 张宏鸣  
缪祎晟 吴秋兰 郭旺 胡瑾 曾馨  
王春山 张岳 易文龙 王菲菲 李晓锁  
崔友林 郎立国

# 智能农业白皮书——农业大模型

## 1. 前言

在全球化与信息化浪潮的驱动下，农业生产正迎来前所未有的变革契机。数字经济、人工智能、云计算与物联网等技术迅速渗透到粮食种植、畜牧养殖、农产品流通乃至农村服务的方方面面，推动农业从传统经验驱动逐步转向智能化决策和精细化管理。各国政府也将农业数字化、智慧化摆在国家战略高度，出台了一系列支持政策：从“数字乡村”与“智慧农业”专项资金，到国家层面对农业大数据和人工智能技术研发的专项扶持，再到地方政府对农机装备升级与农村信息基础设施建设的重磅投入。政策红利的连续释放，为农业领域新兴技术的创新应用提供了制度保障与资金支持，也为广大农户带来了更为广阔的发展机遇。

伴随乡村振兴战略的不断深入，产业振兴、人才振兴、科技振兴、生态振兴以及组织振兴的“五大振兴”目标对农业科技创新提出了更高要求。其中，科技振兴尤其强调要发挥人工智能在提升农业生产效率、保障粮食安全和促进绿色发展的关键作用。大语言模型作为近年来人工智能领域的重大突破，以其杰出的自然语言理解与生成能力，具有从海量非结构化文本中自动提取农业知识、生成技术指导乃至协同管理多模态数据的独特价值。它不仅能够辅助政府部门精准制定农业补贴与科技扶持政策，也能引导农业企业优化生产流程与供应链布局，更可以让千家万户的基层农技员和普通农户通过对话式问答获得及时、可信的生产指导，降低技术门槛，提升服务可及性。

与传统人工智能技术相比，大语言模型极大地拓宽了“人机协同”的边界。在农业生产场景中，它可以将卫星遥感、地面传感器、无人机影像等多模式信息与大量农业文献、政策文件、农技手册等文本资源高效融合，通过自然语言接口为用户提供个性化的种植、施肥、病虫害防控、市场预测等解决方案；更可借助多智能体协作框架，实现对农机装备、灌溉系统和气象监测网络的统筹管理。这种“数据—模型—决策—执行”的闭环，为农业产业链注入了数字化活力，逐步打破了生产、管理与销售各环节的信息壁垒，实现了农业生产的“智慧化”“精细化”和“可追溯化”。

尽管前景广阔，大语言模型在农业应用层面仍面临一系列挑战：从数据采集到数据治理，农业领域信息往往分散于各类传感器与部门系统，需要建立统一的标准与互操作机制；从模型训练到推理部署，大规模预训练模型在计算资源与能耗方面投入巨大，需要寻求“云—边—端”协同的轻量化解决路径；从技术赋能到用户接受，农户尤其是偏远地区的数字素养与基础设施建设尚不完善，需要构建持续有效的培训体系与服务网络；从政策支持到合规监管，农业数据隐私保护、知识产权与技术标准需要得到科学定义与完善。在这些问题面前，必须将技术创新与产业需求、生态环境保护与社会效益的平衡放到同等重要的位置，通过产学研用的联合创新与协同治理，推动大语言模型真正融入农业生产与乡村发展大局。本书面向农业

管理部门、农业企业、科研机构、技术开发者以及基层农技推广人员等不同角色，旨在为其提供系统化、可操作的技术参考与业务指导。通过界定读者定位与使用场景，本白皮书在内容取舍上重点围绕政策制定、产业规划、技术研发与生产实践等核心需求展开，使读者能够在理解总体趋势的基础上快速定位与自身工作最相关的内容，从而提高阅读的有效性和应用价值。

本书正是在这样的时代背景与发展需求下诞生。我们力求从理论到实践、从技术到业务、从本土到国际，系统梳理大语言模型在农业领域的应用价值与实施路径。全书十个章节紧密衔接：第一部分从大语言模型发展与农业数字化转型的宏观视角切入，梳理研究背景、国内外现状与总体框架；第二至第四章聚焦大模型的理论基础、工程实践与多模态融合，为后续农业场景应用提供技术支撑；第五至第八章围绕智能种植管理、精准灌溉、病虫害防治、供应链优化、多智能体协作与平台集成等典型场景进行深度剖析，结合各类工具链与实践案例展示可复制的工程模式；第九章通过国内外成功案例与实证研究，解析商业模式、项目管理、风险管控与规模化推广路径；第十章以系统性的视角对全书内容进行总结，并提出未来挑战与研究方向，展望数字化与智能化对农业产业与乡村生态的长远影响。

本书既面向学术研究者，详尽阐述大语言模型在农业领域的技术原理与工程化实现，也面向产业实践者，提供落地思路与运营经验。我们希望通过本书，能够让更多读者了解并把握大语言模型在农业场景中的巨大潜力，引领农业生产方式的创新升级，助力数字乡村建设与乡村振兴战略的深入推进。同时，也期待通过对未来研究方向的探讨，为学术界与产业界搭建持续协同的平台，推动农业大语言模型应用不断深入，最终实现绿色高效、可持续发展的现代农业愿景。

## 2. 绪论

深度学习技术在自然语言处理领域的突破，标志着人工智能从“窄域智能”向“广域智能”迈进的重要阶段。自 BERT、GPT 系列模型问世以来，预训练大语言模型凭借海量语料学习与自监督微调能力，已在文本理解、生成与多轮对话等任务中取得多项突破。这些模型不仅在学术界引发热潮，也迅速渗透到金融、医疗、教育等行业，展示出强大的跨领域适用性和自我演进潜力。与此同时，农业作为人类社会的基础产业，正处于数字化转型的关键节点。传感器网络、卫星遥感与边缘计算等新兴技术在田间得到广泛应用，为农业生产提供了海量多模态数据。但数据体量大、来源分散、格式不一，使得如何高效挖掘信息价值、提升生产决策智能化水平成为亟待解决的核心难题。

将大语言模型引入农业领域，一方面能够借助其优秀的文本表示和生成能力，对农业文献、政策文件、农技手册等非结构化数据进行自动化处理与知识抽取；另一方面，多模态框架下的预训练模型能够将遥感影像、气象数据与田间传感信息融合，生成精准的作物生长报告与灾害预警建议。与传统依赖词频统计和人工规则的语言处理方式不同，大语言模型基于上下文动态词嵌入实现了知识的向量化表达，使机器首次具备从大规模语料中抽取语义结构和隐含关系的能力。这一表示方式的变革，是大模型在农业知识处理与推理中能够产生跃迁式性能提升的根本原因之一。这种技术融合有望突破传统农业对经验和人工判断的依赖，为播种、施肥、灌溉乃至病虫害防治与供应链管理提供全方位的智能化支持。尤其是在乡村振兴与可持续发展战略的大背景下，基于大语言模型的农业智能化方案具备极高的现实意义，将进一步推动农业生产效率、资源利用效率与生态环境保护的协同提升。

在国际层面，欧美国家和以色列等农业科技发达地区率先开展了大语言模型与智慧农业的融合研究与应用试点。例如，微软 FarmBeats 项目通过边缘计算与云端大模型相结合，实现了对土壤水分与作物长势的实时监测与智能决策；谷歌 X 实验室的 Project Mineral 借助高分辨率遥感与知识图谱，为作物病害诊断和生产优化提供决策支持；IBM Watson Decision Platform for Agriculture 进一步整合气象、遥感与商业数据，为农户定制化农业运营方案。在中国，腾讯云、阿里云、华为云等云服务商与高校、科研院所合作，推出了多款农业大模型应用，通过“政—产—学—研—用”协同机制，推动大模型在病虫害诊断、市场分析与农技培训等领域落地。尽管相关研究与实践已取得初步成果，但在技术标准、数据共享与模型本地化适配等方面仍存在诸多挑战，尚需系统性梳理与深入探索。

本书在总结国内外研究现状的基础上，提出了“技术到业务、理论到实践”的研究思路，力求构建一个覆盖数据、模型与应用的完整体系。具体而言，本书从以下几方面展开：首先，梳理大语言模型的发展历程及其关键技术，包括神经网络与深度学习基础、Transformer 架构、预训练与微调策略、多模态融合与人类反馈强化学习等，为后续农业场景应用奠定理论基础；其次，详细阐述农业场景下大模型训练与部署的工程实践，包括数据采集与预处理、分布式训练与算力优化、模型推理与 MLOps 全生命周期管理等，实现从实验室到云端再到田间的闭环流程；再次，

重点探讨大语言模型在农业典型场景中的应用，例如智能种植管理、精准灌溉与施肥、病虫害智能防治、供应链与市场分析，以及作物育种与精准农业中的多模态数据融合与知识辅助；随后，本书引入多智能体协作概念，结合 LangChain、AgentGPT 等框架，构建具备跨领域协同能力的农业智能系统；同时，对农业智能化平台的架构与技术选型进行系统性分析，阐述数据中台、算法中台与业务中台在农业数字化中的协同机制，并探讨知识图谱、区块链与物联网等要素的深度融合；在案例与实证研究章节，结合国内外典型项目，从商业模式、技术实现、效果评估、项目管理与推广路径等方面进行深入剖析，为可复制性与规模化扩展提供实践指导；最后，本书从标准化与行业规范、地域差异适配与国际合作等角度探讨大模型在农业领域的输出潜力，展望技术对农业与社会生态的长期影响。

在研究框架的设计上，本书突出以下三点创新贡献：

- 跨学科的理论体系构建: 将深度学习与农业多维数据特征相结合，提出了大语言模型在农业环境下的多模态融合与行业微调方法，为学术界提供了一个系统化的跨学科研究范式。
- 工程化实践与可复制路径: 聚焦农业场景下的工程挑战，从数据采集、模型训练到 MLOps 全流程管理进行了全面梳理，并结合多个云服务平台和边缘部署案例，提出了可复制的产业化实施流程。
- 多层次推广与生态协同策略: 从商业模式、项目管理、风险管控与组织协同等多维度，构建了“试点—复制—扩展—巩固”的生态化推广框架，并对标准化、本地化和国际化提出了具体对策，为政府部门、企业与科研机构提供了可操作的转型路径。

第一章将按照上述思路展开，涵盖大语言模型发展与农业结合的背景意义、国内外研究与应用现状的比较分析、研究思路与整本书框架结构的阐述，以及本书在理论与实践层面的创新贡献概述，为后续各章节的深入讨论提供清晰的逻辑支撑和研究导向。

## 2.1 大语言模型与现代农业的融合背景

在当今数字化浪潮席卷全球背景下，人工智能技术蓬勃发展，大语言模型（Large Language Model, LLM）作为其中的璀璨明珠，正以其强大的语言理解和生成能力，为各行业带来前所未有的机遇与变革。与此同时，农业作为人类社会的根基，也在历经数字化转型的阵痛与探索，而大语言模型恰似一把钥匙，为破解农业发展难题提供了新的思路与工具。

人工智能的崛起并非偶然，其发展脉络清晰可循。从早期简单的规则基础系统，到机器学习的兴起，再到深度学习的突破，每一次技术跃迁都为人工智能注入了新的活力。大语言模型的出现，更是借助海量数据与强大算力，实现了对语言的深度

洞察与精准表达。以 GPT、BERT、T5 等为代表的模型，不仅在语言任务中表现出色，更展现出向多领域知识融合与应用拓展的巨大潜力。

农业数字化转型的需求愈发迫切。传统农业生产依赖经验与直觉，难以应对复杂多变的自然环境与市场波动。而数字化技术能够实现农业生产过程的精准感知、智能决策与高效管理。大语言模型在此过程中扮演着关键角色，它能够整合海量的农业数据，包括气象、土壤、作物生长等多维度信息，通过自然语言处理技术将复杂的数据转化为易于理解的知识与建议，为农业生产者提供科学依据，助力其实现从靠天吃饭向知天而作的转变。

关键技术变革的浪潮推动着农业迈向智能化新时代。物联网技术让农田、农机设备实现互联互通，传感器实时采集的数据为大语言模型提供了丰富的素材；云计算则为模型训练与运行提供了强大的算力支持，确保其能够快速响应农业生产的多样化需求。这些技术相互交织、协同发力，为大语言模型在农业领域的深度应用搭建了坚实的桥梁。放眼全球，大语言模型的研究与应用呈现出百家争鸣的态势。国外科技巨头如 OpenAI、Google 等在模型研发上持续投入，不断刷新模型性能的边界，并积极探索其在农业等垂直领域的落地场景；国内企业与科研机构也不甘示弱，结合本土农业特点，挖掘大语言模型在本土化农业服务中的应用价值，如农业生产咨询、农产品市场分析等方面已初见成效。然而，农业信息化在全球范围内仍面临诸多痛点，不同国家和地区间数字鸿沟明显，数据标准不统一、共享机制不完善等问题制约着大语言模型在农业领域的进一步推广。

在此复杂背景下，深入研究大语言模型与现代农业的融合路径、应用场景及技术实现，不仅是推动农业数字化转型的关键环节，更是助力全球农业可持续发展、保障人类粮食安全的重要举措。本书将以此为出发点，系统性地剖析大语言模型在农业领域的理论基础、技术实践与应用前景，为学术研究者、农业从业者及科技开发者提供有益的参考与借鉴，共同探索农业智能化发展的新未来。

## 2.2 国内外研究与应用现状

### 2.2.1 国外研究与应用现状

#### （一）大语言模型在不同领域的进展

在海外，大语言模型的发展呈现出多点开花、竞相绽放的繁荣景象。以 OpenAI 的 GPT 系列、Google 的 BERT、T5 等模型为代表的前沿成果，不仅在自然语言处理领域屡创佳绩，更在跨领域应用中展现出强大的通用性与拓展性。GPT 模型通过不断的架构优化与参数规模扩张，在语言生成的连贯性、逻辑性及语义准确性上实现了质的飞跃，能够生成高质量的新闻报道、学术论文、创意写作等文本内容，为内容创作行业带来了新的变革力量。BERT 模型则在语言理解任务上独领风骚，其双向 Transformer 架构使得模型能够深刻把握文本中的语义关联与上下文信息，在机器阅读理解、情感分析、实体识别等众多自然语言处理子领域刷新了多项基准测试的纪录，广泛应用于智能客服、信息检索、舆情分析等商业场景，为企业的数字化运营与客户服务优化提供了有力支撑。T5 模型以其独特的文本到文本框

架，统一了多种自然语言处理任务的处理模式，无论是文本生成、翻译还是问答系统，都能通过该框架实现高效的业务适配与模型训练，在多语言处理与跨文化信息交流方面具有显著优势，为全球范围内的信息互联互通做出了积极贡献。

## （二）农业信息化的国际对比与痛点

从全球视野来看，不同国家在农业信息化进程中呈现出各异的发展态势与特征。在欧美发达国家，农业信息化起步较早，历经多年的发展与沉淀，已经构建起较为完善的农业信息基础设施与数据资源体系。以美国为例，其在农业遥感监测、精准农业技术应用等方面处于世界领先地位，通过卫星遥感、无人机测绘等先进技术手段，实现对农田土壤肥力、作物生长状况、水分需求等信息的实时精准获取，并借助农业信息化平台进行数据分析与决策支持，指导农场主进行精细化的农业生产管理，大幅提升了农业生产效率与资源利用效率。然而，即便在这些农业信息化先进国家，仍然面临着一些共性痛点与挑战。一方面，农业数据的多样性与复杂性给数据整合与共享带来了巨大困难。农业生产涉及气象、土壤、作物、市场等多源异构数据，不同数据来源之间往往存在数据格式不统一、数据标准不一致等问题，导致数据难以实现有效的融合与协同分析，限制了农业大数据价值的充分挖掘与利用。另一方面，农业信息化技术的应用门槛与成本相对较高，使得广大中小规模农户难以享受到农业信息化带来的红利，加剧了农业领域的数字鸿沟与不平等发展现象。

## （三）现有大语言模型在农业领域初步应用案例概览

尽管大语言模型在农业领域的应用尚处于探索阶段，但在一些细分场景中已经展现出令人瞩目的应用潜力与初步成效。在农业知识问答与咨询服务方面，基于大语言模型的智能聊天机器人能够为农民提供实时的农业技术咨询、病虫害防治建议、市场行情查询等服务，以自然语言交互的方式打破了农业知识传播的专业壁垒，让农民能够便捷地获取所需的农业信息，有效提升了农民的生产决策科学性与自我知识更新能力。在农业生产报告生成与分析领域，大语言模型能够自动解读农业传感器采集的数据，结合历史数据与专业知识，生成具有指导意义的生产报告与分析建议，帮助农业生产管理者及时了解生产现状、发现潜在问题并制定针对性的改进措施，实现了农业生产管理从经验驱动向数据驱动的转型升级。

## 2.2.2 国内研究与应用现状

### （一）大语言模型在不同领域的进展

在国内，大语言模型的研究与应用也在如火如荼地推进，呈现出后来居上、奋起直追的发展态势。众多科研机构、高校以及科技企业纷纷投身于大语言模型的研发与创新实践，不断缩小与国际先进水平的差距，并在部分领域形成了具有本土特色与优势的应用成果。例如，一些国内团队在预训练模型的优化改进方面取得了显著进展，通过引入行业特定数据、优化模型架构设计以及采用高效的训练算法，使得模型在中文语言理解与生成任务上表现出色，能够更好地适应中文语言的表达习惯与语义特点，为中文自然语言处理应用奠定了坚实基础。同时，在大语言模型的应用开发方面，国内也涌现出一批创新性的应用案例，如智能写作助手、智能客服

机器人、智能教育辅导系统等，广泛覆盖了办公自动化、客户服务、教育等多个领域，为国内数字化经济发展注入了新的活力。

## （二）农业信息化的发展现状与特点

我国农业信息化在近年来取得了长足的发展，但整体上仍处于发展阶段，具有自身独特的发展路径与特点。一方面，随着国家对农业信息化的高度重视与持续投入，农业信息基础设施建设不断加强，农村互联网普及率显著提升，为农业信息化应用奠定了坚实的网络基础。同时，我国在农业物联网、农业大数据平台建设等方面也取得了一系列成果，一些示范项目与试点地区已经初步实现了农业生产过程的数字化监测与智能化管理。另一方面，我国农业信息化发展呈现出区域发展不平衡的特点，东部沿海地区以及一些农业产业化程度较高的地区，农业信息化水平相对较高，农业企业与新型农业经营主体对信息化技术的应用意识与能力较强；而在一些中西部偏远地区以及传统农业产区，农业信息化建设相对滞后，农民对信息化技术的认知与应用能力有待进一步提高。

## （三）现有大语言模型在农业领域初步应用案例概览

在国内农业领域，大语言模型的应用探索也在逐步展开，尽管尚处于起步阶段，但已经展现出广阔的应用前景。在农业技术推广与培训方面，基于大语言模型的智能培训平台能够以通俗易懂的语言为农民讲解农业新技术、新品种的种植要点与注意事项，通过智能对话交互的方式解答农民在实际生产中遇到的技术难题，有效提升了农业技术推广的效率与覆盖面，促进了农业科技成果的快速转化与应用。在农产品市场分析与预测领域，大语言模型能够对海量的农产品市场新闻报道、政策文件、交易数据等进行挖掘与分析，生成市场分析报告与价格预测信息，为农业生产经营者提供决策参考，帮助其合理安排生产计划、优化产品销售策略，降低市场风险，提高经济效益。

## 2.3 研究思路与内容框架

### 一、核心问题与写作目标

本书聚焦的核心问题在于，如何深度且系统地剖析大语言模型在农业领域的全方位应用潜能，以及如何突破性地构建起从前沿理论到落地实践的完整转化路径。这一过程中，旨在解决当前农业数字化转型中面临的复杂难题，如农业数据的多源异构性整合、农业生产决策的智能化升级、农业产业链条的协同优化等，从而为农业的智能化升级提供坚实的理论支撑与实用的操作指南。

写作目标设定为，打造一部兼具学术深度与实践指导价值的权威著作。一方面，为学术研究者呈现大语言模型与农业交叉领域的前沿理论研究成果，激发更多跨学科的探索与创新思维；另一方面，为农业从业者、科技开发者提供一部实用性强的“行动手册”，帮助他们理解如何将大语言模型技术巧妙融入农业生产的各个环节，切实推动农业产业的数字化、智能化转型进程，提升农业生产的效率、质量和可持续性。

## 二、技术到业务的纵深：从数据、模型到应用场景

### （一）数据层面

深入探究农业数据的特性与处理难点，针对农业数据来源广泛、格式多样、质量参差不齐等问题，研究如何运用大语言模型进行数据的清洗、标注与融合。例如，整合农田传感器采集的实时数据、气象部门的历史数据以及农产品市场的交易数据等，通过大语言模型的语义理解与知识抽取能力，将这些异构数据转化为具有内在逻辑关联的知识图谱，为后续的模式训练与业务应用奠定高质量的数据基础。

### （二）模型层面

系统分析大语言模型的架构原理与性能优化方法，研究如何根据农业领域的特定需求对模型进行定制化训练与微调。考虑到农业生产场景的复杂性与专业性，探讨如何在通用大语言模型的基础上，引入农业领域的海量文本数据与专业知识，采用迁移学习、提示学习等技术，使模型能够精准地理解和生成农业相关的语言内容，如作物种植技术指导、病虫害防治方案制定、农产品市场行情分析等，从而提升模型在农业应用场景中的适配性与准确性。

### （三）应用场景层面

全面覆盖农业生产的产前、产中、产后各个阶段，深入挖掘大语言模型的应用价值。在产前的规划设计阶段，利用模型对农业资源数据的分析，辅助进行精准的种植规划与品种选择；产中生产管理过程中，借助模型实现智能灌溉、施肥、病虫害预警与防治等精细化管理决策；产后则在农产品质量检测、市场销售预测、供应链优化等方面发挥语言智能的优势，通过自然语言交互的方式为农业从业者提供全方位的决策支持与操作建议，推动农业产业链的整体升级与协同发展。

## 三、主要研究方法 with 章节逻辑说明

在研究方法上，综合运用文献研究法、案例分析法、实验验证法与专家咨询法等多种手段。通过文献研究法全面梳理国内外大语言模型与农业领域的相关研究成果，把握研究现状与发展趋势；采用案例分析法深入剖析国内外具有代表性的农业大语言模型应用案例，总结成功经验与失败教训；运用实验验证法对书中提出的技术方案与应用场景进行实际验证，确保方法的可行性和有效性；并借助专家咨询法，邀请农业领域与人工智能领域的专家学者对研究内容进行指导与评审，提升研究的科学性与权威性。

章节逻辑上，本书构建起一个层层递进、紧密关联的知识体系。从绪论部分对研究背景、现状与意义的阐述，引出后续对大语言模型理论基础的深入讲解；在理论基础之上，逐步展开对训练与部署实践、多模态拓展、农业应用典型场景、智能化平台集成等内容的详细论述；最后通过成功案例与实证研究的展示，进一步验证理论与技术的实用性，最终在总结与展望部分对全书内容进行升华，提出未来研究方向与发展趋势，使读者能够系统、全面地理解和掌握大语言模型在农业领域的应用精髓与发展方向。

## 2.4 本书结构与创新贡献

### 2.4.1 各章节要点简要介绍

#### 第 1 章 绪论

阐述大语言模型与现代农业融合的背景，包括人工智能发展、农业数字化转型需求以及关键技术变革对农业的影响；分析国内外大语言模型研究与应用现状，揭示农业信息化的国际对比与痛点；明确本书的核心问题与写作目标，介绍研究思路与内容框架，为全书奠定基础。

#### 第 2 章 大语言模型的理论与技术基础

系统回顾神经网络与深度学习的基本概念，介绍注意力机制与 Transformer 的出现背景；深入探讨预训练模型的结构与原理，分析参数规模对性能的影响及带来的数据与算力挑战；阐述微调、强化学习等技术在大语言模型中的应用，以及模型优化与高效的参数训练方法。

#### 第 3 章 大语言模型的训练与部署实践

详细讲解数据获取与预处理的流程与工具，针对农业领域数据特点提出处理要点；探讨大规模训练架构与硬件需求，介绍性能优化技巧；研究模型推理与部署优化策略，实现多场景高效部署；阐述模型全生命周期管理的重要性及在农业场景的落实案例与挑战。

#### 第 4 章 多模态大模型：概念与应用

分析农业多模态数据需求，探讨多模态信息融合的难度与价值；介绍多模态大模型的结构与训练策略，阐述如何借助不同模态信息增强模型认知；研究多模态模型的工具链与平台支持，分析开源平台的功能与局限；通过实际案例展示多模态大模型在农业中的应用，并展望其与前沿技术的结合可能。

#### 第 5 章 大语言模型在农业应用的典型场景

深入分析农业数据特征与业务需求，探讨大语言模型在文本挖掘、信息检索、知识问答中的作用；研究其在智能种植管理、畜牧水产养殖、农产品供应链与市场分析等典型场景中的应用，提出针对性的解决方案与决策支持系统设计。

#### 第 6 章 大语言模型在作物育种与精准农业中的应用

探讨大语言模型在基因组学与育种文本数据分析中的应用，辅助高通量筛选与品种改良；研究其在田间管理与遥感数据融合解读、智能施肥与灌溉辅助文本交互、病虫害智能防治知识库构建等方面的作用，推动精准农业的发展。

#### 第 7 章 大语言模型中的多智能体协作

介绍多 Agent 概念在大语言模型中的延伸，探讨其在农业场景中协作的必要性；研究 LLM-Agent 框架与工具链，设计农业场景中的多 Agent 协同模式；分析协同与通信机制，探讨强化学习在多 Agent 系统中的拓展思路；通过典型案例展示多 Agent 在农业智能决策中的应用。

## 第 8 章 农业智能化平台与大语言模型集成

探讨农业智能化平台的架构与技术选型，研究如何构建支持大语言模型的平台；研究模型管理与服务化部署策略，实现不同用户角色的访问权限控制；分析数据与业务流的集成方法，强调大数据分析可视化的重要性；研究大语言模型与其他智能组件的协同，推动跨平台生态建设。

## 第 9 章 成功案例与实证研究

分析国内外典型案例，从技术与商业视角探讨其布局与合作模式；深度剖析具有代表性的落地项目，评估其效果与性能指标；研究项目管理与推广路径，提出从小范围试点到大范围推广的策略；探讨可复制性与规模化扩展问题，展望国际合作与技术输出潜力。

## 第 10 章 总结与未来展望

回顾全书核心观点，总结大语言模型在农业的实际贡献与局限；分析主要挑战与未来研究方向，探讨大语言模型向通用人工智能迈进的可能性；展望其对农业与科技生态的长期影响，包括数字鸿沟、产业升级与社会结构变革等问题。

### 2.4.2 对学术界与产业界的价值与意义

#### （一）学术价值

本书为学术界提供了大语言模型与农业交叉领域的系统性研究，填补了相关领域的研究空白。通过深入探讨大语言模型在农业中的应用理论、技术方法与实践案例，为跨学科研究提供了新的思路与范式。同时，书中对多模态融合、多智能体协作等前沿技术在农业中的应用探索，以及对农业智能化平台架构与集成模式的研究，丰富了农业信息科学与人工智能学科的理论体系，为相关领域的学术研究提供了重要的参考依据，有助于推动学术界对农业智能化发展规律的深入认识与理论创新。

#### （二）产业价值

本书紧密结合产业实际需求，为农业产业升级提供了切实可行的技术路径与解决方案。农业从业者可以通过本书了解如何利用大语言模型提升生产管理效率、优化资源配置、提高产品质量与市场竞争力；科技开发者能够从中获取大语言模型在农业领域应用的技术细节与开发要点，加速相关产品的研发与推广；企业与政府决策者也能依据书中内容制定合理的产业发展战略与政策，促进农业数字化转型项目的落地实施，推动农业产业的智能化、数字化、高效化发展，实现农业生产方式的革新与产业价值链的提升，助力全球农业可持续发展目标的实现。

### 2.4.3 本书在理论与实践上的创新点

#### （一）理论创新

本书首次系统地构建了大语言模型在农业领域应用的理论框架，将人工智能中的前沿技术与农业生产的复杂业务流程深度融合，提出了具有指导意义的理论模型与方法体系。例如，在多模态大模型部分，创新性地将图像、文本、语音等多种模态数据与农业领域知识相结合，拓展了传统农业信息处理与分析的理论边界；在多智能体协作理论中，引入大语言模型作为核心智能体，探索了其与农业场景中其他智能体的协同机制与决策模式，为农业智能系统的构建提供了全新的理论视角。

#### （二）实践创新

在实践层面，本书通过丰富的案例分析与实证研究，展示了大语言模型在农业全产业链中的创新应用。从智能种植管理到精准施肥灌溉，从病虫害智能防治到农产品市场分析与供应链优化，书中详细介绍了如何将大语言模型技术转化为实际的农业生产工具与服务产品。同时，本书还提出了农业智能化平台的架构设计与集成方法，实现了大语言模型与其他农业信息技术的无缝对接与协同工作，为农业产业的数字化升级提供了可操作性强的实践指南，推动了农业智能化应用从单一环节向全链条、从理论研究向实际生产的一次重大跨越，具有显著的实践创新价值。

### 3.大语言模型的理论与技术基础

本章旨在深入探讨大语言模型的理论与技术基础，为后续在农业领域的应用实践奠定坚实的学理与工程根基。随着大规模预训练模型在自然语言处理领域不断突破，从最初基于词向量与循环神经网络的简单结构，到基于注意力机制与 Transformer 架构的内在革新，再到今日百亿乃至千亿参数规模的超大模型，整个技术路线已发生根本性变革。回望这一发展历程，神经网络的基本概念与早期深度学习方法（如卷积神经网络 CNN、循环神经网络 RNN 等）奠定了模型对于信息表达与时序依赖的初步能力，而注意力机制与 Transformer 架构的出现，则将并行化训练与长程依赖解决方案带入主流视野，大幅提升了模型对长文本上下文及多模态信息的捕捉能力。本章将详细梳理这一演进脉络，帮助读者在理解深度学习核心原理的同时，把握预训练模型在参数规模扩张过程中性能提升的机理，从数据与算力角度认识大模型训练的挑战，并从算法与架构层面解析如何在有限资源下平衡性能与成本。

在第二节“预训练模型与参数规模演进”中，将系统分析诸如 BERT、GPT、T5 等经典预训练模型的结构特点与核心思想，阐明逐步从百万级参数到数十亿、数千亿参数规模的扩张，对模型表示能力与下游任务效果的深远影响。此外，探讨围绕预训练数据规模与标注成本之间权衡的策略，进一步揭示数据量、计算资源与模型性能的三角关系。第三节“微调与高效参数训练”则聚焦农业场景下模型部署的实际需求，兼顾行业特征与技术手段，详细介绍从传统的 Fine-tuning 到 Prompt Tuning、LoRA 等轻量化技术的应用原理，剖析其在农业专业领域适配时的关键要点，并就模型压缩、剪枝与蒸馏等方法在算力受限环境下的折中方案展开探讨，帮助读者在有限硬件条件下实现满足实际业务需求的模型性能。第四节“强化学习与大语言模型”环节，则引入强化学习技术在更复杂决策问题中的潜在价值，阐述 RLHF 在模型生成质量、响应风格与安全性等方面的优化作用，并结合农业生产过程中的时序决策需求，说明当模型需要在多轮交互、动态环境与多目标优化中发挥作用时，强化学习如何能够为决策链注入持续反馈和策略迭代的能力。

本章的编排不仅聚焦技术原理的深度剖析，更强调与农业行业的需求对接。针对农业场景下多源异构数据（如文本、传感、遥感与历史统计信息）特有的高维、时序与异构性挑战，我们将在理论阐述中有意识地穿插实际案例与方法示例，使得模型架构与算法细节与农业生产管理需求、自主种植决策与灾害预警等场景一一对应。例如，在介绍注意力机制时，会结合农业图像与文字描述融合的示例，说明如何捕捉不同信息模态间的关联性并为病虫害诊断任务服务；在讨论参数量扩张时，将结合农业大数据生态的特点，解释为何单纯加大参数规模并非万能，必须通过数据标注与模型微调策略对模型进行精细化调整，才能在精准施肥、智能灌溉与高效育种等领域取得实际效果；在引入 RL 的章节，会结合农业决策链的多阶段、多策略目标，展现 RL + LLM 如何在智能灌溉与病虫害防控决策系统中实现从“被动响应”到“主动规划”的跃升。

从更宽的视角来看，本章的目的是让读者全面理解大语言模型技术范式在农业中应用的理论基础与技术路径，而非仅停留在概念层面的介绍。我们强调：第一，模型能力的增强并不单纯依赖于参数规模，还需要与农业领域数据源的质量与多样性相结合；第二，微调与高效参数训练需要考虑到农业垂直领域的专业术语、语料稀缺与标注资源限制，并通过低秩分解、知识蒸馏等方法实现模型性能与计算成本的最优平衡；第三，强化学习与人类反馈机制为大语言模型在农业复杂决策场景中注入了“自我修正”与“目标驱动”的能力，使系统能够在不确定环境下持续优化；第四，多模态信息融合与乡村数字基础设施建设互为支撑，将为章节后续对农业智能化项目实施提供更具可操作性的工程思路。本章的学习与掌握，不仅是理解大语言模型在农业领域应用的前提，也是开展后续章节中实证研究、平台建设与多智能体协作设计的理论基础。

本章并非孤立存在，而是与全书其他章节紧密相连：在第二章奠定了技术原理与优化方法后，第三章将直接展开对农业大模型训练与部署实践的论述；第四章将基于本章多模态融合的理论支撑，深入剖析农业场景中的图文、时序与传感器数据集成策略；第五章则借助本章关于微调与强化学习的知识，针对智能种植、病虫害防治与供应链决策等场景提出具体实现方案；第六至第八章将利用本章所述技术基础，在作物育种、平台集成与多 Agent 协作等更高层次的应用领域进行探索；第九章的案例与实证研究也将基于本章的理论框架，分析真实项目中的技术选型与性能表现；第十章对挑战与未来方向的展望，将回归本章所探讨的技术瓶颈与创新路径，对农业与科技生态的长期演进提供思考指南。通过这种“理论—工程—应用—实践—未来”的整体逻辑架构，读者能够在真实项目和技术研究之间建立清晰的逻辑联系，以更加系统的视角理解大语言模型赋能农业的全景图。

本章将指导读者从零开始构建对大语言模型技术的完整认识：既能准确把握架构原理，也能透彻理解算法优化方法，更能结合农业生产实际场景，设计符合行业需求的模型开发与部署策略。通过本章的学习，读者能够在后续章节中更高效地将技术与业务需求结合，为农业生产实现智能化、精准化与可持续发展奠定坚实基础。

### 3.1 神经网络与深度学习回顾

神经网络的理论源自对生物神经系统工作机制的启发，最早可以追溯到上世纪中叶的感知器研究。感知器模型虽然在结构上十分简化，却首次尝试用数学形式模拟神经元的激活过程，为后续更复杂的网络形态奠定了雏形。随着计算机硬件的发展与算法思想的迭代，人们逐渐发现，通过多层的神经元堆叠与非线性变换，可以在一定程度上逼近任何可测函数，为图像识别、语音处理、自然语言理解等多种应用提供了理论基础。在不断探索与实践中，神经网络从简单的单层或多层感知器演进到深度结构，展现出更强的表达能力与建模潜力，为现代人工智能的发展注入了源源不断的动力。

在这种多层感知器（MLP, Multi-Layer Perceptron）框架中，最核心的创新在于误差反向传播算法的提出与实践，它在一定程度上解决了早期网络训练缺乏有效学习手段的问题。通过将模型预测与真实标签之间的误差逐层向后传播，网络中的

每一个权重参数都能获得准确的梯度信息，从而得以进行迭代更新。但随着网络层数的增多，训练过程中也暴露出梯度弥散和梯度爆炸等瓶颈：前者会让深层网络的权重几乎无法被有效更新，后者则可能导致数值不稳定。为应对这些难题，研究者们相继提出更具鲁棒性的激活函数（如 ReLU、Leaky ReLU），并探索更优的参数初始化方法和正则化策略（如 Batch Normalization、Dropout），为深层结构的可行性铺平了道路。此外，硬件性能的飞跃、并行计算框架的成熟，也为更大规模数据与更深网络的训练提供了重要支撑，让深度学习逐渐从实验室研究迈向大规模实际应用的时代。

在多层感知器等全连接结构逐渐成熟并在各类标量或低维度输入任务上取得初步成功后，研究者们开始意识到：对于更高维度、更具结构性的输入（如图像、时间序列、文本序列等），单纯依靠将所有输入特征与隐藏层做全连接的方式，会导致参数规模指数膨胀，也难以有效提炼局部模式或时间依赖性。为了应对这些局限，卷积神经网络（CNN, Convolutional Neural Network）和循环神经网络（RNN, Recurrent Neural Network）等结构应运而生，图 2.1 简要展示了常见神经网络的结构。CNN 在图像处理中引入了局部感受野与权值共享的概念，通过卷积核在二维空间上的滑动操作，实现对局部纹理或边缘信息的抽取，公式上可表示为：

$$(f * x)(i, j) = \sum_{m, n} x(i + m, j + n) f(m, n),$$

其中  $x$  为输入图像， $f$  为卷积核， $(i, j)$  为输出特征图中的像素坐标，局部相乘求和后再叠加偏置和非线性激活，使得模型能逐层提取丰富的空间层级特征。另一方面，RNN 则主要针对序列数据而设计，通过在时间维度上引入循环结构，使得当前输出不仅依赖于当前输入，也受先前时刻隐藏状态的影响。以最简单的 Elman RNN 为例，隐状态的更新可写为：

$$h_t = \sigma(W_h h_{t-1} + W_x x_t + b),$$

其中  $h_t$  为第  $t$  步的隐状态， $x_t$  为当前时刻的输入， $W_h$  与  $W_x$  分别为循环与输入权重矩阵， $\sigma(\cdot)$  为常见的非线性激活函数（如  $\tanh$ ）。通过这种循环方式，RNN 得以在语音识别、语言模型等需要捕捉时序依赖或上下文关系的任务中发挥威力。在此之后，人们又在 RNN 基础上提出 LSTM、GRU 等改进变体，进一步缓解了长序列依赖中的梯度衰减问题，为更深入的序列建模打下了坚实基础。CNN 和 RNN 的出现不仅拓展了深度学习在计算机视觉、自然语言处理等领域的适用范围，也为后续融合局部注意力及全局上下文的信息表征提供了灵感和实践经验。




图 2.1: (a)一般（稠密）神经网络结构； (b) CNN 结构； (c) RNN 结构。

随着深度学习模型在视觉和语言等特定任务上不断取得突破，研究者们也开始思考如何让网络更好地捕捉远距离的依赖关系，提高对复杂场景的理解和生成能力。特别是在序列到序列（Seq2Seq, Sequence-to-Sequence）框架的推动下，以编码器-解码器（Encoder-Decoder）结构为代表的神经机器翻译模型在语义对齐、上下文捕捉上出现了新的需求。早期的 Seq2Seq 模型主要基于双向 RNN 作为编码器，通过合并前向和后向隐藏状态来概括输入序列的含义，再由解码器根据最后时刻的隐藏状态逐步输出目标序列。然而，受限于 RNN 固有的长依赖难题，当输入序列过长时，模型在捕捉远距离信息时会愈发吃力，导致翻译准确度或生成的连贯性下降。为此，一种名为“注意力机制（Attention Mechanism）”的方法逐渐兴起，通过在解码阶段对输入序列各个时刻的隐藏状态分配不同的注意力权重，模型能更灵活地聚焦关键内容。例如，Bahdanau Attention 与 Luong Attention 的提出，都证明了在解码端进行动态权重计算与上下文向量融合，能够显著提升对长序列或复杂语句的表达与生成能力，为后来更加彻底的“自注意力”结构打下了理论与实践基础。

在进一步挖掘注意力机制潜力的过程中，研究者们发现如果能在序列建模中同时利用序列各位置间的相互关联，就能显著提升对上下文的捕捉效率。由此催生出的自注意力（Self-Attention）方法，彻底摆脱了传统 RNN 逐步传递隐藏状态的限制，使得模型可以并行地计算序列中任意两个位置的关联强度。以最常见的“缩放点积注意力”（Scaled Dot-Product Attention）为例，其核心计算公式为：

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}V\right),$$

其中  $Q, K, V$  分别代表查询（Query）、键（Key）和值（Value）矩阵， $\sqrt{d_k}$  是根据键向量维度进行的缩放因子， $\text{softmax}$  用于归一化注意力权重。通过这种方式，模型在处理自然语言或其他序列数据时，无需像 RNN 那般逐步累积远距离信息，而是可以在同一层结构中“直接”关注到全局上下文，从而在翻译、文本生成、阅读理解等任务中大幅提升准确度与推理效率。进一步地，多头注意力（Multi-Head Attention）机制则通过在并行子空间内对不同关注模式进行学习，让模型能够同时捕捉多种语义关联。正是这一突破性的思路，为后续完全基于注意力结构构建的 Transformer 模型奠定了坚实理论支点，也为深度网络的并行化计算带来了更广阔的前景。

在自注意力与 Transformer 思想呼之欲出的同时，深度学习研究也在不断拓展网络结构的深度与广度，这背后离不开训练算法和优化策略的持续演进。早期的随机梯度下降在面临高维非凸损失面时，往往需要极为细致的学习率调整才能使模型获得较好收敛性能。为提高训练效率与稳定性，研究者们先后提出了动量（Momentum）、RMSProp、Adam 等自适应优化方法，通过动态追踪各参数的梯度历史与方差，使网络在复杂参数空间中能够更平滑地搜索到合适的最优区域。与此同时，残差连接（ResNet, Residual Neural Network）和层归一化（Layer Normalization）等结构性改进也被陆续发明，用于缓解深层网络中梯度消失或信息

传递不足的问题。例如，在 ResNet 中，通过直接将前一层的输出与后续卷积层的输出相加，便可让梯度在反向传播时得到更加顺畅的通路，训练超百层的网络也不再是遥不可及的难题。而在 Seq2Seq 与自注意力框架中，借助残差连接和层归一化能显著加快模型收敛，并在大规模分布式集群上实现高效的并行化训练。在这些理论与工程改进的交织下，深层网络从过去只能处理局部问题或短序列数据，逐步迈向对更大规模、更多样化、乃至多模态数据的高效建模，也为后续全面采用注意力结构的 Transformer 模型铺平了最关键的训练和优化道路。

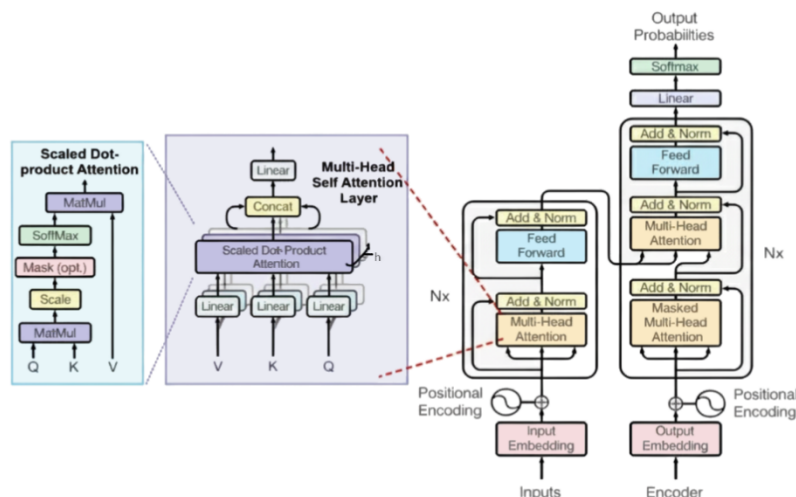


图 2.2: Transformer 架构示意图，从左到右分别是：缩放点积注意力 (Scaled Dot-product Attention)、多头自注意力层 (Multi-Head Self-Attention Layer)、编码器 (Encoder) 和解码器 (Decoder)

与传统的 one-hot、TF - IDF 等基于统计的文本表示方式不同，大语言模型采用的上下文词嵌入机制不仅改变了文本处理的技术路线，更从根本上重塑了知识表示的范式。在以往的离散符号体系中，语言知识以孤立、静态的特征形式存在，模型能捕获的信息往往局限于表层词频，难以形成跨句子、跨文档乃至跨任务的语义联结。而基于神经语言模型的连续向量空间不仅能够表达词语之间的细粒度语义差异，还能够通过上下文动态调整词义，使知识以分布式、可组合和可迁移的形式呈现。这一变化使语言不再仅是被动处理的对象，而成为模型内部可推理、可操作的知识结构，标志着文本处理从“统计相关性”向“语义表征能力”的跨越式跃迁。

Transformer 结构的诞生堪称注意力机制发展的里程碑式事件。在 2017 年发表的“Attention Is All You Need”中，研究者将卷积与循环通通剔除，完全依赖自注意力和多头注意力来建模序列间的依赖关系，大幅简化了计算流程并极大提升了并行化效率。与传统序列模型不同，Transformer 中的编码器和解码器都由多层堆叠而成，层与层之间通过残差连接和层归一化来稳定训练，而最核心的自注意力计算允许每个位置在同一层结构中“直接”与序列中任意位置进行交互。此外，Transformer 还引入了位置编码 (Positional Encoding) 来弥补纯注意力机制无法显式体现序列先后顺序的缺陷，用可学习或固定形式的正余弦函数向量来表示词语在句子中的位

置，使模型在捕捉全局关系的同时，仍能掌握适度的序列顺序信息。由于并行度显著提高，Transformer 比 RNN 等传统模型更容易在大规模数据上进行训练，同时也更能挖掘多头注意力所带来的多视角语义学习潜力。事实证明，在机器翻译、文本摘要、情感分析、对话系统等领域，这种彻底摒弃循环结构的设计不仅在速度上有了质的飞跃，效果也往往显著优于 CNN 或 RNN 为主的架构。随着词嵌入从静态向动态语义表示演进，模型对长距离依赖、上下文关联的需求显著增强，而传统 RNN/CNN 在捕捉跨句跨度的语义结构时仍存在结构性限制。Transformer 架构以自注意力机制为核心，使语义向量空间可以在任意位置之间建立全局关联，实现真正意义上的语义整合与知识推断，从而成为大语言模型得以充分发挥语义表示能力的关键基础。

在实践层面，要让这样大规模、深层次的网络结构发挥作用，研究者不仅需要面对诸如梯度爆炸、梯度消失的老问题，也要考虑计算开销、内存资源和分布式训练等新的挑战。尤其是当网络层数达到数十甚至上百层，且每层都包含数以亿计的可训练参数时，传统单机单卡的训练方式已经难以负荷。于是，大规模并行化训练策略、弹性调度机制、以及对硬件特性的充分利用就变得至关重要。例如，通过数据并行（Data Parallelism）可以将训练集切分后分发给多张 GPU 或多台服务器，让每一部分数据都同时参与前向与反向计算，再在更新参数时进行梯度同步；而模型并行（Model Parallelism）则适用于那些参数量过于庞大的网络，将不同层或不同切片的模型划分至不同设备，以减轻单卡显存压力。与此同时，诸如混合精度训练（Mixed Precision Training）技术，通过将某些参数或中间计算过程切换到半精度，既能减少显存占用量，也能在硬件加速器上获得额外性能提升。

在优化策略方面，为了避免出现数值溢出或更新失控，梯度裁剪（Gradient Clipping）常被用于约束权重更新的幅度，让训练在面对异常梯度时仍能保持稳定。学习率调度（Learning Rate Scheduling）也是提升深度模型性能的关键，通过在早期较快地收敛、后期逐渐细调步幅，可以更高效地探寻损失面的全局最优区域。此外，各种正则化手段（如权重衰减、Dropout 等）能够抑制过拟合，使模型具备更好的一般化能力。当这些训练与优化技巧与 Transformer 等新颖网络结构相结合后，就为后续的海量文本预训练、大规模迁移学习以及各类下游任务的全面开花提供了最核心的技术基底。也正是得益于此，深度神经网络才从早期相对局限的应用，跨越至如今在自然语言处理、计算机视觉、语音交互等多领域多场景均展现出极强的学习与推理潜力。

在深度学习的持续迭代过程中，另一个不容忽视的推动力量来自于大数据与新型计算框架的协同进化。从 ImageNet 等大规模数据集的横空出世，到分布式存储及云计算技术的成熟，数据与算力的双向驱动让研究者可以在更宽泛多元的领域尝试深度神经网络的潜力。与此同时，PyTorch、TensorFlow 等深度学习框架的崛起，为模型开发者提供了更高层次的抽象和灵活性，极大降低了原型设计与实验验证的门槛。在这个过程中，业界也逐步形成了从数据采集、清洗，到分布式训练、模型评估，再到部署上线的完整工作流，并催生了大量面向深度学习任务的基础设施与自动化工具。值得注意的是，当深度学习开始与搜索、推荐、广告、自然语言交互

等高价值商业场景结合后，巨大的资金与资源投入进一步加速了模型结构和训练方式的革新。到 2018 年，深度学习的三位主要奠基人获得图灵奖，也象征着这一波以神经网络为核心的人工智能研究正式站上学术与产业的最前沿。从通用视觉识别到自然语言处理，再到多模态融合，深度学习的理论与实践在近十年里呈现出前所未有的爆发式增长，为后续大语言模型及其在农业等垂直领域的落地创造了必不可少的数据、算法与系统基础，也为本书接下来的讨论奠定了最坚实的学理支柱。

## 3.2 预训练模型与参数规模演进

预训练模型之所以在自然语言处理领域迅速崛起，离不开其在无监督或弱监督阶段充分吸收大量文本信息的能力。与传统需要从零开始训练并依赖海量标注数据的方式不同，预训练模型通过在大规模语料上学习通用的语义表示或语言规律，再利用相对少量的标注数据进行微调（Fine-tuning），便能在多样化的下游任务上获得良好表现。其中，BERT（Bidirectional Encoder Representations from Transformers）、GPT（Generative Pre-trained Transformer）与 T5（Text-to-Text Transfer Transformer）可谓预训练浪潮中的三大里程碑式模型。BERT 率先采用双向 Transformer 编码器，让模型可同时关注上下文信息，并通过掩码语言模型（Masked Language Model, MLM）进行大规模训练，为句子理解和特征抽取提供了高质量的语义表示；GPT 则注重自回归生成特性，利用单向 Transformer 解码器在文本续写、对话等生成类任务上展现出强大能力；而 T5 进一步统一了多种自然语言处理任务的输入输出形式，将所有任务都转化为“文本到文本”的模式，以一体化设计理念简化了模型处理多任务的流程。这些模型在语言理解、生成和转换等方面都取得显著突破，为后续不断扩张参数规模、探索更通用的大语言模型指明了方向。

除了在模型结构上各具特色，它们在预训练目标上也展现出了不同的设计思路[34]。以 BERT 为例，它最核心的创新之一是引入掩码语言模型，在预训练时随机将部分词替换为特殊标记“[MASK]”，令模型在上下文的双向关联下预测被遮蔽的单词。若记  $M$  为被掩码词的索引集合，则目标函数可形式化为：

$$\mathcal{L}_{\text{MLM}} = - \sum_{i \in M} \log P(x_i | x_{M \setminus i}; \theta),$$

其中  $x_i$  为词汇表中对应的真实单词， $x_{M \setminus i}$  之外其他所有已掩码的词做恢复的结果。在这种预训练任务下，BERT 能在大规模语料中同时学习到上下文信息，对后续句子分类、命名实体识别、文本相似度计算等多种下游任务提供通用且强大的特征。而 GPT 系列模型则采取自回归语言建模（Auto-Regressive Language Model），通过让模型在已知部分文本的基础上预测下一个词，得以在生成类任务中展现出更流畅的语境衔接与续写能力。相比之下，T5 采用了“填空式”（Span Corruption）预训练目标，并将各种文本处理任务都统一为“文本到文本”的转换模式，既保留了 MLM 的上下文捕捉优势，又为多任务场景提供了更为灵活的适配方式。这些差异使得 BERT、GPT 与 T5 在不同细分应用中各有所长。

随着预训练理念在学术与工业界不断升温，人们逐渐发现在某些复杂的语言理解或生成任务中，模型规模的扩大往往能带来显著的性能提升。诸如 GPT-2（15

亿参数)与 GPT-3 (1750 亿参数)的横空出世就充分印证了这一点:通过将模型参数从数亿扩张到百亿乃至千亿级别,神经网络能够在超大规模文本语料的熏陶下,捕捉到更加丰富的语义模式和潜在规律,从而在问答、翻译、文本生成、代码编写等多项任务中取得远超前代模型的表现。具体来看,随着参数量和训练数据量的同步增加,模型在零样本 (Zero-Shot) 和少样本 (Few-Shot) 场景下也能够展现非凡的推理与泛化能力,这种“规模跃迁”常常成为大语言模型在各种任务中一骑绝尘的关键所在。例如,对 GPT-3 进行少量示例的提示 (Prompting) 即可完成特定领域的小规模分类任务,无需传统的微调过程。由此可见,大模型尺寸的扩增不单是一种简单的量变,更是让模型在语言理解和知识整合层面达到质变的有效手段。

然而,模型规模的不断攀升也给数据与算力带来了前所未有的挑战。首先,要让百亿乃至千亿级参数模型充分“喂饱”,单纯依赖一般规模的文本语料远远不够,需要在全球范围内收集海量、多元的文本(包括网页快照、电子书、学术论文、社交媒体内容等),并对其进行系统化的清洗、去重和标注。此外,尽管预训练主要使用无监督或弱监督方式,依然需要借助上万甚至数十万 GPU/TPU 集群的协同才能在合理的时间内完成一次大规模迭代。根据业界公开数据,训练一个上百亿参数模型可能需要数百万美元级别的硬件与电费投入,这对企业或研究机构的资金实力和技术积累提出了极高要求。而在具体训练过程中,分布式数据并行、模型并行、流水线并行的组合使用也愈发复杂,一旦通信或负载不均衡,就会显著拖慢整体效率。更棘手的是,模型越大,就越容易出现数值不稳定、优化难度飙升等问题,需要更加精细的学习率策略、混合精度管理以及记忆体优化方法才能保证训练顺利完成。面对这些困难,许多大型科技公司和研究实验室通过自建超算中心或租用云端 HPC 集群来满足算力需求,并且在软件层面不断探索自动化调度、分布式编译优化等技术,以期在庞大的模型规模和实际可行的训练时间之间寻找最佳平衡。

在百亿乃至千亿规模预训练模型的实践中,研究者们还观察到一种颇具“神秘感”的现象——涌现能力 (Emergent Abilities) [37]。当模型参数跨越某个临界点后,它往往会在一些先前未特别显性的任务上表现出新的、甚至可称之为“意外”的推断与生成能力。比如,在 GPT-3 之前的中小型语言模型中,零样本或少样本学习只算是一种辅助特性,很难真正匹敌专门微调的模型;但 GPT-3 却能在几条示例提示的基础上,完成类似翻译、问答、推理等多样化任务。这种“量变引发质变”的过程常被形容为语言模型在大规模预训练中自发形成了某些通用的知识子空间或推理框架,其内部表征不仅凝聚了多语种、多领域的信息,也能够对全新情境进行更深层次的联想和生成。有些研究甚至暗示,在参数规模再度扩大、训练更长时间、数据更丰富的条件下,模型或许会展现出更具通用性的“元学习”特征,并在跨领域迁移中实现前所未有的灵活度。涌现能力是不完全可预期、又潜力巨大的,为预训练大模型的应用打开了一道重要的大门,同时激发了对数据质量、训练范式以及模型内在机制的持续探究。

在这一背景下,虽然大模型的训练和部署成本挑战不容小觑,但它所带来的成果和潜力无疑使得这一投资在各大科技公司和研究机构中成为了竞相追逐的焦点。随着数据收集、硬件加速技术的进步,以及新的算法改进和优化方法的不断涌现,

越来越多的企业已经踏上了大规模大语言模型的探索和实践之路，成为推动技术发展的先行者。例如，OpenAI 通过强化学习（Reinforcement Learning, RL）结合大规模语言生成模型，进一步增强了模型在特定任务上的表现[39]；而谷歌则结合其强大的计算平台和数据资源，推进了相关预训练任务的更大规模化。这些突破意味着未来的大语言模型将不再仅仅是传统文本处理任务的工具，它们将深入到更加广泛的应用场景中，包括但不限于自动化写作、虚拟助手、跨语言即时翻译、创意内容生成等，这些都将大大提高工作效率、带来创新可能性，并释放更多的生产力。然而这些进展的最终实现离不开更高效的算法架构、更多的硬件投入以及对模型优化方法的更深层次理解。整体而言，模型规模的急剧增大不仅为当前的人工智能应用发展提供了强大的助力，也揭示了未来技术发展的一个趋势，即模型向更大规模、更高效的方向演进。这些可以预见的挑战与突破，使得预训练模型成为现代自然语言处理领域的游戏规则改变者，也加速了我们朝着具备更复杂认知和推理能力的通用人工智能（AGI）迈进。

在参数规模不断扩张的同时，业界与学术界也开始尝试更多样化的训练范式，以期在算力投入与模型效果之间寻求新的平衡。例如，Mixture-of-Experts (MoE) 模型通过将网络划分为多个子专家，并在前向推理时根据输入特征只激活一部分专家，从而实现在相似计算量下容纳更多参数、学习更丰富的知识表示。通过在海量训练数据上让不同专家分别应对不同的特征分布，MoE 类模型有望在保持较低运营成本的前提下仍然具备强大的表达能力。此外，知识蒸馏（Knowledge Distillation）等技术也日益受到重视，研究者们利用大模型中学到的潜在表示，将其“迁移”或“压缩”至较小的学生模型（Student Model），以适配算力或内存受限的应用场景。通过这种分层次的知识传递机制，一方面可以最大限度释放大模型预训练所带来的泛化优势，另一方面也能够让具体下游部署不必承担完整大模型的算力与存储压力。

除了上文提及的 MoE、知识蒸馏等尝试，学界也在系统性地研究如何在模型规模与数据规模之间找到最佳匹配关系，形成所谓的“缩放定律（Scaling Laws）”。这类研究通常基于大规模实验与模型性能评估，探索损失函数 $\mathcal{L}$ 在参数规模 $N$ 和训练数据量 $D$ 上的依赖关系，可简单表述为：

$$\mathcal{L} \approx \alpha N^{-\beta} + \gamma D^{-\delta},$$

其中 $\alpha, \beta, \gamma, \delta$ 为经验上得到的拟合系数，反映在给定的数据规模下，继续扩大模型参数能否显著降低损失，或在给定的模型参数规模下，增加数据是否依旧带来收益。通过对不同组合点的观测，研究者往往能找到在算力、数据与模型效果三者之间的平衡策略：如果数据不足，盲目增加参数规模会导致模型在训练中陷入过拟合或出现“数据稀释”现象；而如果数据充裕但模型容量不足，便难以充分挖掘语料中的潜在模式。这些缩放定律的研究不仅为工业界制订预训练方案、配置硬件资源提供了实操指南，也在理论层面提示了模型越大并不一定就越好，关键在于如何匹配恰当数量级的数据与算力投入。随着此类研究的深入，预训练模型正逐渐向“高度规模化 + 精准数据筛选”并行演进——既借助超大数据支撑通用语言理解，又通过精选的高质量样本来突破特定任务或领域的瓶颈。这个趋势预示着，未来的大语言模型

生态将更注重科学化的资源调配和精细化的训练过程，为各行业提供更成熟、稳健、可控的“基础能力层”。

与此同时，“大语言模型”也逐渐演变为“基础模型（Foundation Model）”的概念，即在一次或若干次大规模预训练后，模型即具备广泛迁移到各类下游任务的潜力。相比于以往需要分别训练不同模型来解决翻译、摘要、问答、情感分析、信息抽取等问题，“基础模型”能以统一的架构、参数与预训练语义空间为底座，通过少量定制化微调或智能提示（Prompt Engineering），快速适配各式各样的任务需求。这种范式在实际部署中展现出极大的灵活性：企业或研究机构可以先构建或购买一款具备通用语言理解与生成能力的基础模型，再结合自身业务场景与高价值数据进行增量训练或差异化更新，而不必从零开始耗费庞大的算力与数据成本。更重要的是，大语言模型所学到的通用表征往往跨越多语言、多域文本，甚至能一定程度上处理图像、音频等模态信息，从而在多模态融合、智能对话等前沿应用上“降维打击”传统纯文本模型。随着 GPT、BERT、T5 等路线在国际学术与工业领域的持续演化，人们普遍认为大规模预训练所带来的知识密集与语义泛化，已经成为人工智能迈向更高层次认知与推理能力的核心驱动力之一，也正式拉开了“语言智能”在各行业应用的新时代序幕。

在模型规模和多样化场景需求共同推进的背景下，如何为预训练模型注入更专业、权威、深入的领域知识，也成为一条重要探索路径。由于通用大模型在构建时往往侧重覆盖普适的语言和常见知识范畴，对于农业、医学等高度专业化领域往往缺乏精准理解，这就需要将领域文献、权威数据库、专利文档等高价值数据纳入预训练或后续的知识蒸馏过程中。部分研究者尝试在 Transformer 结构中加入知识图谱的融合模块，使模型在处理文本时能动态调用结构化信息；也有人通过专家标注和自适应提示相结合，将专业术语、行业规范等信息显式纳入语言模型的上下文，引导其生成更具行业适配度的输出。此类针对特定领域的的数据策划与知识注入，不仅能显著提升大语言模型在专业任务上的准确率和可解释性，还可进一步增强模型对跨学科场景的迁移能力。例如，在面向农业生产的实际应用中，若能有效地将作物生长周期、病虫害图谱、土壤成分分析等信息以合理的方式融入预训练过程，模型在提供耕作建议、病虫害诊断、产量预测等方面便能更加精准。也正因为如此，大语言模型兼顾通用性与行业深耕，逐步形成“通用预训练 + 专业知识微调”的混合范式，为各领域提供兼具深度与广度的语言智能支撑。

在这一系列成功背后，如何应对大模型愈发凸显的局限与隐患，也成为业界和学术界关注的焦点。首先，大规模训练往往依赖互联网上爬取的海量文本，而这些文本中可能包含噪音、偏见甚至不恰当内容，导致模型内部固化了不良倾向或失真信息。其次，在实践中，不同语言、不同领域之间存在数据分布差异，大模型若在主流语种和主流领域上表现优异，却未必对小语种或专业农业术语有足够兼容能力，这可能进一步加剧数字鸿沟或专业鸿沟的现象。大模型的可解释性问题也日益突出，随着参数规模增长，模型的决策机制愈发难以直接解析，研究者需要借助探测方法、可视化工具或更有针对性的解释框架来理解其内部表征。应用层面还会涉及到数据隐私、伦理合规与监管等社会议题：在农业领域，若模型生成的信息对作物种植、

病虫害防治等决策产生误导，可能会造成严重经济损失和社会影响。因此，虽然大语言模型在性能层面取得了革命性突破，也必须在技术与制度层面同步构建相应的安全机制、质量评估体系与伦理准则，才能更好地让预训练模型的潜能稳步释放，真正走向行业实际生产与社会实践。

### 3.3 微调与高效参数训练

在大规模预训练模型迅速普及的背景下，如何在下游任务中高效利用这些“通用”模型的语言与知识表征，便成为一条关键的研究与实践路径。其中，“微调（Fine-tuning）”是最直观、也是最传统的解决方案。它通过在预训练好的模型上接入一个新任务的输出层（如分类器、序列标注层等），然后利用少量的有标注数据继续训练全部或部分模型参数，从而让预训练模型的语义能力与新的任务需求相结合。对许多任务而言，这种方式大幅优于从头训练神经网络：一方面，模型在预训练阶段已经吸收了海量语料中的语言规律与通用概念；另一方面，针对性的数据微调能够将通用知识聚焦到任务所需的精细粒度上，既节省了标注开销，也显著提高了收敛效率与最终效果。在实践中，微调往往会考虑哪些层需要冻结（Freeze）或解冻（Unfreeze），以及如何设置分段式学习率（Layer-wise Learning Rate），在保证预训练模型主体语义能力的同时，尽可能地增强对新数据的适应度。对农业等特定领域而言，微调还能借助行业专用词汇表或专业文本，通过少量高价值样本为模型注入更加准确的领域表征，从而实现如病虫害识别、农情诊断等精准而可靠的功能，这也让微调成为衔接通用大模型与垂直领域应用的主流解决方案之一。

在微调过程中，除了完整更新全部网络参数外，近年也出现了许多更轻量级的做法，让用户在资源受限或对响应速度要求更高的场景下依然能够“借力”大模型。其中，“提示学习（Prompt Tuning）”即是一个颇受关注的分支思路。它基于这样一种假设：大模型已经在预训练阶段积累了对语言模式和常识知识的深层表征，只要用一段恰当的“提示文本”来引导模型，就能让其朝着期望的任务方向输出结果，而无需大规模调整内部权重。具体而言，研究者会设计人工或可学习的“提示模板”（Prompt Template），将目标任务的输入信息封装进这种模板中，然后交给模型进行推理或生成。以文本分类为例，传统做法需要在模型顶部添加一个分类层并进行微调；而 Prompt Tuning 则可能采用类似“句子：... 这句话的情感是：\_\_\_\_\_”的自然语言模板，令模型填空或续写正确的情感标签。由于 Prompt Tuning 只是在输入序列中插入少量“提示标记”，模型本身的参数并不会大规模更新，因此它对算力和存储的要求远低于传统微调。更进一步，还有基于可学习向量（Prefix Tuning 或 P-Tuning）来替代人工文本提示的思路，通过在模型的隐层特征空间插入一段可更新的参数向量，使其在推断时发挥“提示”作用，从而让提示本身可被梯度训练[49]。此类方法大幅减轻了对下游数据量和显存资源的依赖，对于需要频繁迭代多任务或快速上线场景尤其友好，也为模型在农业等垂直领域的小数据条件下提供了更灵活的应用途径。

除了提示学习外，“LoRA（Low-Rank Adaptation）”也被视为一种在保留大模型主体的基础上进行参数高效更新的解决方案。LoRA 的核心思路在于将预训练模

型的某些高维权重矩阵近似拆分成若干低秩矩阵进行微调，用数学形式可简单表示为：若原始网络中的某个权重矩阵记为 $W$ ，则在 LoRA 中可写为

$$W + \Delta W = W + A \times B$$

其中 $A$ 与 $B$ 为远低于 $W$ 尺寸的可训练矩阵（即低秩近似项），从而显著减少微调时需要更新和存储的参数量。这样的好处是，一方面能让大模型大部分的原始权重保持不变，以充分利用其在预训练阶段学到的丰富知识；另一方面，通过在目标任务中只学习低秩偏移，微调过程所需的计算量与显存开销都大幅降低，并且在部署时也可动态切换到不同的低秩适配矩阵，达到“一次预训练、多次灵活适配”的效果。在农业领域，由于很多应用场景（如对话问答、产量预测、病虫害诊断等）有着各自的专业知识体系，LoRA 允许为不同场景分别学习少量额外参数，不必反复对整个大模型进行完整更新，从而在保证推理效率的同时增强了模型的领域适配性与可维护性。

当考虑到算力或存储资源尤其有限，或者在终端设备（如农田传感器节点、无人机等）上需要执行一定的智能推断时，模型压缩与剪枝策略便成为不可或缺的技术环节。与 LoRA 这样的低秩适配机制相辅相成，模型压缩（Model Compression）通过减少网络内部的参数冗余，有望让原本庞大的预训练模型在占用更小内存的前提下依旧维持大部分性能。典型做法包括重量化将浮点数参数转换为更低位宽的整数表示、结构化剪枝（Structured Pruning）针对某些卷积核或注意力头直接裁剪，以及非结构化剪枝（Unstructured Pruning）在权重矩阵中剔除一部分较小的参数。如图 2.2 所示，知识蒸馏（Knowledge Distillation）则通过引入一个“教师—学生”范式来传递模型能力：先由体量更大的教师模型在训练或推理阶段输出软标签（Soft Label）或隐藏层特征，再让学生模型通过最小化其与教师输出之间的差异来学习更浓缩、更高效的表征方式。由于学生模型的尺寸可以显著小于教师模型，因此在推理延迟、能耗和设备适配方面都具备优势。对农业应用而言，这些技术意味着在远离数据中心、网络带宽并不稳定的农田场景中，也能部署轻量级但功能较丰富的智能组件，为病虫害识别、土壤监测、农机调度等任务带来高效率的本地推理能力，实现更“接地气”的智慧农业方案。




图 2.3: 模型剪枝与知识蒸馏的区别。

对于像农业这样领域知识相对分散、专业术语复杂多样的行业而言，迁移学习在落实过程中也呈现出鲜明的“本地化”特征。虽然预训练模型在通用语义与跨领域概念上具备相当的洞察力，但农业场景往往需要精通病虫害命名、生长周期、土壤成分分析、种质资源信息等专业内容，这就要求在微调或提示学习时着重强化对本领域关键知识的“感知”。例如，可以先对通用模型进行一次行业数据的域适应预训练（Domain-Adaptive Pretraining），让模型在大量农业报告、政府公报、学术论文、作物百科等文本中习得更精准的语义分布，接着再根据具体任务（如病害识别、耕地规划、产量预测等）针对性地选择微调方式：若算力和标注数据相对充裕，可采用全参数微调来获得最佳效果；若场景受制于硬件或研发周期，可尝试 Prompt Tuning、LoRA 等高效方式进行小规模调整。如此分层式的迁移学习设计，不但能充分利用大模型已有的广谱语言能力，也能在农业专家知识与实际生产需求之间寻找最佳融合点，让智能决策与自动化管理在田间地头真正落地。

在诸多微调方案与参数高效训练策略的探索之外，多任务学习（Multi-Task Learning）与跨任务自适应（Cross-Task Adaptation）也逐渐成为热门方向。相对于针对单一任务定制微调的传统做法，多任务学习期望通过同一模型同时处理多种下游任务，让网络在共享底层表示的基础上充分“迁移”不同任务间的知识和特征。尤其对于农业这样覆盖面广、维度分散的行业，多任务学习能把病虫害识别、田间监测、产量预测、供应链管理等相关任务组合在一起，一方面扩充训练数据的多样性，另一方面让模型在综合上下文中更好地理解农业过程中的关键依赖关系。再配合高效的参数更新方式（如 Prompt Tuning、LoRA 等），就能够在不显著增加算力成本的情况下完成多模、多场景的领域适配，为更复杂的农事决策与综合分析提供通用可迁移的模型底座。

另一方面，当下游任务的数据规模或质量存在不平衡时，如何在微调阶段管理不同数据源或不同类别任务的训练优先级，便成为影响模型性能与稳定性的关键要素。实践中常见的做法包括利用自适应学习率策略在多任务数据之间分配不同迭代周期，或通过动态权重分配机制来平衡各任务的损失函数贡献，避免某些高频任务“淹没”了低频但却重要的细分任务。在农业领域，一些关键场景（例如大型农企的生产规划和小农户的精准耕作）往往面临截然不同的数据规模与需求，这时若能在微调时动态控制训练重心，就可在保证主要任务效果的同时，为相对小规模任务保留足够的学习空间。值得注意的是，为了防止模型过度偏向某一类任务或领域，还应辅以适度的正则化及监控手段，在训练日志中实时追踪各项指标的平衡性，确保大模型在多个子任务间保持大体均衡的发展态势。

在实际生产环境中，不少应用需要一边在线收集数据、一边持续迭代微调模型，这就催生了“在线微调（Online Fine-tuning）”[54]或“增量更新（Incremental Update）”等方案。其核心思想是将新到达的标注数据或来自反馈环节的误差信息，及时纳入模型权重的微调过程，令模型具备更及时的自适应能力，从而迅速应对农事条件的季节性变化、天气异常、市场行情波动等。与传统的大批量离线微调相比，这种小步更新模式对模型结构的扩展性和梯度管理提出了更高要求，需要足够灵活的参数冻结策略和数据缓存机制，才能在保持模型稳定性的同时不断吸收新知识。

对于那些覆盖面广、变化快的农业应用（如跨地域大规模耕种管理），在线微调能显著提升模型的实用性和容错率，使其在面对实时突发状况时依然能提供贴近实际需求的预测或决策支持。通过结合上述多任务管理和在线更新能力，微调与高效参数训练正不断拓展大语言模型在农业场景下的落地深度，让数据驱动的智慧农业体系更具韧性与敏捷性。

### 3.4 强化学习与大语言模型

在人工智能众多分支中，强化学习 RL 因其能够处理动态环境下的连续决策过程，而被视为通往更高智能形态的重要途径。早期的机器学习主要聚焦在“静态映射”或“模式识别”，如图像分类、语音识别、情感分析等，模型仅需对给定输入输出对进行匹配。然而，在真实世界的农业、工业、交通等领域，许多决策过程都同时涉及多步骤与多阶段，不仅要在局部做出正确判断，还要在长期回报上进行权衡与最优化。RL 的出现，为人工智能提供了一种以“策略（Policy）”为中心的思路：智能体在每一步根据当前状态（State）选择动作（Action），并从环境获得即时或延迟的回报（Reward），如图 2.3 所示，通过不断迭代与试错累积经验，最终学习到能最大化收益的行为策略。这一机制在游戏 AI 领域大放异彩，成功地展现了在复杂搜索空间内学习超越人类水平策略的潜力。随后，研究者将其理念迁移到更广泛的场景，例如机器人控制、物流配送优化、个性化推荐等，无论是连续控制还是离散决策，无论是短期回报还是长期收益，都能在 RL 框架下得到综合考量。对于农业来说，田间管理、病虫害治理、资源调度和产量预估等环节往往具备强烈的时序特征，加之环境扰动不可预知，因而仅凭一次性静态预测难以应对。正是在这类需要反复观测、试错和修正策略的复杂情境下，RL 的持续试验与学习能力，能够帮助智能系统动态适应不可控因素，从而在更真实的农事生产循环中实现优化与升级。

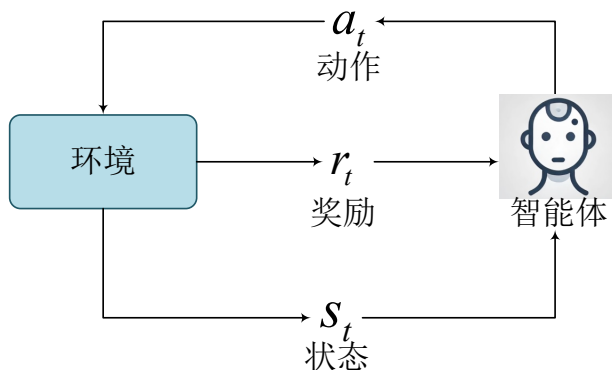


图 2.4: 强化学习框架结构。

在更为严谨的数学框架下，强化学习常被抽象为马尔可夫决策过程（Markov Decision Process, MDP），记作  $(\mathcal{S}, \mathcal{A}, P, r, \gamma)$ 。其中， $\mathcal{S}$  表示状态空间（state space）， $\mathcal{A}$  为动作空间（action space）， $P(s_{t+1}|s_t, a_t)$  指示了环境从状态  $s_t$  经由动

作 $a_t$ 转移到下一状态 $s_{t+1}$ 的概率分布函数，而 $r(s_t, a_t)$ 则给出了即时回报（reward）的函数形式。智能体在每一时刻 $t$ 观察到环境状态 $s_t$ ，基于策略（policy） $\pi_\theta$ 选择动作 $a \in \mathcal{A}$ ，随后环境会发生状态转移并返还即时回报 $r_t$ 。在农业场景中，这种回报可能与作物产量、资源投入成本或病虫害防控成效直接挂钩，也可能是综合多个因素而得到的加权得分。强化学习的核心目标，便是在持续交互与试错中，调节策略参数 $\theta$ 使得智能体获得尽可能高的累计回报（cumulative return），其常见形式可写为带折扣因子 $\gamma$ 的期望总回报：

$$J(\theta) = \mathbb{E}_{\tau \sim p_\theta(\tau)} \left[ \sum_{t=0}^T \gamma^t r(s_t, a_t) \right],$$

其中 $\tau = (s_0, a_0, s_1, a_1, \dots, s_T)$ 表示从初始到终止的整条交互轨迹， $\gamma \in (0,1]$ 则用于平衡对短期收益和长期收益的侧重程度。

在策略梯度（Policy Gradient）的方法论中，为了最大化 $J(\theta)$ ，智能体需通过对参数 $\theta$ 执行梯度上升或下降操作来更新策略 $\pi_\theta(a_t|s_t)$ 。一种典型的近似形式为REINFORCE思路或基线修正（Baseline Correction）后的策略梯度公式：

$$\nabla_\theta J(\theta) = \mathbb{E}_{\tau \sim p_\theta(\tau)} \left[ \sum_{t=0}^T \nabla_\theta \log \pi_\theta(a_t|s_t) (R(\tau) - b(s_t)) \right],$$

其中 $R(\tau) = \sum_{t=0}^T \gamma^t r(s_t, a_t)$ 表示整条轨迹的折扣回报总和， $b(s_t)$ 则是一个可选的基线函数（Baseline），通过其来削减方差并加速策略收敛。在实践中，如果农业系统具备较高维度的状态与动作空间，如田地分布、耕作机具调度、实时气候监测、多级供应链协同等，则需要通过更细致的函数逼近与更强大的计算平台来进行采样与更新。采用上述公式所刻画的“采样—更新”循环，智能体便能在动态环境中不断尝试不同耕作决策或资源配置方案，并依据产生的综合回报评估其优劣，最终逐步收敛于收益更高的策略。与传统的静态监督训练相比，这种模式在时序累积和不确定环境下更具优势，可直接适配于多阶段决策的农业流程。尤其在面对诸如多轮施肥、病虫害防治、灌溉时机选择等问题时，不再需要人工给出明确的“正确答案”，而是让智能体自己摸索、试错，结合真实或模拟环境的即时反馈来调整策略，从而潜移默化地学到如何平衡短期产出与长远土壤健康、如何在有限资源下实现经济与生态效益共赢。

在此基础上，若将强化学习与大语言模型结合起来，则为农业中的复杂决策和实时交互提供了更深层次智能升级契机。传统的自然语言处理 workflow 大多只关注“数据—模型—预测”这一条线性的管道，而在强化学习思想的引入下，系统可以在语言生成与环境反馈之间持续循环，让“输出结果”不再停留于静态回答或一次性指令，而是演变为随时可迭代的动态策略。在农业管理平台中，这意味着无论是针对种植计划、田间监测还是病虫害防治，模型都能够通过多轮对话或交互来积累经验：如果当前采取的播种密度或配肥方案对作物长势并无显著提升，后续系统将基于此负面反馈来更新决策策略，在下一个种植周期或下一批田块里尝试新的组合措施。

同时，为了保证在连续决策中保持正确的价值导向，还可设立一个专门的“奖励模型”去评估当前产量、质量、投入产出比等指标的变动水平，一旦有新的监测数据或用户评价输入到平台，系统就能根据奖励模型的打分来判断是否需要策略进行迭代修正。通过这样的闭环设计，农业大语言模型不仅在表层语言上“学会了对答”，也在深层决策机制上“学会了应变”：在高维度、多变量的耕作环境里进行探索，试错、重试，再从环境反馈中汲取教训，不断迭代出与实际农情最贴合的耕作方案。

更进一步的思路是将大语言模型所擅长的自然语言交互与专家知识表达，与强化学习对复杂策略的长期优化能力结合在一起，打造真正能够“见招拆招”的农业专家系统。一方面，大语言模型可以为系统提供多模态输入接口与可解释的决策解释：例如，农户上传一张携带元数据的田间影像，模型先以文字形式总结当前作物生长状况，并基于外部数据库或先验知识推断可能出现的病虫害类型；另一方面，强化学习部分则持续分析作物在不同时刻的反馈信号（如产量提升情况、施肥成本变动、天气异常导致的病害扩散），从而对下一步行动做出策略性调整。当发现系统在某个维度陷入局部最优时，还可以借助语言模型生成多种可能的干预方案，由强化学习代理逐一试验并比较收益，再结合领域经验与历史数据形成更优解。通过自然语言对方案进行解释、对比和修订，农户或农业技术人员也能更直观地理解背后的逻辑原理，而非被“黑箱式”的算法决策所蒙蔽。凭借这个互补的多回合循环，农业生产将告别传统依赖经验决策的模式，让大数据、语言智能与强化学习在同一个框架下形成合力，推动行业在精细化管理与可持续发展上取得新的突破。

当大语言模型开始面对更复杂的社会与行业应用时，如何让它们不只“能写会说”，更能“说得合情合理、贴近实际需求”，就成为关键命题。人类反馈强化学习（Reinforcement Learning from Human Feedback, RLHF）正是在这一背景下崭露头角的技术思路。与传统的强化学习不同，RLHF并非单纯依赖环境信号或固定规则来定义回报函数，而是将“人类主观评价”引入训练闭环：当模型输出一段文本或回答一个问题后，会让真实用户或评测者对输出的准确度、礼貌性、逻辑严谨度等维度打分，这些打分信息再转化为模型在后续训练中所要优化的目标。借助这种“人工标尺”的监督，大语言模型不再拘泥于对大规模文本语料的统计分布拟合，而是在每一轮交互或迭代中，都能朝着人类偏好和价值取向的方向不断收敛。例如，用户可能对于一句回答的专业度提出更高要求，那么评分模型就会对过于泛泛的回答施加较低回报，引导模型在后续生成时引用更精准的行业术语与事实证据；若一段对话出现歧视性或不恰当言辞，人工反馈同样会通过负奖励提醒模型避免类似失误。这样，在长期迭代的过程中，大语言模型便能逐步学会符合人类标准的语言风格与信息尺度，减少生硬、武断乃至不良内容的出现，从而在专业对答、农业咨询乃至更广泛的社交互动场合中展现出更具亲和力与可信度的语言能力。

在强化学习与大语言模型融合的具体实现中，RLHF常常通过一个专门的“奖励模型（Reward Model）”来对模型输出进行评价，而这一“奖励模型”则由人类的偏好数据进行训练和迭代优化。为便于说明，将大语言模型视作策略 $\pi_{\theta}$ ，其在给定上下文 $x$ 时生成某段文本 $y$ 。而奖励模型则可表征为一个可学习的函数 $R_{\phi}(x,y)$ ，其中参数 $\phi$ 由人类对不同输出的偏好打分、对比选择（pairwise comparison）或评级

分数等信息训练得到。在典型的 RLHF 流程中，模型的整体目标是最大化以下期望回报：

$$J(\theta) = \mathbb{E}_{\mathbf{x} \sim \mathcal{D}, \mathbf{y} \sim \pi_{\theta}(\mathbf{y}|\mathbf{x})} [R_{\phi}(\mathbf{x}, \mathbf{y})],$$

其中 $\mathbf{x}$ 来自一个自然语言上下文分布（可能是对话背景、农户提问或系统提示），而大语言模型的策略 $\pi_{\theta}$ 用以生成回答 $\mathbf{y}$ 。一旦 $\mathbf{y}$ 被产出，人类打分或反馈数据会先行训练或修正 $R_{\phi}$ 使其尽量拟合人类对该回答的好恶程度，然后在强化学习阶段，用该 $R_{\phi}$ 作为回报信号来指导对 $\theta$ 的更新。此处可采用如 PPO（Proximal Policy Optimization）或其他先进的策略优化方法，保证在对话和生成语料中，模型“朝着人类期望前进”的同时，不会因为步幅过大而导致策略塌陷或语言输出质量骤降。

更直观地看，RLHF 本质上是把传统强化学习中的“环境回报”替换为“由人类主观偏好训练出的奖励模型”，这样一来，即便大语言模型在无监督阶段学到的只是对海量文本的分布拟合，在 RLHF 阶段也能结合人类专家或真实用户的价值判断进行二次塑造。对于农业问答场景而言，这种融合意味着：当回答涉及病虫害诊断、施肥用量或作物轮作建议时，人类专家的评分会确保模型在科学性与可行性方面不断提升；而若输出在礼貌度、可解释性方面达不到要求，也能通过负向反馈让策略产生修正，从而在多轮对话中逐步收敛到专业且友善的风格。通过该过程，RLHF 实现了让大语言模型“记住并执行人类价值观、行业准则”的目标，为其在行业应用中保持高可信度与实操价值提供了坚实的机制保障。在人机交互与专业问答的诸多实践中，RLHF 已经展现出超越传统“预训练 + 微调”范式的显著优势。比如，OpenAI 等团队在 ChatGPT 的研发过程中，便投入了大量标注者与评测者来对模型回答进行系统性打分，不仅关注“是否答对了问题”，也对表达风格、推理链条的条理性、对用户感受的尊重度等进行评价。久而久之，模型在一次次对比学习中逐渐内化“何谓合理、何谓友善”的语言表达准则，能够在对话中显现出更加连贯、体贴的人机交互能力。对于专业场景，如金融、医疗或农业，团队可能招募相应行业的专家、科研人员、资深从业者来提供高质量的人类反馈，使得奖励模型在本领域的知识维度上更为精细。例如，在农业咨询系统中，专家可以指出模型回答中对病虫害判定的偏差，或对施肥浓度建议的错误，给出差异化的负反馈，由此进一步训练奖励模型，让其在后续强化学习迭代时“惩罚”类似失误；一旦模型输出的解答在逻辑链或数值建议上更贴近实情，也会被给予更高正向奖励，帮助策略快速收敛至高水平。

在一些社群管理或公共平台上，也开始尝试通过 RLHF 来过滤和优化文本内容。例如，社交媒体若想在海量用户交互中减少仇恨言论或虚假信息，仅靠预训练模型难以应对形形色色的对话场景；但若将人类评估与强化学习结合，便能引导大模型更敏锐地捕捉潜在的违规或敏感内容，并在合适的语境下进行柔性拦截或纠正。这类机制同样可以迁移到农业信息服务平台上，对涉及转基因作物安全、防疫检疫措施等敏感话题时进行谨慎筛查和适度科普，从而在保证信息准确度的同时兼顾舆论健康和公众信任度。归根结底，RLHF 在不打破大模型整体结构的前提下，为其注入了一条直接对接“人类价值”与“行业知识”的快速训练通路。对农业而言，这条通

路使得 AI 系统不仅满足专业可靠的硬标准，也在与农户和农业从业者的交流中体现出更多温度与包容性。

在强化学习、人类反馈等多重机制的推动下，大语言模型不仅在文本生成与问答方面取得跨越式提升，更逐渐展现出超越单点功能的全局认知与决策能力。随着参数规模扩大与训练范式不断演化，人们发现模型在“推理深度”“多步规划”甚至“自适应学习”上呈现出明显的跃迁迹象：它们不再仅仅停留于对既有语料的复述和整合，而是能够在面对新问题时做出一定程度的推理和创新。例如，研究者观察到某些超大规模模型在推断高维问题或处理跨领域交叉信息时，会自发地学习到行之有效的启发式搜索策略；面对前所未见的抽象难题时，模型可能会尝试分解子问题、收集外部工具或知识，从而逐步逼近可行解，而非简单地输出常见范式的答案。更值得期待的是，大语言模型与强化学习在未来或将进一步融合出“自我反馈”“元学习”等更高层次的智能形态。通过自监督阶段累积的海量语义知识，模型可以快速建立对领域概念与逻辑规则的初步认知；然后在强化学习环节中，不断对自身的推理流程与结论进行试验与修正，将错误视为新的学习信号，从而实现“自我进化”。在农业领域，这种潜能表现为：模型不仅能建议农事操作，还能据长期观测反馈推断当前策略在土壤健康、生态平衡、经济收益等指标上的得失，进而不断调整和完善自身的“农业专家观”。若再加上多模态感知（如图像、遥感、语音）与多智能体协作，大语言模型或许能进化到“全局规划 + 局部自适应”相结合的层级，让纵横交织的农业生态系统在动态环境中也能保持高效而稳健的协同。对人类社会而言，这意味着借由大语言模型来缩短行业专业门槛、扩展创新空间，让更广泛的人群都能享受智能化红利，为持续提升农业生产效率与生态可持续性提供前所未有的技术抓手。

在迈向更高层次的智能过程中，大语言模型不仅要不断精进自身的语言理解与决策能力，还需与更广阔的外部知识体系深度融合，以应对真实农业情境中的海量交叉信息和长周期动态影响。当前一些前沿研究开始探索将知识图谱、规则引擎或学科模型（如土壤学、生物学中的机理模型）与大语言模型进行耦合，让后者在回答或制定策略时，能够调用更为系统、可信的行业知识。当模型面临对作物基因编辑、跨季节轮作体系等复杂主题进行多步推理时，外部知识库的引入不但能弥合纯数据驱动可能带来的“盲点”，也可为强化学习中所用的回报函数和中间状态提供更精准的标签或度量。举例而言，如果我们在病虫害防治的对话式推荐系统中预先内置了基于植物病理学构建的知识图谱，大语言模型就可以在输出具体药剂或物理隔离方案时调用相应的条目，引用病原菌进化路径、交叉感染概率等细节信息，以提供更具说服力与可验证性的见解。与此同时，强化学习代理也能借助该知识图谱来构造更细颗粒度的状态表示，如是否存在抗药性突变、邻近农田病情扩散的风险等，从而在策略迭代中更紧密地贴合真实农业生态的复杂度。在与外部知识体系的交互过程中，大语言模型将其“大规模预训练 + 强化学习”中培养出来的“语言推理”与“多步决策”能力充分发挥出来，不再局限于文本表面匹配，而能根据农业行业的“内在逻辑”进行深入分析与更高级别的综合判断。例如，模型可以先依照知识图谱检索到某种病虫害的典型发病条件，再结合近几天的气象预测信息、田间实测数据进行多阶段模拟推理，以判断是否需要提前部署防治措施；在决策做出之后，若实

际结果与预期有偏差，强化学习代理会回溯先前调度或用药动作，尝试寻找更恰当的组合策略。这种“语言 + 知识 + 强化学习”三位一体的模式，让模型不仅可以给出答案，还能在失败或偏差中积累新的知识与策略迭代经验，从而逐步向“通用农业智能”迈进。对于农业政策制定者、科研人员和企业从业者而言，这意味着在宏观规划与具体落地之间能有一座具备自学习、自适应能力的桥梁，为我国乃至全球农业可持续发展提供更具弹性与前瞻性的技术助力。

在更宏大的视野下，大语言模型若能与高阶认知机制和前沿硬件算力相结合，或许将构建出一种兼具广域感知与深度决策的“自进化”生态。凭借分布式计算架构和云端超算资源，强化学习过程中对庞大搜索空间的采样与迭代速度将大大提升，使模型能够快速验证多种耕作策略、供应链组合或气候情境下的产量变化趋势。在实验试错之外，农业数字孪生（Digital Twin）技术也能为此提供更逼真的虚拟环境，让模型可以在高度还原的仿真农场中无限制地试验不同的农机调度模式、病害防治方案或新品种栽培组合，而不必担心对现实农田造成损害。每一次仿真得到的收益与损失都将直接成为强化学习的回报信号，推动语言模型的策略网络朝着更佳解耦度与更优全局性发展。得益于大语言模型对行业文献、专家经验与环境实时监测数据的整合能力，数字孪生不仅是单纯的“模拟场景”，还可不断将新观察和历史知识注入模型，使其在迭代中累积更稳定的对策与更丰富的应急预案。另一方面，随着生物技术与信息科学的进一步交叉，农作物分子育种、基因编辑、土壤微生物组学等深层机理的研究成果也有望通过大语言模型进行跨学科融合，让强化学习在决策规划时兼顾到基因层、细胞层乃至生态群落层的信息。这意味着智慧农业从上层的“田间管理与市场决策”逐步向下渗透到生命科学内部，将病虫害防治、养分吸收机理、土壤修复措施等元素纳入同一套语言推理与策略优化体系。在此过程中，模型若能把分子水平的因果链条和宏观农业体系的经济考量进行统筹，便可在高维度信息融合中为不同阶段和不同规模的种植经营者提供定制化建议。无论是大型农业企业需要大范围推广化肥减量增效，还是小农户渴望精细化的灌溉指南，都能在这样一个“大模型 + 强化学习 + 多学科知识”的体系中获得合适的解决方案。最终，大语言模型所展现的决策潜力不再局限于回答“该怎么做”，而是能在解释自身思路、跟踪长期效果、吸收新数据反馈的多重循环中，不断积累跨学科、跨时空的洞察力。这种演进对农业现代化而言，无疑具备颠覆性意义：从过去以人为主的经验驱动，迈向以数据、知识和自适应算法融汇驱动的新形态，让农业在动态环境与社会需求变化中保持高韧性与可持续性，为全球粮食安全与生态平衡作出更大贡献。

### 第 3 章 参考文献

- [1] Bernard Widrow and Michael A Lehr. “30 years of adaptive neural networks: perceptron, madaline, and backpropagation”. In: Proceedings of the IEEE 78.9 (1990), pp. 1415–1442.

- [2] Marius-Constantin Popescu et al. “Multilayer perceptron and neural networks”. In: WSEAS Transactions on Circuits and Systems 8.7 (2009), pp. 579–588.
- [3] Rudolf Kruse et al. “Multi-layer perceptrons”. In: Computational intelligence: a methodological introduction. Springer, 2022, pp. 53–124.
- [4] Vivienne Sze et al. “Efficient processing of deep neural networks: A tutorial and survey”. In: Proceedings of the IEEE 105.12 (2017), pp. 2295–2329.
- [5] Zewen Li et al. “A survey of convolutional neural networks: analysis, applications, and prospects”. In: IEEE transactions on neural networks and learning systems 33.12 (2021), pp. 6999–7019.
- [6] Larry R Medsker, Lakhmi Jain, et al. “Recurrent neural networks”. In: Design and Applications 5.64-67 (2001), p. 2.
- [7] Paul Rodriguez, Janet Wiles, and Jeffrey L Elman. “A recurrent neural network that learns to count”. In: Connection Science 11.1 (1999), pp. 5–40.
- [8] Ilya Sutskever, Oriol Vinyals, and Quoc V Le. “Sequence to sequence learning with neural networks”. In: Proceedings of the 28th International Conference on Neural Information Processing Systems-Volume 2. 2014, pp. 3104–3112.
- [9] Jan Chorowski et al. “Attention-based models for speech recognition”. In: Proceedings of the 29th International Conference on Neural Information Processing Systems Volume 1. 2015, pp. 577–585.
- [10] Minh-Thang Luong, Hieu Pham, and Christopher D Manning. “Effective Approaches to Attention-based Neural Machine Translation”. In: Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. 2015, pp. 1412–1421.
- [11] Peter Shaw, Jakob Uszkoreit, and Ashish Vaswani. “Self-Attention with Relative Position Representations”. In: Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 2 (Short Papers). 2018, pp. 464–468
- [12] Miquel Àngel India Massana, Pooyan Safari, and Francisco Javier Hernando Pericás. “Self multi-head attention for speaker recognition”. In: Interspeech 2019: the 20<sup>th</sup> Annual Conference of the International Speech Communication Association: 15-19 September 2019: Graz, Austria. International Speech Communication Association (ISCA). 2019, pp. 4305–4309.
- [13] Mohammad Dehghani and Haidar Samet. “Momentum search algorithm: A new meta-heuristic optimization algorithm inspired by momentum conservation law”. In: SN Applied Sciences 2.10 (2020), p. 1720.
- [14] Fangyu Zou et al. “A sufficient condition for convergences of adam and rmsprop”. In: Proceedings of the IEEE/CVF Conference on computer vision and pattern recognition. 2019, pp. 11127–11135.

- [15] Zijun Zhang. “Improved adam optimizer for deep neural networks”. In: 2018 IEEE/ACM 26th international symposium on quality of service (IWQoS). IEEE. 2018, pp. 1–2.
- [16] Saining Xie et al. “Aggregated residual transformations for deep neural networks”. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2017, pp. 1492–1500.
- [17] Jingjing Xu et al. “Understanding and improving layer normalization”. In: Proceedings of the 33rd International Conference on Neural Information Processing Systems. 2019, pp. 4381–4391.
- [18] Kai Han et al. “Transformer in transformer”. In: Proceedings of the 35th International Conference on Neural Information Processing Systems. 2021, pp. 15908–15919.
- [19] Ashish Vaswani et al. “Attention is all you need”. In: Proceedings of the 31st International Conference on Neural Information Processing Systems. 2017, pp. 6000–6010.
- [20] Avinash Maurya et al. “Datastates-llm: Lazy asynchronous checkpointing for large language models”. In: Proceedings of the 33rd International Symposium on High Performance Parallel and Distributed Computing. 2024, pp. 227–239.
- [21] Zhihao Jia, Matei Zaharia, and Alex Aiken. “Beyond data and model parallelism for deep neural networks.” In: Proceedings of Machine Learning and Systems 1 (2019), pp. 1–13.
- [22] SR Nandakumar et al. “Mixed-precision deep learning based on computational memory”. In: Frontiers in neuroscience 14 (2020), p. 406.
- [23] Xiangyi Chen, Zhiwei Steven Wu, and Mingyi Hong. “Understanding gradient clipping in private SGD: a geometric perspective”. In: Proceedings of the 34th International Conference on Neural Information Processing Systems. 2020, pp. 13773–13782.
- [24] Jinia Konar, Prerit Khandelwal, and Rishabh Tripathi. “Comparison of various learning rate scheduling techniques on convolutional neural network”. In: 2020 IEEE International Students’ Conference on Electrical, Electronics and Computer Science (SCEECS). IEEE. 2020, pp. 1–5.
- [25] Pierre Baldi and Peter J Sadowski. “Understanding dropout”. In: Advances in neural information processing systems 26 (2013).
- [26] Jia Deng et al. “ImageNet: A large-scale hierarchical image database”. In: 2009 IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society. 2009, pp. 248–255.
- [27] Eli Stevens, Luca Antiga, and Thomas Viehmann. Deep Learning with PyTorch: Build, train, and tune neural networks using Python tools. Manning, 2020.

- [28] Bo Pang, Erik Nijkamp, and Ying Nian Wu. “Deep learning with tensorflow: A review”. In: *Journal of Educational and Behavioral Statistics* 45.2 (2020), pp. 227–248.
- [29] Dumitru Erhan et al. “Why does unsupervised pre-training help deep learning?” In: *Proceedings of the thirteenth international conference on artificial intelligence and statistics. JMLR Workshop and Conference Proceedings*. 2010, pp. 201–208.
- [30] Larisa Gorenstein et al. “Bidirectional encoder representations from transformers in radiology: a systematic review of natural language processing applications”. In: *Journal of the American College of Radiology* 21.6 (2024), pp. 914–941.
- [31] Martin R Chavez et al. “Chat Generative Pre-trained Transformer: why we should embrace this technology”. In: *American journal of obstetrics and gynecology* 228.6 (2023), pp. 706–711.
- [32] Colin Raffel et al. “Exploring the limits of transfer learning with a unified text-to-text transformer”. In: *Journal of machine learning research* 21.140 (2020), pp. 1–67.
- [33] Julian Salazar et al. “Masked Language Model Scoring”. In: *Proceedings of the 58<sup>th</sup> Annual Meeting of the Association for Computational Linguistics*. Association for Computational Linguistics. 2020
- [34] Thomas Wang et al. “What language model architecture and pretraining objective works best for zero-shot generalization?” In: *International Conference on Machine Learning*. PMLR. 2022, pp. 22964–22984.
- [35] Reza Pourreza et al. “Painter: Teaching auto-regressive language models to draw sketches”. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2023, pp. 305–314.
- [36] Xiao Liu et al. “GPT understands, too”. In: *AI Open* 5 (2024), pp. 208–215.
- [37] Rylan Schaeffer, Brando Miranda, and Sanmi Koyejo. “Are emergent abilities of large language models a mirage?” In: *Proceedings of the 37th International Conference on Neural Information Processing Systems*. 2023, pp. 55565–55581.
- [38] Julian Coda-Forno et al. “Meta-in-context learning in large language models”. In: *Proceedings of the 37th International Conference on Neural Information Processing Systems*. 2023, pp. 65189–65201.
- [39] Thomas Carta et al. “Grounding large language models in interactive environments with online reinforcement learning”. In: *International Conference on Machine Learning*. PMLR. 2023, pp. 3676–3713.
- [40] Ben Goertzel. “Artificial general intelligence: concept, state of the art, and future prospects”. In: *Journal of Artificial General Intelligence* 5.1 (2014), p. 1.

- [41] Yanqi Zhou et al. “Mixture-of-experts with expert choice routing”. In: Proceedings of the 36th International Conference on Neural Information Processing Systems. 2022, pp. 7103–7114.
- [42] Jianping Gou et al. “Knowledge distillation: A survey”. In: International Journal of Computer Vision 129.6 (2021), pp. 1789–1819.
- [43] Armen Aghajanyan et al. “Scaling laws for generative mixed-modal language models”. In: International Conference on Machine Learning. PMLR. 2023, pp. 265–279.
- [44] Yujia Qin et al. “Tool learning with foundation models”. In: ACM Computing Surveys 57.4 (2024), pp. 1–40.
- [45] Louie Giray. “Prompt engineering with ChatGPT: a guide for academic writers”. In: Annals of biomedical engineering 51.12 (2023), pp. 2629–2633.
- [46] Xiaojun Chen, Shengbin Jia, and Yang Xiang. “A review: Knowledge reasoning over knowledge graph”. In: Expert systems with applications 141 (2020), p. 112948.
- [47] Xinyu Lin et al. “Data-efficient Fine-tuning for LLM-based Recommendation”. In: Proceedings of the 47th international ACM SIGIR conference on research and development in information retrieval. 2024, pp. 365–374.
- [48] Brian Lester, Rami Al-Rfou, and Noah Constant. “The Power of Scale for ParameterEfficient Prompt Tuning”. In: Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. Association for Computational Linguistics. 2021.
- [49] Xiang Lisa Li and Percy Liang. “Prefix-Tuning: Optimizing Continuous Prompts for Generation”. In: Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). 2021, pp. 4582–4597.
- [50] Soufiane Hayou, Nikhil Ghosh, and Bin Yu. “LoRA+ efficient low rank adaptation of large models”. In: Proceedings of the 41st International Conference on Machine Learning. 2024, pp. 17783–17806.
- [51] Jan-David Krieger et al. “A domain-adaptive pre-training approach for language bias detection in news”. In: Proceedings of the 22nd ACM/IEEE joint conference on digital libraries. 2022, pp. 1–7.
- [52] Ying Li, Zhen Tan, and Weidong Xiao. “LLM for Uniform Information Extraction Using Multi-task Learning Optimization”. In: Asia-Pacific Web (APWeb) and WebAge Information Management (WAIM) Joint International Conference on Web and Big Data. Springer. 2024, pp. 17–29.
- [53] Uday Kamath et al. “LLM Adaptation and Utilization”. In: Large Language Models: A Deep Dive: Bridging Theory and Practice. Springer, 2024, pp. 135–175.

- [54] Shugang Hao and Lingjie Duan. “Online learning from strategic human feedback in llm fine-tuning”. In: ICASSP 2025-2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE. 2025, pp. 1–5.
- [55] Tianhao Shi et al. “Preliminary study on incremental learning for large language model-based recommender systems”. In: Proceedings of the 33rd ACM International Conference on Information and Knowledge Management. 2024, pp. 4051–4055.
- [56] Leslie Pack Kaelbling, Michael L Littman, and Andrew W Moore. “Reinforcement learning: A survey”. In: Journal of artificial intelligence research 4 (1996), pp. 237–285.
- [57] Martin L Puterman. “Markov decision processes”. In: Handbooks in operations research and management science 2 (1990), pp. 331–434.
- [58] David Silver et al. “Deterministic policy gradient algorithms”. In: International conference on machine learning. Pmlr. 2014, pp. 387–395.
- [59] Mengyuan Yang et al. “Fine-tuning large language model based explainable recommendation with explainable quality reward”. In: Proceedings of the AAAI Conference on Artificial Intelligence. Vol. 38. 8. 2024, pp. 9250–9259.
- [60] Gokul Swamy et al. “A minimaximalist approach to reinforcement learning from human feedback”. In: Proceedings of the 41st International Conference on Machine Learning. 2024, pp. 47345–47377.
- [61] Jiaxiang Li et al. “Getting more juice out of the sft data: Reward learning from human demonstration improves sft for llm alignment”. In: Advances in Neural Information Processing Systems 37 (2024), pp. 124292–124318.
- [62] Zifan Wu et al. “Coordinated proximal policy optimization”. In: Proceedings of the 35th International Conference on Neural Information Processing Systems. 2021, pp. 26437–26448.
- [63] Fei Tao et al. “Digital twin modeling”. In: Journal of Manufacturing Systems 64 (2022), pp. 372–389

## 4.大模型的训练与部署实践

近年来，“大模型”已成为人工智能领域最为瞩目的研究热点，其核心驱动力来自于深度神经网络规模的不断扩张、训练数据量的持续攀升以及分布式计算能力的高速发展。以 Transformer 为代表的预训练架构，使得模型能在海量无监督语料上自学语言表达与推理能力，再通过微调适配下游任务，实现了从自然语言处理到多模态理解的显著突破。然而，要将这些算法层面的革新真正应用于农业生产场景，仍需跨越数据获取、训练架构、推理部署与全生命周期管理等一系列工程化难题。农业领域的数据高度异构——涵盖遥感影像、土壤传感器时序数据、气象预报、农艺文档与政策法规文本等多种模态；同时，数据分布区域广、标注成本高，并且在田间环境下硬件资源往往受限，给大规模模型训练与推理带来挑战。此外，模型上线后还需要持续监测、迭代优化与安全合规保障，才能在生产环境中保持稳定与可靠。

本章将聚焦“农业大模型”的训练与部署实践，系统性地阐述如何在农业场景下构建“从数据到模型再到服务”的完整链路。首先，我们会在 4.1 节“数据获取与预处理”中深入探讨农业多源异构数据的采集渠道与清洗策略。农田传感器采集的土壤水分与温湿度数据，往往以高频时序形式存在；无人机与卫星遥感影像则以高分辨率栅格图层呈现；农业文献、技术手册与政策文件包含大量专业术语与领域知识；这些异构数据在格式、精度与语义层面差异显著，需要通过标准化元数据、字段映射与数据增强等方法，实现统一的语料格式与多模态对齐。我们将结合典型案例说明如何利用自动化脚本与半自动化标注工具，将 Raw Data 转化为可供预训练与微调使用的高质量语料库，同时兼顾噪声过滤与敏感信息屏蔽，确保数据安全与合规。

在 4.2 节“大规模训练架构与硬件需求”中，我们将详细介绍分布式训练范式在农业大模型开发中的应用路径。面对千亿级别参数的 Transformer 模型，单卡显存早已无法满足需求，必须借助数据并行、张量并行与流水线并行等协同策略，在多机多卡集群上进行高效训练。我们会结合国内外主流框架（如 Colossal-AI、DeepSpeed 与 Alpha）说明如何设置合理的并行切分方案、显存优化与混合精度训练，以最大程度提升训练吞吐与资源利用率。同时，针对农业项目常见的算力限制与成本约束，还将讲解 High-Performance GPU/TPU/HPC 集群选型方案、边缘设备与云端协同的异构算力调度思路，帮助研究者在资源受限的环境下实现可量化的模型性能提升。

4.3 节“模型推理与部署优化”聚焦将已训练好的大模型高效化地应用于实际农业生产场景。推理阶段的核心难点在于如何在保证模型准确度的同时，最大程度降低延迟与算力消耗。一方面，我们会介绍预填充（Prefill）与解码（Decode）两大阶段的性能分析，探讨如何通过 KV 缓存压缩、PagedAttention 等技术减少显存占用与内存碎片；另一方面，将重点剖析模型量化（Quantization）、剪枝（Pruning）与知识蒸馏（Distillation）等方法，讲解如何将数十亿参数的模型压缩为可部署在边缘服务器或田间便携设备上的轻量化版本。此外，还会结合农业具体应用场景（如基于无人机图像的病虫害识别、面向农机的智能调度指令生成）给出部署示例，

说明在云端、边缘与本地之间如何灵活选择部署方式，以实现“高并发、多场景、低延迟”的在线服务。

4.4 节“模型全生命周期管理（MLOps）”则从运维角度出发，介绍如何构建大规模农业大模型应用的持续迭代与服务安全体系。农业环境往往变化多端，季节性与区域差异会导致模型面临“数据漂移”（Data Drift）与“概念漂移”（Concept Drift）问题，我们会分析如何通过持续集成与持续部署（CI/CD）流水线，结合版本控制与自动化测试，确保模型在新数据到来时快速更新而不影响系统稳定；同时，讲解模型监控指标（如推理延迟、置信度分布、农户反馈满意度）与预警机制的设计，为运营团队提供实时预警与回滚策略。针对农业场景的合规要求，也会探讨数据隐私保护与审计机制，确保系统在采集农户敏感信息与在线推理时遵循相关法规，并能够在发生安全事件时迅速定位与修复。

本章内容不仅涵盖了从数据标注到模型上线的端到端流程，还结合农业场景下的典型技术难点，提供了实用的优化建议与最佳实践示例。读者通过本章能全面了解如何高效搭建农业大模型训练与部署体系：既能深入掌握分布式训练的关键技术，也能灵活运用推理加速与压缩技术，将大模型运行在现实农田与云平台之上；更能构建持续迭代的 MLOps 管道，确保系统稳定、高效并具备可扩展性。通过本章的学习，农业科研人员与工程师将具备从零开始构建“可用、可扩展、可维护”大模型应用的能力，加速推动人工智能赋能农业的落地进程。

## 4.1 数据获取与预处理

大模型崛起的背后，是庞大而精心构建的训练数据集，模型的能力上限很大程度上由训练数据的质量和多样性决定。从预训练阶段的海量语料，到微调阶段的精细指令数据，每一步都对模型的最终表现产生深远影响。合理地获取、清洗、标注和增广这些数据，是大模型训练的起点。本节将探讨这些数据预处理步骤，并结合农业领域数据的特点（如不同地域数据的异构性、标注数据稀缺等）进行说明。

在构建用于大模型预训练的数据语料库时，研究者通常从多种来源采集数据，以最大程度提升模型在语言理解、知识覆盖和语用表达等方面的能力。通常来讲，主流的大模型的数据来源分为以下几类：

**通用网络文本。**这类数据广泛来自互联网，以网页、论坛、博客、社交平台等形式呈现，其语言风格丰富、题材广泛、贴近真实世界对话，对于提升模型在开放式问答、通用对话等任务上的表现具有重要意义。典型代表如 Common Crawl[1]，它是一个面向研究社区的大规模网页抓取项目，累计包含数十亿网页的原始文本。尽管该类数据规模庞大，但由于其抓取过程天然带来大量格式噪音与低质量内容，直接使用可能反而降低模型训练效果。因此，研究者往往会在数据使用前引入复杂的清洗和筛选流程。例如，Google 发布的 C4（Colossal Clean Crawled Corpus）便是基于 Common Crawl 经过清洗、去重、语言筛选和毒性过滤等步骤后得到的高质量训练语料。

**百科全书。**相比网络语料，百科内容更具有结构化、权威性强、语言中性等特点，因此在模型学习准确知识表述与逻辑推理时具有显著优势。维基百科（Wikipedia）作为全球最大且持续更新的自由百科全书，已被广泛纳入包括 GPT、LLaMA、DeepSeek 在内的众多主流模型的训练数据中。其统一的格式、良好的段落结构和跨语言链接，也方便了模型在多语言任务中的迁移能力的形成。

**书籍语料。**与百科短文相比，书籍语料则往往承载更深入的主题探讨与复杂的叙事结构，是语言模型掌握长文本生成能力的关键资源之一。书籍不仅覆盖丰富的文学、人文、历史和科技主题，而且在句法结构、修辞方式等方面更为多样，有助于模型在语言风格、上下文记忆等方面建立更稳固的建模能力。目前主流训练语料中广泛使用了来自 Project Gutenberg、BookCorpus 等开源项目的数据，这些书籍均处于公共版权状态，便于大规模整理与使用。

**学术文献。**在强化模型的专业理解能力方面，学术论文语料提供了另一维度的支持。学术文献通常结构规范、论述严谨、引用清晰，适用于培养模型在技术、医学、自然科学等领域的概念理解和事实推理能力。例如，arXiv 和 PubMed 是两大开放获取平台，分别提供物理、计算机科学和生物医学方向的大量研究论文。在一些面向特定领域（如农业、气象等）的模型训练中，这类文献尤其能提供高质量的事实语料和术语背景，弥补网络数据在专业性上的不足。

**图像字幕数据。**随着多模态大模型的发展，图像与字幕数据也逐渐成为构建语料的重要来源。这类数据往往由图像与其描述性文字（caption）构成，适用于训练模型对图文关系的理解能力。例如，用户上传到社交平台的图文内容、新闻媒体中的配图解说、或者图像搜索引擎返回的文本摘要，都属于这类资源的一部分。研究者通常基于现有的网页抓取框架，进一步提取其中的图像元素并配套其上下文描述文本，构建大规模图文对数据集。类似 LAION-5B 这样的图像-文本对数据库已广泛用于 CLIP、BLIP 等多模态模型的训练，并在语言模型预训练中作为增强模块参与进来，以支持对图像场景的自然语言描述与理解。

**传感器及物联网数据。**对于像农业这样高度依赖物联网的领域，各种传感器数据（温度、湿度、土壤养分、设备监控等）也是潜在的数据来源。这类数据往往是时间序列或空间序列形式，可能缺少直接的语义标签。为了将传感器数据融入大模型训练，可以采取两种思路：一是将其转化为结构化文本描述（例如“传感器 X 在某时的读数为 Y”），将海量的农业环境数据统一到语言模型可以理解的输入域中，从而为模型提供对实际农业环境条件的长期建模能力。二是为大模型设计适应非语言模态的专门子结构。例如，可为模型增设一个处理时间序列的编码器模块，专门负责对来自传感器的原始数值流（如每日光照变化曲线、温湿度变化序列）进行建模，然后将编码结果融合到语言模型的主干网络中。这种做法在医疗、金融等行业已有初步尝试，在农业领域也正逐步展开，尤其适用于长周期、高分辨率的环境监测任务。

虽然从各类渠道采集到了大量文本数据，但这些原始数据往往无法直接投入模型的训练过程，其中混杂着各种噪音信息、错误数据和低质量内容，因此数据清洗

与质量控制成为模型训练准备阶段至关重要的一环。数据清洗的主要目标是去除文本中明显的非结构化信息，以确保模型所接收到的数据能够准确反映人类语言的真实分布和结构。

首先，对于从互联网抓取的数据，通常会借助自动化工具对原始内容进行初步过滤，去除 HTML 标签、页面内嵌脚本、文本乱码等非文本内容。如以 Common Crawl 为代表的数据库，初步过滤之后仍需进一步清理低质量内容，如重复的模板文本、异常短小且无意义的句子，以及明显来自广告或垃圾页面的内容等。为此，研究团队开发了多种自动识别低质量文本的方法，例如基于规则的关键词匹配或文本模式识别，以及通过已有的语言模型计算文本质量分数，以决定数据是否保留或丢弃。其次，在数据清洗过程中，数据去重也是一项不可或缺的步骤。研究表明，重复文本不仅无助于模型性能提升，甚至会降低模型泛化能力。因此，研究者常采用哈希函数（如 SimHash 或 MinHash）识别并移除重复和近似重复的内容。另外，大规模公开数据不可避免地混入不良内容（例如隐私信息、仇恨言论、暴力或歧视性言辞），这些内容若不加以控制，可能会引导模型产生有害输出。因此研究团队往往建立专门的内容黑名单与敏感词库，利用文本匹配、分类模型或人工审核等方法过滤掉不合适的内容。

大模型的训练过程通常分为两步，一是预训练（Pre-Training）阶段，二是微调（Fine-tuning）阶段。前者采用自监督的训练模式，通过从海量的文本中的宽泛学习，掌握语言规律和基础知识，不追求特定的训练目标，通过上述处理后的数据通常能够满足训练要求。相比预训练，微调旨在使预训练模型适应特定任务或改进模型与人类价值观的对齐程度，所需的数据规模较小但质量要求更高，通常需要人为进行构建。最常见的数据类型包括：指令微调数据，由一轮或者多轮的“指令-相应”组成，主要目标及引导模型遵循用户的指令进行回复；偏好数据，主要在基于人类回复的强化学习（Reinforcement Learning from Human Feedback, RLHF）上使用，通常由人类评估者对模型多个输出进行排序生成。这类数据帮助模型学习人类偏好，产生更符合预期的输出；安全对齐数据，包含有害请求识别、拒绝生成危险内容的示例等，帮助模型学习安全边界，这类数据的构建通常涉及“红队测试”（Red Teaming），即专门设计可能导致模型产生有害输出的输入，然后提供正确的拒绝响应作为学习目标；特定任务数据，针对垂直领域的应用，如医疗问答、法律咨询等专业数据集，用于增强模型在特定领域的表现。

在文本数据能够被大模型直接使用之前，需要将文本转化为词元（token）的集合，即分词化（tokenization），将连续的文本字符序列转化为离散的数值 Token 序列，这些 Token 作为模型的直接输入单元。主流大模型常用的分词化方法包括 GPT 系列模型采用的基于字节对编码（Byte-Pair Encoding, BPE）、T5 模型采用的 SentencePiece 等。通过自动统计大量语料中字符和子字符串的频率，BPE 等算法动态地构建出高效的子词词表，有效地平衡了词表规模与序列长度之间的关系。

## 4.2 大规模训练架构与硬件需求

随着大模型参数量级从数亿级别迅速跃升至数千亿甚至上万亿，模型训练对计算资源和分布式架构提出了前所未有的挑战。单卡 GPU 显然已无法承载如此庞大的计算与内存负载，必须依赖多机多卡的分布式训练框架，并采用高效的并行策略和系统优化方法，才能在可接受的时间和成本范围内完成训练任务。本节将从分布式训练的主流策略出发，系统介绍数据并行、模型并行（包括张量并行与流水线并行）以及稀疏激活模型（如 MoE）的并行方法，并进一步讨论现代高性能硬件、高速互连网络及系统级训练加速工具在大模型训练中的角色与实践价值。

分布式训练的目标，是在保证模型正确收敛的前提下，以最小代价最大化训练吞吐与资源利用率。由于大模型的模型参数及数据量规模空前，远超单台显卡（GPU）的显存容量，因此必须借助分布式训练框架和并行策略来协同多 GPU 进行训练。当前主流的大模型训练通常采用集中基本并行策略，并根据模型规模与硬件拓扑进行灵活组合：

**数据并行（Data Parallelism）** 是一种传统且直接的训练加速方式。它强调将训练数据划分为多个子集，每张 GPU 复制模型结构的相同副本并分别处理其中一部分训练数据，并在每个训练步骤后通过通信操作（如 All-Reduce）同步参数梯度。将本次的训练数据进行分割后，将计算出的模型梯度变化进行汇总后，再并行更新各个副本，典型的例子如参数服务器（parameter server）等。数据并行具有实现简单、通信模式清晰的优点，适用于模型本身较小或已经经过模型并行切分后的情况。它也是几乎所有现代深度学习框架，如 PyTorch 等所原生支持的并行方式。但当模型变得极大时，单卡难以容纳全部模型参数，单纯依赖数据并行将面临内存瓶颈。

**模型并行（Model Parallelism）** 则解决了模型过大无法在单卡完整加载的问题。其基本思路是将模型的不同部分（如不同层，或同一层的张量矩阵）划分到不同设备上执行。张量并行（Tensor Parallelism）是模型并行的核心形式之一，它将模型中的大型权重矩阵按行或列切分，每张 GPU 计算其中一部分，随后将输出结果汇聚。NVIDIA 在 Megatron-LM 中提出的张量并行技术，首次成功训练了高达 83 亿参数的 Transformer 模型，因而被广泛用于 GPT 类模型的训练。个矩阵乘法等算子在多个 GPU 间拆分计算，从而成功训练了高达 83 亿参数的 Transformer 模型。另一种形式是流水线并行（Pipeline Parallelism），它将模型层划分为多个阶段，按序部署在多张 GPU 上，再通过微批次处理方式实现前向与反向传播的流水线并行执行。流水线并行可提升设备利用率，降低整体系统的内存压力，但也引入了训练过程及调度的复杂性，如降低训练效率的“气泡”效应（pipeline bubble）等。

**专家并行（Expert Parallelism）** 是一种专用于混合专家（Mixture-of-Experts, MoE）模型的并行方式。与常见的稠密模型（Dense Model）不同，混合专家模型作为稀疏模型（Sparse Model）的代表之一，通过一个动态路由机制，在每次前向计算中仅激活模型中的一部分专家网络，使得每个输入样本仅需与少量参数交互，从而实现“参数规模大、计算负担小”的理想结构。不过，这也为训练效率带来了诸多挑战，最显著的问题是较高的显卡占用平均参与运算的运算量小，训练效率底下。

因此稀疏 MoE 常结合专家并行：不同 GPU 各放置不同的专家，与数据并行结合后，每张卡负责不同专家的前向计算并在路由时跨卡发送 token。例如，每层 MoE 先广播路由计算得到每个 token 的专家分配，然后不同 GPU 之间传输相应 token 激活到负责该专家的卡上处理。这种通信开销是稀疏模型训练特有的开销，但凭借专家并行，一台机器可容纳极其庞大的参数量（如 Google 的 Switch Transformer 达到 1.6 万亿参数）。




图 4.1: (a)数据并行； (b) 张量并行； (c) 流水线并行； (d)专家并行。

当然，手工实现上述各种并行策略非常复杂，因而一些常见的训练框架被用于封装完整的解决方案，简化了大模型分布式训练。

**Colossal-AI**：来自香港中文大学的团队提出的 Colossal-AI[10]是一个支持大模型高效训练的统一系统。该系统提供了简洁的接口，开发者可以用几乎与单机相同的方式编写模型代码，然后让框架自动地将其扩展到多机多卡环境中。它内置支持数据并行、流水线并行、张量并行甚至序列并行等多种并行维度，以及 ZeRO 优化器的整合（见下文）。使用 Colossal-AI 在大模型上训练，相比基础实现可实现最多 2.76 倍的加速。Colossal-AI 的出现，使研究者不需要精通并行计算的细节就能尝试千亿级模型的训练。例如，将一个 Transformer 模型用 Colossal-AI 的装饰器标记，便可一键启用张量+数据并行方案。该系统还在持续更新，适配新的 GPU 和网络，以降低大模型训练的门槛。

**DeepSpeed**：由微软研发的 DeepSpeed 是另一个广泛使用的大模型训练优化库。DeepSpeed 最著名的贡献是提出了 ZeRO 技术,将传统数据并行中的冗余内存开销降到最低：它在不同 GPU 间分摊模型的各类状态（梯度、优化器状态、参数），而非每个进程都保存一份。具体来说，ZeRO-1 拆分优化器状态，ZeRO-2 进一步拆分梯度张量，ZeRO-3 甚至连模型参数本身在显存中也只保留各自的一部分，其余存在 CPU 或 NVMe 上，需要时再调入。借助 ZeRO 技术，DeepSpeed 曾展示在单机或少数 GPU 上训练超大模型的能力，例如利用 ZeRO-Offload 在单张 32GB GPU 加大内存的情况下训练 400 亿参数模型。此外，DeepSpeed 也支持 MoE 模型的并行

(DeepSpeed-MoE)，提供了内置的 MoE 层实现和路由负载均衡机制。对于推理阶段，DeepSpeed 提供了 ZeRO-Inference 等方案，实现将大模型权重分块存储于 CPU/NVMe，仅逐层调入 GPU 计算，从而用很少的 GPU 也能运行超大模型推理。例如，DeepSpeed 团队演示了在单卡利用 CPU/NVMe 存储，实现对 5300 亿参数模型的推理——尽管速度较慢，但极大降低了资源门槛。综合来说，DeepSpeed 为大模型训练提供了全方位的优化，包括内存、高速通信、混合并行等，使训练更快、更省内存和更经济。

**Alpa** : Alpa 是由斯坦福等机构开发的分布式训练编译器，旨在自动化并行策略搜索。传统上，确定怎样划分模型、在多少设备上采用何种并行组合，需要人工和经验。而 Alpa 通过在 JAX 框架上实现，将模型的计算图进行分析，自动找到跨算子和算子内部两种层面的并行划分方案，然后生成相应的并行执行计划。它综合考虑数据并行、算子级别的张量并行、以及跨算子的流水线并行，力求找到最优的组合。在 OSDI 2022 发表的论文中，作者展示了只需一行代码即可将单机 JAX 模型转变为分布式模型，Alpa 会自动选择并行策略并部署到给定的 GPU 集群上。例如，对于 GPT-3 175B 这样的模型，Alpa 可以自动决定如何在 8 台 AWS 服务器（每台 8 张 GPU）上划分模型和数据，几乎达到人工优化的性能。Alpa 的意义在于将并行优化从人工技巧转变为自动编译器搜索，使得非系统专家的研究者也能利用大规模计算资源训练超大模型。这对于加速模型开发和探索非常有利。

## 4.3 模型推理与部署优化

训练出一个大模型只是成功的一半，将其高效地部署到实际应用中并提供推理服务，同样需要深入的工程和优化。本节将主要讨论大模型推理阶段（Inference）的特征和瓶颈，并介绍各种优化技术，包括预填充和解码阶段的加速、KV 缓存管理创新、模型量化压缩、稀疏专家模型的推理方案，以及不同部署方案（云端、边缘、本地）的考虑。我们也将结合农业场景给出一些部署案例，如在边缘设备上进行虫情识别、基于气象数据的响应决策等，说明如何权衡性能与资源，实现大模型的落地。

当前，大模型的部署面临主要挑战是在保证准确性的同时尽可能提升推理速度和吞吐。对于用户回复的生成过程，大模型的推理通常分为两个阶段：预填充阶段 (Prefill / Initiation phase) 和解码阶段 (Decode / Generation phase)。预填充阶段是指模型对给定的输入（如提示 prompt）进行一次性前向计算，得到第一个输出 token 的概率分布。这一步需要处理完整的输入序列，其计算开销随着输入长度线性增加。解码阶段则是在得到第一个输出后，模型迭代地产生后续输出 token：每生成一个新 token，就将该 token 附加到输入序列末尾，再次送入模型计算下一个 token，直至完成输出长度或遇到终止符。

在预填充阶段，由于可以并行地计算输入序列中的所有位置，如 Transformer 的自注意力机制允许并行计算 softmax，但整体仍是随长度线性增长的复杂度，因此这个阶段的延迟主要取决于输入长度和模型本身深度。许多应用关注的首次响应延迟 (Time-to-First-Token, TTFT) 就对应预填充阶段的时延。如果用户提供了很

长的 prompt，那么 TTFT 会明显变长，因为模型需要处理完所有提示才能给出第一个回复。解码阶段则往往是逐步进行的，不能像预填充那样完全并行，因为每一步的计算依赖前一步生成的 token。假设需要生成 M 个 token，那么解码阶段总体算力复杂度约为 M 次模型前向，每次输入长度从初始 prompt 开始递增。这意味着总计算量大约与输出长度呈线性关系，组合输入+输出长度看是二次增长。不过，解码过程的并行度有限：即使使用向量化 GPU 计算，一个模型一次只能为一个序列的一个位置生成输出，或者通过批处理同时为多个序列各出一个 token。对于 LLM 服务而言，提高吞吐量通常需要批量并行处理多个请求，但过大的批处理又会提升每个请求的延迟。因此，推理阶段的性能瓶颈经常在于如何在解码过程中兼顾并行度和单步延迟。

大模型解码另一个显著问题是内存和缓存管理。Transformer 为了避免重复计算先前的注意力，会在解码时存储先前步骤的 KV 缓存 (Key-Value Cache)。具体来说，每产生一个新 token，模型都会保存该 token 在每一层注意力中的键和值向量，这些向量在后续解码步骤中用于和新 token 的查询向量计算注意力分数。KV 缓存确保每次解码新步骤时，不必重新计算之前所有 token 的注意力表示，将注意力计算复杂度从每步  $O(n^2)$  降低为  $O(n)$ 。然而，缓存的代价是显存占用迅速增长：每个解码 token 在每层都会产生 Key 和 Value，两者加起来大小约为  $2 \times d_{head}$ （例如  $d_{head} = 128$ ，FP16 则每 token 每头 0.256KB，每层有多头叠加）。累积而言，一个长度 T 的序列在 L 层、H 个注意力头的 Transformer 中的 KV 缓存大小为  $O(L \times H \times d_{head} \times T)$ ，可见与 T（总序列长度）线性增长。在模型和序列较大时，这个缓存会极其庞大。一个实际的例子是 LLaMA-13B 模型，如果序列长度扩展到几千，单条序列的 KV 缓存可能达到接近 2GB 显存开销。当批量内有多条序列时，如多次批量请求时，缓存大小将成倍增加。这使得 GPU 内存很容易因为缓存而告急。传统 Transformer 推理实现对缓存采用预先分配固定大缓冲区或按最大长度申请内存的方式，不仅浪费（因为并非所有请求都用到最大长度），还导致碎片化问题：不同请求缓存大小各异，内存无法连续利用，调查显示常规系统中缓存可能有 60%-80% 的内存被碎片和过量预留浪费。这严重限制了单 GPU 能容纳的批次请求数和序列长度。

针对上述 KV 缓存问题，2023 年的一项突破性工作是来自 UC Berkeley 的 PagedAttention 算法。PagedAttention 受到操作系统分页技术启发，将注意力的 KV 缓存视作“虚拟内存”，采用分页管理来实现灵活的缓存分配和复用。其核心思想包括：让缓存内存以小块 page 为单位管理，消除碎片；允许不同请求共享前缀相同的缓存片段，从而避免重复存储。基于 PagedAttention，作者实现了高吞吐量 LLM 推理系统 vLLM。实验证明，vLLM 在相同硬件上相比现有最快的系统（如 HuggingFace Transformers 或 FasterTransformer）吞吐提升 2-4 倍，且延迟相当。提升在长序列、更大模型和更复杂解码算法场景下更为显著。简而言之，PagedAttention 几乎消除了 KV 缓存的内存浪费，使批处理数量受限于算力而非内存。此外，由于缓存可以跨请求共享，vLLM 能够高效地将有相同前缀的请求合并计算“预填充”部分，然后分别生成后续部分，大幅提高了多请求并行时的 GPU 利用率。在 vLLM 的对比测试中，它相对标准 HuggingFace 推理最高实现了 24 倍的

吞吐量提升。除了 PagedAttention，还有其他方向优化 KV 缓存。例如 KV 压缩：当序列非常长时，早期 token 对后续贡献可能降低，可以考虑压缩较旧的 KV 表示以节省空间（类似于摘要记忆）。有研究提出用低维投影或定期 down-sample 来减小长程上下文的缓存大小。另外，分块计算也是一招：将长序列拆成若干块分别计算注意力，例如每隔一定步长只保留汇总信息，而非所有 token 的 KV。但这些方法通常会牺牲一定准确率。在 batching 方面，许多推理服务器支持动态批处理，即将短时间内到来的多个请求自动组成 batch 执行，以更充分利用 GPU 的并行能力。然而批处理也会引入尾部延迟：如果不同请求长度差异大，短的请求需要等待长的请求结束同一批次计算。为此，有一些策略如“最大解码批次”控制和分组相似长度请求，以折中吞吐与延迟。OpenAI 等服务提供商会对请求做一些内部排队算法来优化这一点。最新有工作 DistServe 提出预填充-解码分离的框架，通过在系统层面将预填充阶段和解码阶段拆分处理，各自批次化，从而兼顾 TTFT 和单 token 吞吐。比如，对于注重实时响应的请求，只批次化预填充部分以尽快给出第一个词，然后再灵活安排解码；对长文本生成则更激进地批处理解码以提高总吞吐。这种思路引入了“Goodput”（满足服务延迟目标的吞吐）指标来替代单纯吞吐衡量系统。总体而言，针对大模型解码，我们看到存算结合的多种优化：通过 PagedAttention 这类方法解决存储效率，通过批处理调度等提高计算效率。随着上下文长度的不断增加（近期模型上下文动辄上万 token），这些优化愈发关键。实际上，最新发布的一些大模型，例如 Claude 2 号称支持 10 万 token 上下文，就非常依赖高效的缓存管理和并行算法，否则推理速度将不可接受。

除了针对密集模型的优化，稀疏模型的推理加速也有所发展。例如 Mixture-of-Experts 模型在推理时每层仅激活少量专家，相比等参数量的稠密模型计算更少，但直接部署会浪费算力于判断路由和等待不同专家返回。近期的 kTransformers 框架针对本地部署的 MoE 模型提出了高效的 top-k 路由机制：它预先将路由计算和通信开销最小化，按需选取最优专家执行，并跳过低概率专家，从而降低延迟。据报道，kTransformers 成功将 2360 亿参数、需要多 GPU 推理的 DeepSeek MoE 模型移植到单机 24GB 显存环境运行，通过 CPU-GPU 异构调度和稀疏计算优化，实现比传统实现快 28 倍的推理速度。这种本地化的稀疏加速技术表明，即使是超大规模的 MoE 模型，也可以通过精心的路由算法和内存管理在较廉价的硬件上实现可用的推理性能。

为了降低推理资源消耗，模型压缩技术在大模型部署中扮演重要角色。量化通过用低精度数值表示模型权重和激活来减小模型尺寸、加快计算。常用方案包括 8 比特定点量化甚至更低至 4 比特。前者在几乎不损失精度的情况下将 Transformer 权重用 8-bit 表示，可将推理显存缩减一半以上。近期业界更探索 4-bit 量化配合微调来弥补精度，例如提出 SmoothQuant[13]、OPTQ 等算法在保留模型精度的同时将权重压缩到 4 比特范围。然而，极端低比特量化（如 2-bit、1-bit）目前仍会导致模型性能大幅退化，需要辅助技术（如量化感知训练、微调校正或蒸馏）来弥补。即使是 4 比特量化也存在挑战：需要定制高效的低精度算子内核，否则运算可能退化为软件模拟而变慢。此外，不同硬件对低精度支持程度不同，例如 NVIDIA Hopper 架构提供了 Transformer Engine 能高效执行 FP8 运算，这为未来更激进的量

化提供了硬件支撑。剪枝是另一种压缩手段，通过移除模型中不重要的权重连接来减小模型规模。在大型 Transformer 中可应用结构化剪枝（如剪掉注意力头或稀疏化前馈层连接）以保持模型结构规则。然而大量非结构化剪枝会造成稀疏矩阵乘法，当前 GPU 对这种不规则计算并不友好，实际加速效果有限。因此剪枝更多用于在许可的性能损失范围内缩小模型规模，然后配合硬件或库（如 SparseTensor 核心）才能看到显著提速。蒸馏则试图训练一个小模型去模仿大模型的输出分布，通过教师指导学生的方式，将大型模型的知识压缩进小模型。蒸馏后的学生模型参数远少于教师，可以大幅提高推理速度，并便于部署在内存受限设备上。在 LLM 场景下，蒸馏需要精心设计训练任务使学生能够在能力上接近教师，例如斯坦福大学的 Alpaca[15]项目利用 GPT-3 产生指令数据来微调 7B 的小模型，从而获得了接近导师能力的模型。在实际部署时，量化和蒸馏也可结合使用——先训练小模型再做低比特量化以进一步压缩。但需要注意的是，过度压缩会牺牲模型生成质量或鲁棒性，因此需要在性能与精度间权衡。总的来说，模型压缩是 LLM 落地的关键手段，可以在较小代价损失下换取数倍的推理效率提升，但如何自动化地找到最佳压缩策略并保证模型可靠性仍是开放研究问题。

高效部署 LLM 还需要在软件层面优化推理计算图和算子实现。算子融合是常用手段，即将原始计算图中序列执行的多个算子合并为一个自定义内核，一次性完成，以减少中间内存读写和调度开销。例如 Transformer 解码器中典型的“矩阵乘+Bias 加法+GeLU 激活”可融合为单个 GPU 内核执行。NVIDIA 的 TensorRT-LLM 库提供了多种针对 Transformer 的优化，包括自定义的多头注意力和 LayerNorm 融合算子等，可以充分利用 GPU Tensor Core 潜力

## 4.4 模型全生命周期管理（MLOps）

大模型从训练到部署并非一劳永逸。模型上线后，需要持续监控其性能，根据新数据不断更新迭代，确保模型始终高效可靠。这就需要借鉴软件工程中的 DevOps 理念，应用于机器学习模型运维，即所谓 MLOps（Machine Learning Operations）。通过完善的 MLOps 流程，团队可以实现模型的持续集成与部署（CI/CD）、严格的版本管理与回滚机制、实时的线上监控报警，以及基于指标的评估和改进。尤其在农业这样的应用中，环境和数据是动态变化的，只有建立模型全生命周期管理，才能让 AI 系统不断学习新知识、纠正错误，在长期运行中保持良好表现。

CI/CD（持续集成/持续部署）是成熟软件开发的实践，强调频繁的小幅更新经过自动化测试后迅速部署上线。对于机器学习模型，同样可以构建这样的流水线。具体而言，当数据和代码有更新时，触发持续集成流程：比如每隔一段时间收集到新的标注数据或模型改进代码，自动启动模型重新训练或微调。训练完成后，在预设的验证集上跑一系列评估测试，包括准确率指标是否达到要求、是否引入新的错误模式等。如果通过测试，就进入持续部署阶段，将新模型发布到运行环境中。部署可以采取灰度发布的形式：先在一小部分实例上运行新模型观察效果，如果指标正常再逐步扩大全量；一旦发现问题则及时中止。CI/CD 流水线应与版本控制系统

集成，每次模型训练产生的工件（模型文件、配置等）都关联到版本记录上，做到可追溯。文献指出，将 CI/CD 理念融入大规模 MLOps 部署，对提高部署效率和可靠性至关重要。例如，Matsui 等提供了 MLOps 实践资源，Ayesha[18]等讨论了 MLOps 在 TensorFlow 项目中的方法和挑战。总的来说，CI/CD 使得模型更新像软件更新一样敏捷可控，对于需要频繁迭代的大模型应用（如不断有新病虫害情况出现，需要模型及时学会），这一路径非常必要。

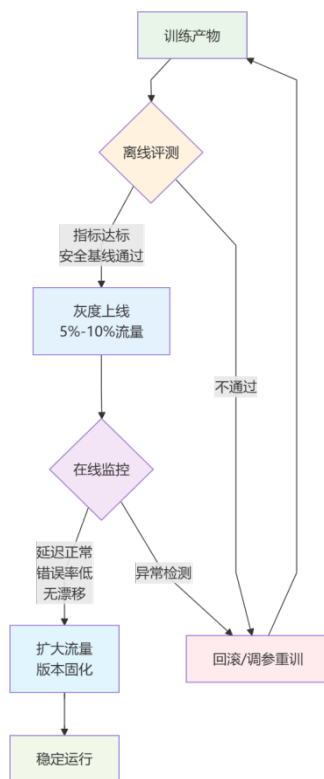


图 4.2: MLOps 质量把控与回滚流程

在持续部署模型时，版本控制和回滚机制是保障系统稳定性的关键。每一个上线的模型都应有唯一的版本号或标识，并与其训练数据、训练配置一起记录存档。这样当出现问题时，可以精准定位使用的是哪一版模型。版本控制还便于比较新旧模型的性能差异，进行 A/B 测试等。例如在农业决策系统中，团队可能尝试用新版模型调整灌溉策略，但会先让旧版模型继续运行作为对照，通过一段时间对比评估新版是否确有提升。自动化回滚是指当新模型上线后如果出现异常（如误报率激增或服务不稳定），系统能够自动恢复使用旧模型。为实现这一点，部署平台通常在加载新模型的同时保留上一版本模型以便随时切换。如果监控指标超出阈值或收到用户大量负面反馈，触发回滚流程将流量切回旧模型，并告警开发人员。由于已保存旧模型版本，回滚速度可以很快，将影响降至最低。这一点在大模型服务中尤为重要——大模型往往行为复杂，稍有改动可能导致未曾料到的问题（例如输出风格变化引起用户不满）。没有回滚机制的话，新模型一旦不适用就会造成持续的业

务损害。实践经验表明，将 CI/CD 与版本控制、回滚相结合，可以显著降低机器学习系统上线变更的风险。比如 Wazir 等研究强调了 MLOps 中模型交付与版本管控的重要性，而一些企业案例也表明，引入自动回滚后，可以大胆尝试更频繁的模式迭代，因为即使出错也有安全网兜底。

模型一旦上线服务，需要对其运行状况和性能进行实时监控。这包括两方面：系统监控和性能监控。系统监控关注模型服务的基础指标，如每秒请求数、平均延迟、99 百分位延迟、GPU/CPU 利用率、显存占用、错误率等。对于大模型部署，这些指标关系到服务质量的 SLO (Service Level Objective)，如前述 TTFT 和单 token 延迟 TPOT 是否在要求范围内。如果某段时间延迟升高，可能表示流量突增或硬件故障，需要及时扩容或检修。性能监控则侧重模型决策的准确性和合理性。在生产环境通常没有直接的标签来衡量模型准确率，但可以通过代理指标和异常检测来评估。例如，监控模型输出的分布是否发生漂移 (data drift)：假如某农作物识别模型，突然输出“未知病害”的比例大增，可能意味出现了训练集中没有的新病害种类。又如一个农情对话 LLM，某段时间用户评价分急剧下降，提示模型可能在新出现的问题上表现不佳。配置恰当的监控逻辑可以捕捉到这些现象。当模型偏离预期行为时，触发警报并进入干预流程（如启动模型重训或回滚）。评估指标在部署阶段也需要持续计算。除了精度类指标（准确率、F1 等）在离线评估，新数据下还关注业务指标。以农业 AI 系统为例，业务指标可以是节水率（灌溉模型优化带来的节水百分比）、减损率（病虫害早发现减少的损失）等。这些需要长周期跟踪评估，但对于证明模型价值很重要。此外还有公平性和稳健性指标：模型是否对某些作物/地域系统性偏差？对异常输入是否鲁棒？现代 MLOps 强调加入对模型伦理和可靠性的监控。例如，在 LLMops 实践中，有观点提出上线监控应包括对不良输出的检测频率、审查对抗性输入的表现等。在农业场景，也许要监控模型是否一直忽略某些小农场传感器数据（数据偏差）或者在极端天气下预测失准（稳健性问题）。为实现这些，通常会建立日志和反馈系统。所有模型请求输入和输出（或摘要）将记录日志，并定期抽样由人工或辅助脚本检查。这不仅提供模型失误案例用于分析，还可产出新的标注数据来强化模型（见 4.4 节）。许多 MLOps 框架（如 Prometheus 配合 Grafana、ELK 栈等）已经可以方便地收集指标并触发警报。重要的是，将模型性能的监控纳入整体运维文化中，像监控服务器 CPU、内存一样对待模型预测质量。只有这样，模型出了问题才能第一时间发现并干预，避免对业务造成严重影响。

机器学习模型的生命力在于持续学习。部署后的模型会遇到训练时未见过的新情况，此时数据反馈机制就显得尤为重要。所谓数据反馈，即将线上收集到的新数据（包括模型错误案例、用户新提出的问题、环境变化导致的数据分布变化等）反馈回模型研发流程，不断提升模型能力。实现数据反馈的第一步是获取有标签的反馈数据。在一些产品中，这通过用户交互来完成：比如农户对 AI 诊断给出“正确/错误”评价，或者在模型未识别出的问题上自行标注病虫害类别。另一些情况下，需要专家定期审核模型输出，整理出错误和遗漏并标注真值。例如，某虫害识别模型上线后，专家发现模型对新出现的“水稻细条病”识别不出来，那么收集若干该病害图片标注好，加入训练集。社区近年流行的人类反馈强化学习 (RLHF) 也是类

似思路，让人对模型输出质量打分，转化为奖励信号用于优化模型。但对很多垂直领域应用来说，简单的监督再训练已足够。有了新标签数据，可采用持续学习或定期再训练的方式更新模型。持续学习是指模型以一定频率（如每天/每周）在新数据上追加训练（或微调），使其逐步适应环境变化。这要求设置机制防止“灾难性遗忘”，即在学习新知识时性能在旧知识上不下降。一种做法是每次用新数据微调模型前，保留一部分旧训练数据混合作为稳固模型基础的回放。另一种是训练增量模块而非动原模型权重，如用知识蒸馏把新旧模型融合。定期再训练则是更彻底的做法：累积一段时间的数据后，用新老数据全集重新训练模型一轮。这在数据增长较慢时适用，比如农业每年新增的数据不算太多，可以一年一更新模型。MLOps 流程可以对此高度自动化。比如，当监控发现模型精度下降到某阈值或定期到了训练窗口，自动触发再训练流水线：准备包含新数据的训练集、运行训练作业、评估测试通过后部署新模型。

在这个过程中，人类专家仍然发挥重要作用，即人在回路（Human in the Loop）。他们负责标注和审核数据、设定评估准则、决定何时正式推出更新等。实践经验显示，人机结合的持续改进能显著提升模型长期表现，同时避免模型朝错误方向学偏。例如，有研究在 LLMOps 中强调引入人工反馈回路到 CI/CD 管道可提高质量和可靠性。以农业 AI 系统为例，可以这样构建闭环：假设有一个作物病虫害诊断大模型在手机 App 上供农民使用。每天模型会处理上千张作物照片，系统记录下模型的诊断以及农民对诊断结果的反馈（如果农民纠正了诊断，系统就获得了宝贵的新标签）。这些数据汇总后，每月由农技专家复核，形成新增标注数据集。然后研发团队启动模型微调，用这些数据对模型进一步训练，使其认识新出现的病虫害和纠正过去经常出错的地方。微调后的模型经过测试集验证准确率提升 5 个百分点且没有新的明显偏差，于是通过 CI/CD 流水线部署替换旧版本。这一过程中，如果新模型出现问题，还有随时回滚机制保障。在下一个月，循环往复。通过这样的持续学习，模型相当于在“在线进化”，能够适应不同季节、不同地域的新挑战。除了性能改进，MLOps 的全流程管理还能考虑能效优化和资源调度。例如在非高峰时段动态减少加载模型副本节省能源，在重要农时季节临时增加算力保证服务稳定，等等。这些属于更广义的运维优化，也是模型生命周期的一部分。综上，模型全生命周期管理旨在将模型从开发、部署一直管到运营、反馈，形成一个闭环不断优化过程。对于大模型，这种管理尤为重要：模型复杂度高、潜在风险大，只有借助 MLOps 工具和理念，才能让其在现实场景中发挥持久价值而不是昙花一现。从持续集成部署保障快速迭代，到版本控制和监控保障可靠运行，再到反馈再训练保障与时俱进，这些环节共同构成了大模型应用的生命线。

## 第 4 章参考文献

- [1] Nicholas Carlini et al. “Extracting training data from large language models”. In: 30th USENIX security symposium (USENIX Security 21). 2021, pp. 2633–2650.

- [2] Colin Raffel et al. “Exploring the limits of transfer learning with a unified text-to-text transformer”. In: *Journal of machine learning research* 21.140 (2020), pp. 1–67.
- [3] Martin Gerlach and Francesc Font-Clos. “A standardized Project Gutenberg corpus for statistical analysis of natural language and quantitative linguistics”. In: *Entropy* 22.1 (2020), p. 126.
- [4] Yukun Zhu et al. “Aligning books and movies: Towards story-like visual explanations by watching movies and reading books”. In: *Proceedings of the IEEE international conference on computer vision*. 2015, pp. 19–27.
- [5] Christoph Schuhmann et al. “Laion-5b: An open large-scale dataset for training next generation image-text models”. In: *Advances in neural information processing systems* 35 (2022), pp. 25278–25294.
- [6] Ethan Perez et al. “Red teaming language models with language models”. In: *arXiv preprint arXiv:2202.03286* (2022).
- [7] Rico Sennrich, Barry Haddow, and Alexandra Birch. “Neural machine translation of rare words with subword units”. In: *arXiv preprint arXiv:1508.07909* (2015).
- [8] Taku Kudo and John Richardson. “Sentencepiece: A simple and language independent subword tokenizer and detokenizer for neural text processing”. In: *arXiv preprint arXiv:1808.06226* (2018).
- [9] Mu Li et al. “Communication efficient distributed machine learning with the parameter server”. In: *Advances in neural information processing systems* 27 (2014).
- [10] Shenggui Li et al. “Colossal-ai: A unified deep learning system for large-scale parallel training”. In: *Proceedings of the 52nd International Conference on Parallel Processing*. 2023, pp. 766–775.
- [11] Lianmin Zheng et al. “Alpa: Automating inter-and {Intra-Operator} parallelism for distributed deep learning”. In: *16th USENIX Symposium on Operating Systems Design and Implementation (OSDI 22)*. 2022, pp. 559–578.
- [12] Woosuk Kwon et al. “Efficient memory management for large language model serving with pagedattention”. In: *Proceedings of the 29th Symposium on Operating Systems Principles*. 2023, pp. 611–626.
- [13] Guangxuan Xiao et al. “Smoothquant: Accurate and efficient post-training quantization for large language models”. In: *International Conference on Machine Learning*. PMLR. 2023, pp. 38087–38099.
- [14] Elias Frantar et al. “OPTQ: Accurate post-training quantization for generative pretrained transformers”. In: *11th International Conference on Learning Representations*. 2023.

- [15] Rohan Taori et al. “Alpaca: A strong, replicable instruction-following model”. In: Stanford Center for Research on Foundation Models. <https://crfm.stanford.edu/2023/03/13/alpaca.html> 3.6 (2023), p. 7.
- [16] David Sculley et al. “Hidden technical debt in machine learning systems”. In: *Advances in neural information processing systems* 28 (2015).
- [17] Dominik Kreuzberger, Niklas Kühl, and Sebastian Hirschl. “Machine learning operations (mlops): Overview, definition, and architecture”. In: *IEEE access* 11 (2023), pp. 31866–31879.
- [18] Saurabh Pahune and Zahid Akhtar. “Transitioning from MLOps to LLMOps: Navigating the Unique Challenges of Large Language Models”. In: *Information* 16.2 (2025), p. 87

## 5.多模态大模型：概念与应用

在当下，人工智能技术的迅猛发展已不仅限于处理单一模态的数据——仅仅从文本或仅仅从图像中进行模式识别的时代已经过去。在农业领域，这种单一维度的技术应用面临的数据源极其丰富而又高度异构：遥感卫星和无人机航拍产生的高精度图像，地面传感器所采集的土壤水分、温度与湿度数据，农艺师在田间记录的文本笔记，以及政府和科研机构发布的农业政策与技术手册等。这些多模态信息蕴含了作物生长状态、病虫害演变、环境变化以及市场需求的全方位视角，然而如何将它们进行有效整合，进而从中挖掘高价值的决策依据，成为制约智慧农业应用落地的核心难题之一。正是在这样的背景下，“多模态大模型”（Multi-Modal Large Models）应运而生，本章将聚焦其在农业场景中的概念框架与应用实践，帮助读者深入理解多模态技术如何搭建从数据感知到决策支持的智能化闭环。

需要认识到农业生产过程本身具有天然的多模态特征。一块农田内，一张高分辨率的遥感图像可以直观反映作物冠层覆盖度与土壤湿润度，而对应的地面传感器则能以分钟级频率精确监测温湿度、土壤成分以及养分含量等微观数据；与此同时，农艺师在田间巡查时所记录的病虫害样本描述和防治措施说明，往往以文本形式蕴含大量经验性知识；市场端，农产品价格走势、供应链节点状态与市场需求预测同样以文字与表格形式存在。这些信息在采集形式、时空尺度和数据结构上存在显著差异，若仅依赖单一模型进行处理，往往只能得到片面或局部有效的分析结果，而无法全面呈现农业生产生态的动态变化。因此，多模态大模型所追求的，就是跨越不同数据类型和语义空间的壁垒，将图像、时序数据与文本知识在一个统一的深度学习框架内进行融合，形成既能保留各自模态特征，又可在更高层次上产生协同增益的智能系统。

跨模态融合的核心并非简单地将图像和文本“拼接”在一起，而是要在模型内部设计多层次的互补机制。一方面，视觉模态的信息（如遥感影像中作物的长势、病斑范围、田间杂草分布等）提供了宏观、整体的空间感知；另一方面，文本或结构化数据（如土壤检测报告、历史产量记录、农机设备运行日志）则传递了微观、精细的属性与逻辑关系。要将二者有效结合，就需要模型具备以下能力：第一，将图像特征与文本特征映射到同一语义空间，使得“图像中的绿色植被指数”与“土壤氮含量”这类不同类别的数值能够在高维向量空间中进行关联分析；第二，能够自动在多层级上学习其中的映射关系，比如通过自监督学习或对比学习，让图像与文本描述形成“对齐对”——即模型知道某段遥感图像对应的是“早稻生长期第六周，叶片呈现黄绿色斑点”，从而在提取到新的图像或文本时能够自动识别其语义关联；第三，在推理和决策阶段，具备根据具体任务动态调用不同模态信息的能力，比如在推荐灌溉方案时，不仅要考虑图像中水分不足区域的位置，还要综合传感器显示的土壤湿度曲线、气象预测文本以及历史产量数据，最终生成综合性、个性化的农业建议。

多模态大模型在农业应用中还需要关注自然语言与领域知识融合的深度。当下许多农业技术文档与研究论文都以文字形式存在，其中蕴含了大量关于作物品种、病虫害防治、农机操作和政策导向的专业术语与策略。但是，如果没有一个强大的语言理解机制，模型就难以从冗长的文本中提炼关键信息，更难以将这些信息与遥感图像或传感器数据中的时空特征结合起来。例如，在一个病虫害早期预警系统中，单纯依靠图像分析只能检测到叶片上的斑点，但无法判断该病斑是侵染自哪种病菌，也无法通过文学报告中关于季节性流行病的描述进行早期预警。通过多模态大模型，农业专家能够将遥感检测到的叶片斑点与文本知识库中关于不同病害的描述进行匹配，从而提高诊断准确率并生成针对性防治建议。这种“图像—文本—知识库”多层次协同，就需要依托预训练大模型的语言理解与知识迁移能力，将“领域文本”与“图像特征”对齐，在推理时自动调用所需的知识片段。

多模态大模型在实现农业应用的过程中，还必须克服现实环境中对算力与资源的巨大压力。农业数据量巨大且更新频率高，尤其是无人机与卫星遥感产生的高分辨率图像往往以每周、甚至每日级别进行采集，如果要在云端对数以万计的遥感图像和数百万条地面传感器数据进行实时分析，就需要超大规模的分布式训练和推理集群。此外，田间环境经常出现网络不稳定、算力受限的情况，在边缘侧部署大模型时，需要优先考虑模型压缩、剪枝与蒸馏技术，以减小模型参数量并兼顾推理速度。合适的做法是在云端进行大模型预训练与微调，再将压缩后的轻量化模型下发到边缘设备或便携式终端，实现“云—边协同”的推理部署；同时，设计基于增量更新与在线学习的算法，使模型能够在本地根据最新采集的数据进行微调，进一步提高对新场景的适应性与鲁棒性。

在工程实践层面，多模态大模型也需要紧密结合具体场景需求，设计“可评估、可监控、可审计”的 MLOps 全流程。农业应用场景常常伴随着数据漂移与概念漂移——例如在旱季与雨季之间，作物长势与病虫害类型的分布会发生显著变化；不同区域的土壤类型与气候条件也会导致模型表现出现差异。要在此种环境中保持模型性能，就需要构建一套从“数据采集—模型训练—推理部署—在线监控—模型迭代”闭环：在数据采集阶段，设计自动化的数据清洗与标注流水线；在模型训练阶段，结合分布式训练集群与混合精度计算，实现高效预训练与多模态融合；在推理部署阶段，采用微服务架构与容器化技术，实现模型的弹性伸缩与跨场景适配；在在线监控阶段，通过预设监控指标（如模型置信度、推理时延、反馈满意度等）设立阈值预警，及时发现性能衰退与偏差；在模型迭代阶段，以微调与增量学习为主线，将新的标注数据与用户反馈纳入训练集，定期对模型进行更新与优化。这种 MLOps 思路不仅适用于多模态大模型在农业生产流程中的持续优化，也为未来跨模态、跨场景的智能农业服务提供了可复制的工程方法论。

本章的核心结构将分为以下部分：

- 农业多模态数据需求：首先从数据类型和数据特点入手，全面介绍农业场景下图像、文本、语音与传感器数据的收集渠道与预处理要点，并阐释多模态信息融合的难度与潜在价值，以及典型应用场景（如病虫害识别、产量预测、缺水预警等）；

- 多模态大模型的结构与训练策略：在介绍图文匹配（如 CLIP 等）与图像 Caption、语音识别与 NLP 融合技术基础后，深入分析自监督与多任务训练在多模态领域的实践方法，并结合农业场景，说明如何将语言模型借助视觉与语音信息进行认知增强；
- 多模态在农业的案例与展望：通过作物长势监测、农业专家系统和实时诊断等典型案例，展示多模态大模型与传感网络、农机装备联动的思路，并探讨它与数字孪生、虚拟仿真等前沿技术结合的可能性，为未来智慧农业的发展提供多维视角的启发。

本章的目标不仅是阐明多模态大模型的技术原理，更要通过具体的农业应用案例，将抽象技术转化为实际可操作的工程方案。我们强调以下几点：第一，多模态数据的预处理与对齐是实现模型性能提升的第一道“关口”，需要在语义层面与时序层面双向保证各个模态数据的可用性与准确性；第二，多模态模型训练需关注“任务设计”与“损失函数构建”，以确保视觉与语言特征能够在同一空间内进行有效融合；第三，合理选择工具链与平台，不同团队可根据自身资源与场景特点设定端到端的开发框架；第四，在实战过程中，需要对典型案例进行横向与纵向对比实验，通过定量指标与用户反馈相结合的方式，验证多模态模型相对于单模态模型在农业任务中的优势与边界。通过上述思路的引导，读者能够在后续章节中更有效地掌握多模态大模型在农业场景下的设计思路、技术实现与应用效果，为智能农业的发展贡献可落地的技术方案与实践经验。

## 5.1 多模态大模型的发展历史

人工智能发展初期，研究通常围绕单一模态的数据展开，如自然语言处理（Natural Language Processing, NLP）领域主要关注文本数据，而计算机视觉领域则专注于图像或视频的分析。这些单模态模型各自在其领域取得了一定的成功，但其局限性也逐渐显现。举例而言，传统的视觉模型（如卷积神经网络，CNN）虽然可以准确识别图像中的物体，但无法描述物体的属性与状态；而文本模型（一般使用循环神经网络 RNN，如长短期记忆网络（Long Short-Term Memory, LSTM）则在描述性理解上有所欠缺，无法直接与视觉感知交互。这些局限促使研究者开始尝试多模态信息的融合，试图通过结合文本和视觉优势，提升 AI 系统对现实世界更全面的理解能力。而随着现实应用需求的增长，探究将文本与图像等任务进行结合，使得模型能够处理数据异构任务，成为重点的研究方向之一。

2015 年前后出现的图像描述（Image Captioning）[4]和视觉问答（Vision Question Answer, VQA）任务，是多模态模型发展的重要节点，前者侧重于使用语言在多个角度描述图像，后者则需要结合图像及用户回复给出文本答案。早期的解决方案通常是将预训练的 CNN 提取出的图像特征与文本 RNN 的隐藏状态简单拼接或通过注意力机制融合进行的。早期的图像描述模型通常采用“编码器-解码器”架构，数学上可表示为：

$$p(y|I) = \prod_{t=1}^T p(y_t|y_{<t}, \phi(I))$$

其中 $I$ 是输入图像， $\phi(I)$ 是通过 CNN 提取的图像特征， $y$ 是生成的文本序列。解码器通常是 LSTM，每一步的预测概率为：

$$p(y_t|y_{<t}, \phi(I)) = \text{softmax}(W_o h_t + b_o)$$

其中 $h_t$ 是 LSTM 的隐藏状态。视觉问答模型则需要考虑图像 $I$ 和问题 $q$ 的联合表示：

$$\hat{a} = \underset{a}{\operatorname{argmax}} p(a|I, q)$$

一些代表性工作包括 Vinyals 等在 2015 年提出的 Show and Tell 模型，该模型采用经典的 CNN-RNN 编码-解码结构，将图像特征编码为一个向量后输入 LSTM，生成与图像内容相符的文本描述。这一方法在 MS COCO Caption 数据集上实现了优异的性能，成为视觉语言融合研究的开端。此外，Antol 等提出了 VQA 数据集和基准测试任务，要求模型根据图像和自然语言问题生成答案。这类任务天然具备跨模态理解与推理需求，促进了视觉与语言共同建模方法的发展。早期模型多采用将图像 CNN 特征与文本嵌入拼接，或通过注意力机制引导信息交互，但整体仍较为浅层。这些尝试开启了多模态学习的序幕。

2018 年开始，随着 Transformer 架构的出现，促进了 BERT (Bidirectional Encoder Representations from Transformers) 为代表的较大规模的语言模型模型的出现。研究者尝试引入类似的预训练思路到多模态领域，涌现了一批视觉-语言预训练模型。例如，2019 年的 ViLBERT 和 VisualBERT 模型采用了“双流”架构：图像通过预训练 CNN 获取区域特征，文本则通过 BERT 进行编码，然后在高层通过交叉注意力机制融合，从而在下游任务（如 VQA、跨模态检索）上取得优异表现。同年出现的 LXMERT、UNITER 等模型在此基础上进一步改进对齐方式和预训练任务，如 UNITER 进一步引入了跨模态的掩码语言建模，促进了雏形多模态文本生成模型的出现。

进一步的，ViT (Vision Transformer) 模型将 Transformer 架构引入图像领域，打破了传统上认为自注意力机制难以应用于图像处理的观念。传统的卷积神经网络 (CNN) 通过局部感受野和权重共享处理图像，而 ViT 采用了完全不同的方法。ViT 中的图像被划分为固定大小的块 (patches) 并进行处理。对于输入图像  $x \in \mathbb{R}^{H \times W \times C}$ ，ViT 首先将其重塑为  $N$  个展平的 2D 块  $x_p \in \mathbb{R}^{N \times (P^2 \cdot C)}$ ，其中  $(P, P)$  是每个块的分辨率， $N = HW/P^2$  是块的数量。这些块通过可学习的线性投影映射到潜在维度  $D$ ：

$$z_0 = [x_{\text{class}}; x_p^1 E; x_p^2 E; \dots; x_p^N E] + E_{\text{pos}}$$

其中  $E \in \mathbb{R}^{(P^2 \cdot C) \times D}$  是块嵌入投影， $E_{\text{pos}} \in \mathbb{R}^{(N+1) \times D}$  是位置嵌入， $x_{\text{class}}$  是特殊的分类 token。然后，通过  $L$  个 Transformer 编码器层处理这些嵌入：

$$z'_l = \text{MSA}(\text{LN}(z_{l-1})) + z_{l-1}$$

$$z_l = \text{MLP}(\text{LN}(z'_l)) + z'_l$$

其中 MSA 是多头自注意力，LN 是层归一化，MLP 是多层感知器。ViT 展现了纯 Transformer 架构在处理多模态数据上的潜力，使得在同一架构下处理文本、图像等不同模态的数据成为可能。这一突破很快被应用到多模态任务中，为多模态模型的发展铺平了道路。

2021 年由 Kim 等人提出的 ViLT (Vision-and-Language Transformer) 模型是多模态 Transformer 的一次重大尝试。ViLT 直接将图像划分为 patch 并通过线性投影与位置编码后，与文本 token 一起输入同一个 Transformer 进行联合建模。ViLT 在多模态领域使用统一的单塔模型框架，通过舍弃 CNN 与区域提取器，显著减少了模型参数和计算开销，在 VQA 和 图像文本召回 (Image-Text Retrieval) 等任务中实现了与双流模型相当的性能，极大提升了效率。ViLT 引发了后续一系列“纯 Transformer 融合”架构的思考，即能否在不依赖额外视觉特征提取器的情况下实现高效而强大的图文建模能力。

跨模态对比学习成为多模态模型发展的另一个里程碑，这一方式通过使用正负样例的方式进行大规模的自监督学习，将多模态任务朝泛化的方向进行演进，其中的代表是 OpenAI 在 2021 年提出的 CLIP 模型通过对比学习将图像和文本映射到同一向量空间。CLIP 包含图像编码器  $f_I$  和文本编码器  $f_T$ ，目标是最大化匹配图文对的余弦相似度，最小化不匹配对的相似度。形式上，对于一批包含  $N$  个图文对  $(i_n, t_n)$ ，CLIP 的对比损失函数可以表示为：

$$\mathcal{L}_{\text{CLIP}} = -\frac{1}{2N} \sum_{n=1}^N \left[ \log \frac{\exp(\text{sim}(f_I(i_n), f_T(t_n))/\tau)}{\sum_{m=1}^N \exp(\text{sim}(f_I(i_n), f_T(t_m))/\tau)} \right. \\ \left. + \log \frac{\exp(\text{sim}(f_I(i_n), f_T(t_n))/\tau)}{\sum_{m=1}^N \exp(\text{sim}(f_I(i_m), f_T(t_n))/\tau)} \right]$$

其中  $\text{sim}(a, b) = a^T b / (\|a\| \|b\|)$  是余弦相似度， $\tau$  是温度参数。这种对称的对比损失确保了图像到文本和文本到图像的双向映射。CLIP 在 4 亿对图文数据上训练，只需给出对应的类别名称文本，不经过额外训练的情况下即可完成文本分类任务，在多个图像分类数据集上达到了高准确度，展示了惊人的通用化零样本识别能力，是多模态图像-文本融合的一大突破。受 CLIP 启发，其他的文本-图像跨模态模型也相继被研发出来，如 Google ALIGN 进一步把数据规模提升到十亿级，在进一步提升模型能力的同时验证了即使在嘈杂网页语料中对比学习同样有效，验证了巩固了“图文双塔对齐配合线性探针”的这一工业范式。

此外，同一时期，纯 Transformer 模型也开始从多模态对比学习向多模态融合的方向继续发展。ALBEF (Align Before Fuse) 模型是多模态 Transformer 模型的一大突破，其创新性的引入了多种模型结构与训练方式，首先使用对比学习的方式进行图文的粗略对齐，再使用动量更新 (Momentum Update) 的方式，使用模型蒸馏的方式，将模型内部的多个子结构训练出教师模型，减轻网络数据噪声对模型的性

能影响，引导主模型进行图文深度融合。ALBEF 模型的动量蒸馏使用在线编码器（online encoder） $f_\theta$ 和动量编码器（momentum encoder） $f_\xi$ 。动量编码器参数通过指数滑动平均更新：

$$\xi \leftarrow m\xi + (1 - m)\theta$$

其中 $m$ 是动量系数。ALBEF 的损失函数包括图文对比损失 $\mathcal{L}_{ITC}$ 、图文匹配损失 $\mathcal{L}_{ITM}$ 和掩码语言建模损失 $\mathcal{L}_{MLM}$ ：

$$\mathcal{L} = \lambda_{ITC}\mathcal{L}_{ITC} + \lambda_{ITM}\mathcal{L}_{ITM} + \lambda_{MLM}\mathcal{L}_{MLM}$$

其中 $\lambda$ 是各损失项的权重。ALBEF 改进了 CLIP 在下游任务泛化性能不足的问题，并提供了一种对比先行、融合精炼的两阶段范式。此外，由微软提出的 VLMo（Unified Vision-Language Pre-Training with Mixture-of-Modality-Experts）模型进一步将对齐与融合编码器统一到一个架构中。VLMo 使用统一的 Transformer 模型基本架构，同时引入 MoE（Mixture of Experts）门控机制，根据输入模态选择不同专家子网络，使模型可以灵活适配纯图像、纯文本和图文对输入，同时兼容 CLIP 和 UNITER 的优点。

2022 年开始，以 GPT-3.5 为代表的大语言模型（LLMs）以其通用的文本生成及通用文本对话能力，取得了 AI 领域的广泛关注，研究学者开始考虑如何将图像引入通用的文本生成任务中，做到能够遵照用户指令执行通用的图文问答任务。

BLIP（Bootstrapping Language-Image Pretraining）由 Salesforce Research 于 2022 年提出，是一种将视觉理解与语言生成任务统一框架建模的典范。其提出了一种三阶段预训练机制：1. Caption Bootstrapping（字幕增广），利用图像生成伪文本描述，缓解网络数据中的标注缺失问题；2. Vision-Language Pretraining（VLP，视觉文本预训练）：使用多任务目标，包括图文匹配（ITM）、图文对比（ITC）、掩码语言建模（MLM）；3. Vision-to-Language Generation（图生文）：通过图像生成文本，强化语言建模能力。BLIP 在视觉问答、图像描述与跨模态检索任务中均实现了大幅领先。其引入的 ITM/ITC 联合训练策略使得图文对齐更加稳健。而基于生成式解码器的设计，包括上述的训练范式，也为后续多个多模态大模型所沿用和发展。

同时，直接将现有的大模型引入模型，也逐渐成为研究重点之一。Flamingo 是 DeepMind 于 2022 年提出的多模态少样本学习模型，其引入了冻结的 LLM 模型作为文本生成的基础模型，依靠 Perceiver Resampler 的长序列建模，在中间层引入跨模态门注意力层来用于文本与图像 token 的交叉信息流动。假设从视觉骨干网络提取的特征为  $V \in \mathbb{R}^{N_v \times d_v}$ ，Perceiver Resampler 将其转换为固定长度的表示  $R \in \mathbb{R}^{N_r \times d_r}$ ：

$$R = \text{PerceiverResampler}(V) = \text{Transformer}(Q, K = V, V = V)$$

其中  $Q \in \mathbb{R}^{N_r \times d_q}$  是可学习的查询嵌入。跨模态门控注意力（Gated Cross-Attention）层则将视觉信息注入到语言模型中：

$$\begin{aligned}\tilde{h} &= \text{SelfAttention}(h) \\ g &= \sigma(W_g \tilde{h} + b_g) \\ \hat{h} &= \tilde{h} + g \odot \text{CrossAttention}(\tilde{h}, R)\end{aligned}$$

其中 $h$ 是语言模型的隐藏状态， $g$ 是门控因子， $\sigma$ 是 sigmoid 函数。Flamingo 支持处理图文交错的上下文输入，具备强大的视觉对话、说明解释、跨图理解等能力。而最令人瞩目的，是其极强的少样本学习（Few Shot Learning）能力，仅用少量样例即可完成复杂多模态任务。2023 年初推出的 BLIP-2 模型进一步将多模态预训练的效率推向极致，同时引用了预先训练的 LLM 模型以及 ViT 模型，将模型参数量扩充到十亿级别的同时，通过少量训练即可训练出具有通用图像对话能力的模型。其主要结构包括来自 Clip 模型的图像编码器，以及大语言模型（如 Flan-T5 XXL 或 GPT-J）作为语言生成器，二者之间引入少量的 Querying Transformer (Q-Former) 模块作为中介，在训练时仅微调中介模块而冻结其他结构。这一结构使得 BLIP-2 能够高效衔接两种强大的单模态模型，仅需训练少量参数即可获得远超传统模型的多模态生成能力，极大降低了资源要求与训练门槛。BLIP-2 在视觉问答（VQA）、图像推理（OK-VQA）、图文生成等多个基准上达到了当时最优性能。

进入 2023 年，多模态大语言模型（Multimodal Large Language Model, MLLM）成为研究热点。OpenAI 发布的 GPT-4 即是一种大型多模态模型：它不仅具有强大的文本生成和理解能力，还能接收图像输入，实现图文结合的推理。GPT-4 的图像理解能力（常称为 GPT-4V）展现了许多新兴能力，包括图像问答、图像分析与细节识别，不通过 OCR 模块而直接理解理解图像中的文字,将图像嵌入文本推理链条中（例如数学题），以及多轮图文对话，具备长上下文图文交叉对齐能力。这类能力在传统多模态模型中十分罕见，显示出通用人工智能的潜力，其继承者 GPT-4o 至今也是多模态大模型性能与功能的高峰，成为业界的参照标准。此外，需要特别提到的是谷歌在 2023 年底发布的 Gemini 模型。作为首个真正意义上大规模从零开始原生地构建的多模态模型，Gemini 在预训练阶段就同时加入了文本、代码、图像、音频、视频等多模态数据，在 30 项多模态基准上达到 SOTA 性能，体现了多模态模型向更大规模、更高融合度发展的趋势。

此外，随着开源 LLM 的发展，研究者开源了诸多 GPT-4 风格的多模态模型，例如 LLaVA、MiniGPT-4、Otter 等，它们常通过将视觉编码器（如 CLIP 的 ViT 模型）输出接入预训练语言模型，并在指令数据上微调，实现对图像的对话式理解。这样的多模态大语言模型，其通常采用投影层将视觉特征映射到语言模型的嵌入空间。假设视觉编码器输出为 $v \in \mathbb{R}^{d_v}$ ，投影层可以表示为：

$$v' = W_2 \cdot \text{ReLU}(W_1 v + b_1) + b_2$$

其中 $W_1 \in \mathbb{R}^{d_h \times d_v}$ ， $W_2 \in \mathbb{R}^{d_t \times d_h}$ ， $d_h$ 是隐藏维度， $d_t$ 是语言模型的 token 嵌入维度。这些视觉特征作为前缀 tokens 添加到文本输入之前：

$$h = \text{LLM}([v'; t])$$

其中 $t$ 是文本输入的嵌入， $h$ 是语言模型的输出。

LLaVA (Large Language and Vision Assistant) 由 UC Berkeley 等机构提出, 其架构包含视觉编码器 (CLIP ViT-L/14)、映射层 (2 层 MLP) 将图像特征对齐至语言 token 维度、以及 LLM 后端 (Vicuna-7B/13B) 进行对话生成通过在生成式图文对话数据 (如来自 COCO 的自动问答样例) 上进行指令微调, LLaVA 成为首批支持复杂图像对话、图像细节问答与步进推理的开源 MLLM 模型。MiniGPT 4 的思路更加极简, 仅使用一层线性映射将图像特征接入 Vicuna[25]模型。它展示了在网页图像理解、复杂图文交互等任务上的潜力。Otter 在 Flamingo 风格结构的基础上加入 In-Context Learning 能力与语义强化训练, 强调多轮对话一致性和上下文保持, 是另一种典型的多模态开源方向。这些开源工作推动了 MLLM 在社区中的快速复制与创新, 形成了高度活跃的生态系统。

总的来看, 多模态大模型的发展经历了从单模态独立到双模态融合, 再到如今多模态统一的演进。早期尝试为视觉和语言搭建桥梁, 随后涌现了基于大数据对比学习的跨模态对齐模型, 以及将预训练语言模型扩展到视觉领域的生成式模型。进入当前阶段, 跨模态模型的能力边界不断被突破: 不仅模态种类从图文扩展到音频、视频, 模型规模也达到百亿甚至千亿参数级。同时, 多模态模型正逐步具备推理、对话等更复杂的认知能力。这一历程为多模态技术在各行各业的应用奠定了基础, 农业正是受益的领域之一。

## 5.2 多模态大模型的结构与训练

### 5.2.1 多模态大模型的模态融合

多模态大模型在技术上需要首先攻克的难题之一, 是如何有效的融合不同模态的模型信息。根据融合发生的模型位置, 多模态融合架构可以分为早期融合 (Early Fusion)、晚期融合 (Late Fusion) 和混合融合 (Hybrid Fusion) 三种主要范式。早期融合是指在特征提取的早期阶段就将不同模态的原始数据或低级特征进行整合。例如, 对于图像和文本的融合, 可以将图像的像素信息与文本的字符序列直接拼接后输入单一编码器进行联合处理。这种方法的数学表达式可以简单表示为:

$$h = f_{\theta}([x_v; x_t])$$

其中  $x_v$  和  $x_t$  分别表示视觉和文本的输入特征,  $[\cdot]$  表示拼接操作,  $f_{\theta}$  是共享的特征提取器。早期融合的优势在于其信息丰富度较高, 能够捕捉模态间的低级交互, 但面临的主要挑战是不同模态数据的统计特性差异较大, 可能导致训练不稳定, 所以比较适合数据量有限且算力要求较小的场景。

晚期融合则采用模态特定的编码器分别处理各模态数据, 在模型的末端得到高级特征后再进行融合。典型代表如 CLIP 模型使用独立的图像编码器和文本编码器, 分别提取模态特征后通过内积计算相似度。晚期融合的数学表示为:

$$h_v = f_v(x_v), \quad h_t = f_t(x_t), \quad h = g([h_v; h_t])$$

其中  $f_v$  和  $f_t$  分别是视觉和文本编码器,  $g$  是融合函数。晚期融合架构允许各个模态采用专门的特征提取器, 但因为特征会被逐步压缩, 尤其对于图像来讲, 可能错过

模态间的早期交互信息，混合融合则结合了早期和晚期融合的优点，在多个层次上进行跨模态交互。例如 ALBEF 模型首先使用模态特定编码器获取初步特征，然后通过多层的交叉注意力机制实现深度融合。混合融合可以表示为：

$$h_v^{(0)} = f_v(x_v), \quad h_t^{(0)} = f_t(x_t)$$

$$h_v^{(l)}, h_t^{(l)} = \text{CrossAttention}(h_v^{(l-1)}, h_t^{(l-1)}), \quad l = 1, 2, \dots, L$$

其中 $L$ 是交互层数。近年来，以 Flamingo、BLIP-2 为代表的模型进一步发展了这种混合融合架构，通过精心设计的中间模块（如 Perceiver Resampler 或 Q-Former）实现不同预训练模型间的高效连接。

## 5.2.2 多模态训练目标

多模态大模型的训练通常涉及多种训练目标，这些目标从不同角度优化模型对跨模态数据的理解能力。除了已在前文中提到的一些训练目标外，现代多模态大模型还采用了模态对齐目标、生成式训练目标、对话与指令遵循目标等多个训练目标。

模态对齐目标旨在建立不同模态表示空间之间的语义对应关系。除了前文提到的对比学习外，还包括如下几个目标：

**全局-局部对齐 (Global-Local Alignment)**，不仅考虑整体图像与文本的匹配，还关注图像区域与文本片段的细粒度对应关系。例如，OSCAR 模型引入了对象标签作为锚点，连接图像区域和相关文本表述。数学上，可以表达为最大化图像区域特征 $r_i$ 与相关文本片段 $t_j$ 的互信息：

$$\mathcal{L}_{G-L} = - \sum_{i,j} p(r_i, t_j) \log \frac{p(r_i, t_j)}{p(r_i)p(t_j)}$$

**多粒度对齐 (Multi-granularity Alignment)**，要求同时考虑 token 级、句子级和文档级的对齐。例如 UNITER 在预训练时同时优化图像区域与单词的局部对齐和图文整体的全局对齐，捕捉不同级别的语义关联。

生成式训练目标促使模型学习根据一种模态生成另一种模态的内容，或在多模态上下文中生成连贯的输出。**条件生成目标**要求模型在给定一种模态输入的条件下生成另一种模态的内容。最典型的例子是图像描述任务，其目标函数通常是基于最大似然估计的交叉熵损失：

$$\mathcal{L}_{caption} = - \sum_{t=1}^T \log p(y_t | y_{<t}, I)$$

其中 $I$ 是输入图像， $y_t$ 是生成文本序列的第 $t$ 个词。

**掩码自回归重建 (Masked Autoregressive Reconstruction)**，通过随机掩盖部分模态输入，训练模型预测被掩盖的部分。BERT 的掩码语言建模 (MLM) 被扩展

到多模态场景，如掩码图像建模（MIM）和掩码跨模态建模（MMM）。数学表示为：

$$\mathcal{L}_{MMM} = -\mathbb{E}_{(x_v, x_t) \sim \mathcal{D}} \mathbb{E}_{m_v \sim \mathcal{M}_v, m_t \sim \mathcal{M}_t} [\log p(x_v^{m_v}, x_t^{m_t} | x_v^{-m_v}, x_t^{-m_t})]$$

其中 $m_v$ 和 $m_t$ 分别是视觉和文本模态的掩码， $\mathcal{M}_v$ 和 $\mathcal{M}_t$ 是掩码生成分布。

随着多模态大模型向通用人工智能发展，对话能力和指令遵循能力变得越来越重要。多模态指令遵循目标指的是，针对包含图像上下文的指令，训练模型生成符合要求的输出。通常采用监督微调（Supervised Fine-tuning, SFT）方法，最大化条件概率：

$$\mathcal{L}_{SFT} = -\mathbb{E}_{(I, x, y) \sim \mathcal{D}} [\log p(y | I, x)]$$

其中 $I$ 是图像输入， $x$ 是文本指令， $y$ 是期望的输出。

**多回合对话目标**则要求训练模型在多轮对话中保持上下文一致性，同时正确参考和解释视觉信息。例如，LLaVA-1.5 模型使用学术考试风格的多轮问答数据强化模型的视觉推理能力。

### 5.2.3 多模态融合技术

多模态融合是指将不同模态的信息整合为统一、语义连贯的表示的过程。现代多模态大模型采用了多种先进的融合技术。

**交叉注意力机制（Cross-Attention）**是多模态融合的核心技术之一。在交叉注意力中，一个模态的特征作为查询（Query），另一模态的特征作为键（Key）和值（Value）。形式上，对于视觉特征 $V$ 和文本特征 $T$ ，交叉注意力可以表示为：

$$\text{CrossAttn}(Q = T, K = V, V = V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right)V$$

交叉注意力允许模型动态地聚焦于与当前文本内容相关的图像区域，或根据图像内容选择性地关注文本中的关键词。例如，LXMERT 和 ViLBERT 等模型使用双向交叉注意力，实现视觉到文本和文本到视觉的双向信息流动。许多模型如 ALBEF 采用复合架构，同时包含模态内自注意力和模态间交叉注意力。这样的设计让模型既能捕捉单模态内的结构化信息，又能建立模态间的语义联系。

为了控制信息流动并协调不同模态的贡献，多模态模型常采用门控机制和专门的适配层，即门控交叉注意力：如 Flamingo 模型中使用的门控交叉注意力层，通过学习门控因子 $g$ 控制视觉信息对语言模型的影响程度：

$$g = \sigma(W_g h + b_g)$$

$$h' = h + g \odot \text{CrossAttn}(h, V)$$

其中 $\sigma$ 是 sigmoid 激活函数， $\odot$ 表示逐元素乘法。门控机制使模型能够选择性地融合视觉信息，根据上下文自适应地调整视觉信息的权重。此外，适配器（Adapter）

技术指在预训练模型的基础上，插入少量可训练的适配层，实现高效的模态融合。例如，LoRA（Low-Rank Adaptation）技术通过添加低秩矩阵来调整预训练权重，而仅训练少量参数：

$$W = W_0 + \Delta W = W_0 + BA$$

其中 $W_0$ 是冻结的预训练权重， $B$ 和 $A$ 是低秩矩阵，满足 $B \in \mathbb{R}^{d \times r}$ ， $A \in \mathbb{R}^{r \times d}$ ，且 $r \ll d$ 。这种方法在 MiniGPT-4、BLIP-2 等模型中被广泛应用，以低计算成本实现高效的多模态融合。

## 5.2.4 多模态大模型训练方法

多模态大模型的训练过程通常涉及多个阶段和多种技术，以满足规模化训练和高效融合的需求。与 LLM 相同，多模态大模型通常遵循“预训练-微调”范式，先在大规模数据上进行自监督或弱监督预训练，再在下游任务数据上进行微调。而部分模型，如 BLIP-2，则采用的三阶段训练策略：先在大规模图文数据上预训练视觉编码器和 Q-Former 建立视觉-语言对齐；然后在图文描述数据上训练 Q-Former 与 LLM 的连接；最后在高质量指令数据上进行视觉指令微调。这种渐进式训练策略使模型能够稳定、高效地学习复杂的多模态能力。

为了充分利用现有的强大单模态预训练模型，同时避免灾难性遗忘（catastrophic forgetting），许多多模态大模型采用“冻结+适配”的训练范式。例如，LLaVA 模型冻结 CLIP 视觉编码器和大部分 LLM 参数，仅训练视觉-语言映射层和部分 LLM 参数；BLIP-2 仅训练 Q-Former，同时冻结视觉编码器和语言模型。数学上，训练的目标参数可表示为：

$$\theta_{train} = \{\theta_{adaptor}\} \cup \{\theta_{LLM}^{partial}\}$$

而冻结参数为：

$$\theta_{frozen} = \{\theta_{vision}\} \cup \{\theta_{LLM}^{majority}\}$$

这种方法大大降低了计算资源需求，同时保持了模型性能。

## 5.2.5 多模态大模型的评估

与文本或者图像不同，多模态大模型的评估需要多角度衡量其跨模态理解、生成和推理能力。为此，大量的多模态基准被应用到模型的评估中，其中包括视觉-语言理解基准，例如 VQA、NLVR<sup>2</sup>、SNLI-VE 等测试模型在图像中回答问题、判断图像与文本关系的能力。评估指标通常是准确率和 F1 分数。也包括视觉-语言生成基准，如 MS COCO Captions 评估图像描述能力，使用 BLEU、METEOR、CIDEr 等指标衡量生成文本的质量。此外，针对部分图文召回类模型，则主要为跨模态检索基准，如 Flickr30k 和 MS COCO 的图文检索任务，使用召回率（Recall@K）和中位数排名（Median Rank）等指标。

随着多模态大模型向着通用人工智能方向发展，越来越多的评估集中在指令遵循能力上。**多模态指令基准**，如 MMMU、MME、MM-Vet 等，测评模型在复杂视觉推理、多步骤任务和特定领域知识应用等方面的能力。这些基准超越了传统的单一任务评估，要求模型展示通用的视觉-语言问题解决能力。类似的，人类偏好对齐评估则通过人类反馈或人类评估模型（如 GPT-4）对多模态模型的输出进行评分，衡量其是否符合人类偏好和期望。这种评估方式特别适用于开放式生成任务。

多模态幻觉（hallucination）是指模型生成与视觉内容不一致的文本，是多模态模型面临的关键挑战之一。幻觉检测基准，如 POPE（Probing Object Hallucination in Multimodal LLMs）通过设计精心构造的问题测试模型是否会错误断言图像中不存在的物体；GAVIE 专注于评估模型在判断图像中复杂物体关系时的准确性。幻觉缓解方法包括基于不确定性估计的自我批判训练、对比学习增强视觉-语言对齐、多角度视觉验证等，这些方法共同目标是提高模型的事实准确性。



图 5.1: 多模态大模型及农业数据架构图

### 5.3 多模态大模型在农业领域的应用

农业现代化正迈入数字化和智能化的新阶段，多模态大模型（Multimodal Foundation Models, MFMs）的兴起为农业的智能化转型提供了核心技术支撑。多模态大模型能够整合视觉（RGB、多光谱、热红外）、文本（农事记录、气象信息）、时序传感器数据（温湿度、CO<sub>2</sub>、EC 值）、音频（虫鸣、机械噪声）以及遥感影像等多种异构信息，突破了传统单一模态算法的局限性，显著提升了农业管理与生产的精细化程度。

病虫害诊断是多模态大模型最具代表性的应用领域之一。以 Agri-LLaVA[26] 为代表的多模态对话模型，通过构建覆盖大量病虫害种类的专业图文数据集，实现了领域知识的有效注入。该模型利用视觉特征映射和指令微调技术，自动实现病害诊断与防治方案推荐。IPM-AgriGPT 则在综合防治（IPM）方面表现突出，通过链

式推理和生成评价对抗训练，优化病虫害防治决策，明显减少农药使用量，提高防治效果。

在视觉分割与定位任务上，Segment Anything Model (SAM) 在农业领域的适应已成为近期的研究热点。SAM 原生的零样本分割能力虽然强大，但在农业中特殊场景（如病斑边缘模糊、目标尺度差异大）中表现不稳定。针对这一问题，研发团队开发出领域适配器（如甘肃农业大学的 EMSAM），通过多尺度适配器与局部-全局特征融合显著提高了农业场景下病斑识别精度。

遥感与环境监测同样受益于多模态大模型的应用。利用 Transformer 架构构建的多模态网络，成功整合了卫星遥感数据与田间实时气象数据，使得作物产量预测精度大幅提高。如 Tan 等使用 GPT-4V 测试了多模态大模型在理解遥感数据上的能力，表明其能够在较高的正确图像分析上，在产量预测、处置方案、风险评估等各个方面均展现出不俗能力。同时，基于高光谱遥感影像、作物管理记录与短期气象数据的 CMAViT 多模态 Vision Transformer，将测试集上的决定系数  $R^2$  从 0.73 提升至 0.84，并将平均绝对百分比误差 (MAPE) 降至 8.22%，同时同步生成注意力热图和解释文本供专家审核。这些可视化的注意力图谱能够直观地标示出关键光谱波段、管理实践要素和生育期时段对作物产量的影响，为精准农业中的产量预测与管理决策提供透明且可解释的依据。

多模态大模型与农业物联网 (IoT) 融合形成了全新的智能农业生产范式。通过标准化的数据接口（如基于 JSON-LD），多模态模型能够实时处理来自各类传感器的环境数据并进行智能决策。例如，在日光温室环境中，模型实时分析土壤湿度、电导率数据并自动生成精准的灌溉与施肥指令。同时，通过自然语言交互，农户可以实时进行反馈与优化，实现“人-机协作”闭环，极大提升了农业生产的效率和精准度。

尽管多模态大模型前景广阔，但数据稀缺、高昂算力需求与数据隐私保护仍是重大挑战。研究人员通过众包方式积累大规模农业图像数据，建立开源共享平台降低数据获取成本；同时利用低秩适配 (LoRA) 与量化微调 (QLoRA) [33] 技术降低模型训练算力需求，使大模型可以在普通设备上部署。此外，联邦学习和差分隐私技术也被积极引入，以保障农户的数据主权与隐私安全，推动农业大模型更广泛的应用。

未来，随着原生时空多模态模型与因果推理技术的进一步发展，农业领域的智能化将获得更大的突破。研究者正在开发具备因果推断能力的农业多模态模型，以准确预测不同农业措施对产量的真实影响。此外，可解释 AI 技术的发展将进一步提高模型决策的透明度与可信度，促进农户与决策者的理解与接受。

综上，多模态大模型的广泛应用正在深刻地改变农业生产与管理的模式。通过持续优化数据获取与模型训练效率，深化模型与物联网协作能力，多模态大模型必将在精准农业、可持续发展与全球粮食安全保障中发挥更加关键的作用，推动智慧农业全面迈入智能化新时代。

## 第 5 章参考文献

- [1] OpenAI. GPT-4 Technical Report. Tech. rep. OpenAI, 2023.
- [2] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton. “ImageNet Classification with Deep Convolutional Neural Networks”. In: *Advances in Neural Information Processing Systems*. Vol. 25. 2012.
- [3] Sepp Hochreiter and Jürgen Schmidhuber. “Long Short-Term Memory”. In: *Neural Computation* 9.8 (1997), pp. 1735–1780.
- [4] Oriol Vinyals et al. “Show and Tell: A Neural Image Caption Generator”. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2015, pp. 3156–3164.
- [5] Stanislaw Antol et al. “VQA: Visual Question Answering”. In: *Proceedings of the IEEE International Conference on Computer Vision*. 2015, pp. 2425–2433.
- [6] Ashish Vaswani et al. “Attention is all you need”. In: *Advances in neural information processing systems* 30 (2017).
- [7] Jacob Devlin et al. “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding”. In: *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics*. 2019, pp. 4171–4186.
- [8] Jiasen Lu et al. “ViLBERT: Pretraining Task-Agnostic Visiolinguistic Representations for Vision-and-Language Tasks”. In: *Advances in Neural Information Processing Systems*. Vol. 32. 2019.
- [9] Liunian Harold Li et al. “VisualBERT: A Simple and Performant Baseline for Vision and Language”. In: *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing*. 2019, pp. 648–657.
- [10] Hao Tan and Mohit Bansal. “LXMERT: Learning Cross-Modality Encoder Representations from Transformers”. In: *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing*. 2019.
- [11] Yen-Chun Chen et al. “Uniter: Universal image-text representation learning”. In: *ECCV*. 2020.
- [12] Alexey Dosovitskiy et al. “An Image is Worth 16×16 Words: Transformers for Image Recognition at Scale”. In: *International Conference on Learning Representations* (2021).
- [13] Wonjae Kim et al. “Vision-and-Language Transformer”. In: *Findings of the Association for Computational Linguistics: EMNLP 2021*. 2021, pp. 5583–5594.

- [14] Alec Radford et al. “Learning Transferable Visual Models From Natural Language Supervision”. In: Proceedings of the 38th International Conference on Machine Learning. 2021.
- [15] Chuang Jia et al. “Scaling Up Visual and Vision-and-Language Representation Learning With Noisy Text Supervision”. In: Proceedings of the 38th International Conference on Machine Learning. 2021.
- [16] Liunian Harold Li et al. “ALBEF: Align Before Fuse for Vision-Language Representation Learning”. In: Advances in Neural Information Processing Systems. Vol. 34.2021.
- [17] Tom B. Brown et al. “Language Models are Few-Shot Learners”. In: Proceedings of the 34th Conference on Neural Information Processing Systems. 2020.
- [18] Junnan Li et al. “Bootstrapping Language-Image Pre-training for Unified Vision Language Understanding and Generation”. In: Proceedings of the 39th International Conference on Machine Learning. 2022.
- [19] Jean-Baptiste Alayrac et al. “Flamingo: a Visual Language Model for Few-Shot Learning”. In: Advances in Neural Information Processing Systems. Vol. 35. 2022.
- [20] Junnan Li et al. “BLIP-2: Bootstrapping Language-Image Pre-training with Frozen Image Encoders and Large Language Models”. In: arXiv preprint arXiv:2301.12597 (2023).
- [21] Gemini Team et al. “Gemini: a family of highly capable multimodal models”. In: arXiv preprint arXiv:2312.11805 (2023).
- [22] Zhijie Liu et al. “LLaVA: Large Language and Vision Assistant”. In: arXiv preprint arXiv:2304.08485 (2023).
- [23] Jia Zhu et al. “MiniGPT-4: Enhancing Language Models with Image Understanding”. In: arXiv preprint arXiv:2304.10592 (2023).
- [24] Fan Chen et al. “Otter: A Vision-Language Model with In-Context Learning”. In: arXiv preprint arXiv:2305.16272 (2023).60
- [25] Wei-Lin Chiang et al. Vicuna: An Open-Source Chatbot Impressing GPT-4 with 90%\* ChatGPT Quality. Mar. 2023. url: <https://lmsys.org/blog/2023-03-30vicuna/>.
- [26] Liqiong Wang et al. “Agri-LLaVA: Knowledge-Infused Large Multimodal Assistant on Agricultural Pests and Diseases”. In: arXiv preprint arXiv:2412.02158 (2024).
- [27] Yuqin Zhang et al. “IPM-AgriGPT: A Large Language Model for Pest and Disease Management with a G-EA Framework and Agricultural Contextual Reasoning.” In: Mathematics (2227-7390) 13.4 (2025).
- [28] Alexander Kirillov et al. “Segment anything”. In: Proceedings of the IEEE/CVF international conference on computer vision. 2023, pp. 4015–4026.

- [29] Junlong Li et al. “EMSAM: enhanced multi-scale segment anything model for leaf disease segmentation”. In: *Frontiers in Plant Science* 16 (2025), p. 1564079.
- [30] Chenjiao Tan et al. “On the promises and challenges of multimodal foundation models for geographical, environmental, agricultural, and urban planning applications”. In: *arXiv preprint arXiv:2312.17016* (2023).
- [31] Hamid Kamangir et al. “CMAViT: Integrating Climate, Management, and Remote Sensing Data for Crop Yield Estimation with Multimodal Vision Transformers”. In: *arXiv preprint arXiv:2411.16989* (2024).
- [32] Edward J Hu et al. “LoRA: Low-Rank Adaptation of Large Language Models”. In: *International Conference on Learning Representations*. 2022.
- [33] Tim Dettmers et al. “Qlora: Efficient finetuning of quantized llms”. In: *Advances in neural information processing systems* 36 (2023), pp. 10088–10115.

## 6. 大模型在农业应用的典型场景

当下精准农业、智慧农业的概念早已不再新鲜，“用最小成本实现最大产量、最优品质、最低环境损耗”的目标始终悬在每一个农技工作者心头。然而，过去的研究往往依赖单一数据源（如仅用遥感影像进行作物识别）或仅限于“浅层”机器学习算法，难以全面、准确地捕捉农业生态系统的时空演变特征。大模型凭借其在大规模无监督语料上的预训练优势，可在“零样本”或“小样本”场景下实现对多种农作物、病虫害甚至土壤与气候要素的高效识别与推理。在本章中，我们将从如下几个角度依次展开讨论：

作物识别与田块分割是精准农业的基础。早期应用多为基于卷积神经网络的专项模型，只能在特定场景下进行作物或地块边界提取。随着 Vision Transformer (ViT)、SAM (Segment Anything Model) 等通用大模型的出现，可以在缺乏标注数据的地区实现对卫星遥感与无人机航拍影像的零样本分割，准确勾勒出不同作物田块的边界，为更下游的分类与监测提供先决条件。此后再结合 CLIP 等跨模态模型，将图像与作物名称、品种描述等文本信息映射到同一语义空间，实现不同作物种类在大范围地块图像中的“开箱即用”识别。本章将详细介绍这些模型在农业影像领域的微调策略、提示工程，以及如何结合多时相影像提高分割与识别精度。

病虫害识别与监测是保障农业产量与品质的关键环节。传统巡田方式费时费力，且对早期病害往往难以及时发现；卷积网络虽能自动识别病斑，但在“小病斑”、少样本和新发病害场景中局限明显。大模型通过在海量植物病虫害图像及对应描述文本上预训练，可在极少样本条件下实现高准确的零样本病害分类，并结合对比学习或检索增强 (RAG) 技术，将图像检测结果与领域知识库中的防治方案一并输出，帮助农技人员快速诊断病虫害类型、推演病害扩散风险并给出针对性的防治建议。本章将剖析 PlantCaFo、AgriCLIP 等多模态模型在小样本病虫害识别与跨区域迁移中的优势，并展示如何借助 YOLO、SAM 等视觉大模型构建实时田间虫害检测与病斑识别系统。

农作物产量预测与估产对区域粮食安全与市场调控至关重要。以往基于统计学和物理模型的预测往往局限于单一指标，难以兼顾气象变化、土壤差异与作物生长过程的复杂耦合；大模型应用 Transformer 架构，可将卫星遥感序列、气象站时序数据、历史产量记录与土壤监测数据进行多模态时空融合，实现全方位的产量预测。如 MMST-ViT 等模型将时序影像与气候数据一同输入，捕捉短期天气异常与长期气候趋势对作物生长的多层次影响；基于 TimeGPT 等时间序列大模型，则可在田块级别进行早期产量预报，用于指导精准灌溉与耕作投入。为此，本章将详细讨论多模态时空 Transformer 的设计思路与训练技巧，以及如何在小样本与区域数据异构场景下保持模型泛化能力，并给出对于模型性能评估与误差分析的实用方法。

精准农业与农场管理的核心在于对田间异质性进行精细化控制。以往农民依赖经验和有限传感器数据做出局部决策，而今大模型可根据不同田块的土壤成分、微气候条件与作物长势，实现分区化、区域化的施肥、灌溉与植保策略。例如，基于

Vision Transformer 的田间杂草检测与分割模型，能在复杂光照与背景下准确识别杂草位置，为农机设备提供喷洒或机械除草的精确目标；基于物联网数据与时序气候信息的大模型决策系统，可根据畜牧场温湿度、饲料库存与市场价格等多源数据，自动生成合理的饲养、采集与销售计划，从而最大化经济效益并降低资源浪费。本章将结合真实农业项目案例，展示如何将大模型嵌入智慧农场管理平台，实现从数据采集到决策执行的闭环自动化。

农业机器人在播种、施药、收获等环节承担着越来越重要的角色。与传统基于手工编程和浅层视觉算法的机器人不同，多模态大模型能够让农业机器人具备更强的环境感知、语义理解与路径规划能力。例如，将深度强化学习与大模型结合，可让机器人在不规则种植行间进行自主导航，并通过与视觉模型的融合，实现动态障碍物避让与目标作业识别；将 SAM 与大型视觉 Transformer 应用于单株果实识别，则可辅助机械臂完成精准采摘，提升收获效率和果实品质。本章将重点介绍多模态大模型如何支撑农业机器人完成自主感知与执行任务，并探讨在复杂户外环境下如何通过模型压缩与知识蒸馏技术加速推理、降低能耗，使农机具备真正的无人自主作业能力。

智能育种与基因组预测是提升作物品种与品质的核心。传统育种依赖田间试验与统计遗传学模型，周期长、成本高；借助大模型，研究者可以将基因组与环境因子、表型试验结果等多源数据融合，构建可在小样本下实现精准预测的育种辅助系统。例如，集成基因组-环境预测（iGEP）框架通过多层神经网络将全基因组标记与环境变量相结合，预测基因型与环境互作对产量、抗性等性状的综合影响；构建类似 AgroNT 的 DNA 语言模型，让模型通过 Masked Language Model 方法学习植物基因组的序列语言，进一步应用于功能元件识别与突变效应预测。本章将阐述这些模型在实际育种流程中的落地路径，并解析如何在数据稀缺与遗传多样性巨大的条件下实现高效育种决策。

农业气象与作物生长建模是应对气候变化与极端天气风险的关键环节。大模型在融合遥感与气象数据时展现出较强的时空推理能力，可用于动态模拟作物生长过程与气候胁迫影响。例如，通过多模态 Transformer 对多年气象序列与遥感影像进行联合预训练后，可在灾害来临前预测病虫害爆发与叶面积指数变化，为作物管理提供精准预警；将气候-作物大模型应用于洪涝、干旱等极端情景模拟，可为政府与农户的应急预案提供科学支撑。本章将详细探讨这类模型的核心设计与验证思路，并给出在极端天气与气候变化语境下进行农业风险评估的工程实践方案。

农业知识问答与综合决策支持服务是面向广大农户的“最后一公里”场景。传统的农技推广通常依赖线下培训与人工咨询，受制于覆盖面与专业性；大语言模型与知识图谱结合后，可为农户提供智能化的在线问答平台，及时解答病虫害防治、施肥用量、品种选择等问题。例如，结合农业知识图谱与检索增强生成（RAG）技术的问答系统，能够在用户提出问题后快速检索权威信息，并利用大模型将专业术语转化为通俗易懂的建议。此外，通过集成时间序列大模型与市场预测模型，可为政府与企业提供农产品价格和供需趋势的决策参考，从而优化整个供应链。本章还

将阐述各类农业问答与决策支持系统的最佳实践，并讨论如何在保证答案准确性的基础上兼顾实时性与可解释性。

通过上述七个典型场景的讲解，读者不仅能深入了解大模型在农业产业链中各环节的创新应用，还能把握其在不同场景下的技术痛点与解决策略。我们将结合大量国内外研究成果和实地案例，详细剖析每一类模型在数据采集、模型设计、算力需求、效果评估及应用制约方面的具体做法与经验教训，并提出未来可持续优化的方向。在这一过程中，既强调多模态融合与跨领域协同的重要性，也关注模型轻量化与边缘化部署的工程挑战；既展示顶级研究机构的前沿探索，也关注可复制的地方性实践，以期为农业从业者、科研人员和技术开发者提供切实可行的指导路径。通过本章的学习与思考，希望每一位读者都能在理论与实践的交汇处找到适合自身场景的应用思路，共同推动农业朝着高效、绿色、智能的方向发展。

## 6.1 作物识别与田块分割

作物种类识别和农田边界分割是精准农业的基础工作之一。过去主要依赖遥感影像的分类和分割算法，但受到分辨率、光照等因素影响，精度有限。大模型的出现为大尺度、高复杂度的图像分割提供了新手段。

### 6.1.1 通用语义分割模型的应用

Meta 公司发布的 Segment Anything Model (SAM) 是一种通用的语义分割大模型，不需要针对特定任务训练，即可提取出物品的轮廓。农业领域开始将 SAM 引入作物识别与田块轮廓提取。例如，Gurav 等研究使用 SAM 对卫星影像进行零样本分割，尽管无法直接让 SAM 在遥感影像中分割作物种类，能够快速准确地勾画出农田边界，为后续识别每块田地的作物类型奠定基础，可大幅降低人工标注成本。Tripathy 等人探究了 SAM 在小农田地块边界提取上的性能：在印度比哈尔邦 2 米分辨率的 SkySat 影像上，未经任何训练微调的 SAM 准确识别出约 58% 的田块边界。这一准确率已与依赖大量标注数据训练的专用模型相当。尤其通过提供多时相影像作为输入，SAM 的分割效果进一步提升。这证明了在缺乏标注的地区（如南亚、小农户聚集地），利用大模型可以高效获取农田分布信息。

### 6.1.2 多尺度应用

同时，大模型在不同尺度的作物影像上均有应用。宏观上，NASA 和 IBM 发布了基于海量卫星数据训练的地理空间大模型，可用于监测土地利用变化。该模型在遥感影像上具备通用的分析能力，被视为 Earth Observation 领域的一个里程碑。

微观上，在植株级图像分析中也引入了大模型技术。例如 "Leaf Only SAM" [3] 方法将 SAM 应用于植物近景图像，实现了对叶片的零样本自动分割。这使研究人员能够在不标注大量训练数据的情况下，快速提取单株作物的叶片轮廓，用于后续的叶面积测量、长势评估等。

### 6.1.3 跨模态融合识别

作物种类与生长状态的智能识别是农业信息获取的基础。传统方法需大量带标注的图像训练特定作物分类模型，而大模型的引入显著提升了开放领域识别能力。例如，OpenAI 提出的 CLIP 模型将图像和文本嵌入到共同空间，可零样本地匹配图像内容与文本标签。在农业领域，Nawaz 等开发了 AgriCLIP 模型，以约 60 万对农作物、牲畜图像-描述文本为语料进行继续训练。AgriCLIP 不仅学到农业领域的语义特征，还结合了自监督 DINO 模型获取细粒度视觉细节，从而在 20 个农业下游数据集上实现零样本分类准确率 48.27%，比未经适配的原始 CLIP 提高了 9.07 个百分点。

总体而言，大模型为作物识别与田块分割带来了新的范式：大模型可利用其在通用图像上的知识，实现对农田的快速解析，但仍需结合领域数据进行适配以保证精度。在未来，更大规模的农业遥感预训练模型和专门的提示优化技术有望进一步提高作物分割的自动化程度和可靠性。

## 6.2 病虫害识别与监测

农作物病虫害的及时识别与监测对保障农业产量至关重要。传统方法依赖人工巡田和经验判断，随着计算机视觉的发展，基于卷积神经网络的图像识别模型已经能够对植物病害进行自动诊断。然而，病虫害种类繁多、样本获取困难，许多场景下标注样本匮乏，限制了传统深度学习模型的性能。大模型通过在海量图像上预训练，可以在小样本条件下取得较好结果，因而被引入植物病虫害识别中以提高鲁棒性。

### 6.2.1 小样本病害识别

一方面，在植物病害图像识别中，研究者尝试利用大模型实现小样本学习。Jiang 等提出了 "PlantCaFo" 方法，这是一种基于大模型的高效少样本植物病害识别框架。该方法利用预训练模型提取的通用特征并进行微调，在极少的病害样本下仍能取得优异的分类准确率。这证明了大模型自带的视觉知识有助于新病害的识别，降低了对大规模标注数据的依赖。

另有研究结合多模态信息来增强小样本病害识别的效果。Cao 等设计了一种图像-文本标签结合的多模态模型，用于黄瓜病害的小样本识别。他们利用大模型将少量图像样本与文本描述标签对齐，从而显著提高了病害分类的准确率。据报道，该方法在只有很少训练图像的情况下也能正确识别出白粉病、霜霉病等病害类型，体现了跨模态大模型在农业领域的威力。

### 6.2.2 多模态病虫害分析

病虫害是威胁粮食生产的重要因素，利用大模型可实现更通用、高效的病虫害识别与监测。传统检测模型（如训练特定病害的卷积网络或目标检测器）往往缺乏对未知病虫的识别能力，而大模型凭借开放集泛化特性，可以弥补这一不足。例

如, Arshad 等构建了农作物病虫害诊断的多模态基准 AgEval, 涵盖虫害种类识别、病症分类等 12 项植物胁迫表型任务, 评估了 GPT-4、Claude 等多模态大模型的零样本和小样本学习性能。结果显示, 通过提供 8 个示例问答 (8-shot), 最佳模型的平均 F1 分数从 46.24% 大幅提升到 73.37%, 证明少量领域样本示范能显著增强大模型对农作物病虫害问题的理解与回答能力。

### 6.2.3 病虫害检测与智能诊断

另一方面, 大模型还被用于植保领域的虫害监测和诊断。传统虫害识别需要对田间虫情进行分类计数, 目前的研究正引入视觉-语言大模型来提升自动化程度。Truong 等发布了一个面向昆虫的多模态大模型 "Insect-Foundation", 包含大规模的虫害图像和描述数据, 用于训练视觉-语言模型识别农业害虫。该模型能够理解图像中的昆虫种类, 并结合文本描述进行分类, 对于农业害虫的识别和知识查询提供了统一的框架。

同样地, 大模型还能帮助将计算机视觉的检测结果转化为人类可理解的诊断信息。Qing 等提出了一个 GPT 辅助的诊断系统: 先用轻量级 YOLO 模型检测农作物图像中的病斑或虫体, 然后将检测结果与症状描述通过 GPT 模型生成诊断结论。这种流程利用了大模型强大的语言生成与推理能力, 将图像分析与专家知识相结合, 能自动给出病虫害的诊断和防治建议。

### 6.2.4 问答系统与植保应用

大模型本身也被直接应用于农业病虫害领域的信息服务。赵新艳等将大语言模型与农业知识图谱相结合, 构建了一个植物病害智能问答系统, 以提高病害诊断的效率。该系统利用知识图谱提供权威的植保知识, 由 LLM 理解用户输入并匹配相应的病害信息, 能够在咨询中给出病害名称、发病机理和防治措施等回答。这种知识驱动的大模型应用, 有助于构建面向农民和农业技术员的智能病虫害咨询助手。

此外, 研究者还开始评估通用大模型在植保领域的表现。Calone 等分析了 ChatGPT 在作物病害风险预警中的潜力, 探讨这类通用 LLM 是否能支持病害风险预测系统。初步结果表明, ChatGPT 能够生成一定逻辑性的病害发生风险分析报告, 但在专业准确度方面仍需要与领域模型和数据相结合。这些探索为将来开发植保智能决策支持系统奠定了基础。

大模型正推动病虫害监测从传统的图像分类迈向多模态、智能交互的方向。一系列研究表明, 大模型在小样本病害识别、害虫多模态理解以及诊断问答等方面均取得了突破。然而, 病虫害领域的复杂性也对模型提出了高要求: 不同作物和区域的病虫害症状差异巨大, 模型需要具备良好的跨域适应能力; 诊断不仅要求识别准确, 还要求给出可靠的防治建议。这些都需要在未来通过融合专业知识、强化学习反馈等手段, 不断完善农业领域的大模型应用。

## 6.3 农作物产量预测与估产

作物产量的准确预测对于农业决策、粮食安全具有重要意义。传统产量预测模型往往基于历史统计或简单的回归分析，难以同时考虑多源异构数据（如气象、遥感、品种）对产量的综合影响。随着深度学习的发展，研究者开始尝试将大量数据源融合，用神经网络预测农作物产量。

### 6.3.1 多模态时空融合模型

Lin 等提出了一种多模态时空 Transformer 架构，用于美国县级玉米产量预测。他们的模型（MMST-ViT）包含多模态 Transformer 模块融合卫星遥感影像与季节气象数据，以表征生长季节天气波动对作物生长的影响；同时引入空间 Transformer 捕捉不同区域产量的空间相关性，时间 Transformer 建模长期气候变化对作物的影响。通过这种架构，模型能够同时学习短期气候异常和长期气候趋势对产量的作用。在超过 200 个县的数据上测试结果显示，该模型在多项评价指标上均优于以往方法，成功将气候变率和变化的信息融入了产量预测。

一方面，大模型能够融合遥感影像、气象数据和历史产量记录，捕捉影响产量的复杂模式。MMST-ViT 模型使用了对比学习预训练策略，在无监督情况下让模型对齐多模态特征，从而充分利用历史影像与气候数据。实验证明，该大模型在 200 多个县域的产量预测中优于现有方法，在多个评估指标上取得最佳表现。这一成果展示了大模型对复杂时空过程的表征能力，有望用于评估气候变化情景下的作物产量走势。

### 6.3.2 预报与田块级估产

除了大范围的区域产量预测，大模型也应用于田间尺度的产量估计与早期预报。Bi 等针对大田作物生长初期的产量预报，提出了一种 Transformer 结构结合时序影像的方法。该研究利用无人机拍摄的高分辨率田间图像序列，对每块田的植被长势进行跟踪，并在季初阶段融合种子品种等元数据来预测最终的大豆产量。具体而言，他们将每张田间图像通过语义分割分为“植被”和“裸土”两类区域，并分别构建视觉 Transformer 提取两类区域的特征；随后再通过时序 Transformer 整合生长期多时相影像的信息，最后结合种子特性等输入估计产量。在加拿大农田的数据集上，Transformer 模型的预测误差比其他基线模型降低了 40% 以上。尤其是在低产情景下，加入种子信息显著提高了预测准确度，表明多源数据的大模型融合有助于捕捉产量的复杂影响因素。

针对单一农田或区域的小规模产量预测任务，大模型的时间序列预测能力亦有所展现。DeForce 等将时间序列大模型 TimeGPT 引入农业，预测果园土壤张力（与土壤水分和最终产量密切相关）。在仅使用历史观测数据且未引入传统众多影响因子的情况下，TimeGPT 的预测精度与专门训练的最优模型相当。这凸显了大模型在小数据环境下的强大建模能力，能从历史模式中自发提取与产量相关的信号。

## 6.4 精准农业与农场管理

精准农业旨在利用观测和模型优化农作物生产的每个环节，包括土壤管理、灌溉施肥、病虫害防治等。大模型技术在精准农业中的应用，主要体现为对海量农情数据的融合分析和决策支持，以及对田间异质性的自动响应。传统上，精准农业依赖传感器和经验规则进行决策，现在借助大模型，可以实现数据驱动的智能管理。

### 6.4.1 田间异质性管理

田间异质性管理的一个典型场景是杂草的精准防除。相比过去统一喷洒除草剂，借助机器视觉可以实现按需除草。近年来 Transformer 等大型视觉模型被用于田间杂草检测，取得了显著效果。有研究表明，基于 Transformer 的模型在实际玉米田杂草检测中表现出很高的准确率。

例如，将 Swin Transformer 架构应用于杂草识别，可以细粒度地区分作物和杂草，即使在复杂的田间光照和背景下也能可靠地识别杂草。Transformer 模型强大的特征提取能力和全局注意力机制，使其在杂草分布稀疏、不均的农田环境中仍能有效检测，实现真正的“按株施策”。结合田间机器人或无人机，这些模型检测出的杂草位置信息可用于精准喷洒除草剂或机械除草，既提高了除草效果又减少了农药用量。实际应用中，约翰迪尔(John Deere)公司的 See & Spray 技术已证明了机器视觉按需喷洒的可行性，而未来引入更强大的基础视觉模型后，杂草检测的鲁棒性和速度将进一步提升。

### 6.4.2 数据驱动的决策支持

精准农业的另一核心是根据多源数据进行智能决策推荐。传统农艺决策需要综合土壤、天气、作物状态等多方面信息，往往依赖专家经验。大模型通过对物联网(IoT)和传感器数据的融合分析，可以提供数据驱动的推荐。

Fattepur 等[13]提出了一个物联网数据与机器学习深度融合的平台，帮助农户进行精确作物种植和管理决策。该系统收集土壤湿度、养分含量、历史气候等数据，利用预训练模型进行分析，给出适宜的作物选择和田间管理方案。实践证明，这种融合多源数据的大模型推荐能够比单一信息来源的决策更加可靠，帮助农民在播种阶段就做出有利于增产和风险降低的选择。

同样，在灌溉施肥方面，深度强化学习等大模型方法也开始用于制定动态优化策略。一项研究使用深度强化学习(DRL)来生成灌溉调度方案，结果显示 DRL 方法在水资源受限场景下能够明显优于传统规则法，既保证产量又节水。这些探索预示着未来的农场管理决策将更多由 AI 辅助完成：模型持续读取传感器和天气预报数据，实时调整灌溉、施肥、防治策略，实现高度精准的田间管理。

大模型通过对物联网(IoT)和传感器数据的融合分析，可以提供数据驱动的推荐。传统上，农艺师需要根据土壤、水分、植被指数等多方面信息制订管理措施。如今，大模型可以训练成为“农业数据分析师”，自动处理来自卫星遥感、地面

传感器、气象站和农业机器的数据流，并从中挖掘相关性。例如，一项研究利用 TimeGPT 模型仅根据历史土壤张力序列准确预测未来的土壤水分动态。这种能力可用于灌溉决策支持：模型发出的土壤干旱预警可以提示何时启动灌溉，以及预测不同灌溉量对未来土壤湿度和作物状况的影响，从而实现精准灌溉。相比之下，以往经验规则或简单模型难以兼顾如此多变的影响因素。

### 6.4.3 生产全过程的优化控制

此外，大模型还可以用于农作物生产过程的全局优化控制。Chen 和 Huang[15] 提出了一种将强化学习（RL）与大语言模型结合的新范式，用于优化作物生产全过程的管理与控制。他们的思路是利用大语言模型整合农业领域的知识和规则，再通过强化学习在模拟环境中反复试验，寻找最优的决策序列，例如何时灌溉、施肥及收获。初步结果表明，这种知识驱动的深度强化学习能够逐步逼近专家水平的种植方案，并在复杂情况下表现出自适应调整能力。虽然这一研究仍在实验阶段，但展示了大模型用于农业系统级决策优化的巨大潜力。

大模型经过在海量农业文献和知识库上的预训练，掌握了农业科学与实践要点。当输入特定农场的环境和作物信息时，LLM 能够给出个性化的建议。例如，Silva 等以巴西农业研究机构 Embrapa 的数据和印度农业研究生入学考试题库为基础，通过检索增强型的大语言模型，为当地农民生成作物管理指导。结果表明，GPT-4 结合检索与提示优化，能够输出较为可靠的播种时间、施肥策略等方案建议。

## 6.5 农业机器人导航与作业

农业机器人是实现无人化农场、精准作业的重要载体，包括田间自动驾驶车辆、播种机、植保无人机、采摘机器人等。在这些机器人系统中，大模型为环境感知和决策控制提供了先进的技术支撑。现代农业机器人需要在复杂的田间环境中感知作物和障碍物、规划路径并执行具体作业，这对计算机视觉、定位导航和智能控制都提出了高要求。大模型通过在广泛场景下的训练，具备了较强的环境理解和决策泛化能力，因而被逐步应用于农业机器人领域。

### 6.5.1 基于强化学习的智能导航

在导航方面，深度强化学习等决策型大模型开始用于农业机器人路径规划。传统农机的自动导航多依赖 GPS 直线导航，对于复杂地形或行距不规则的田块往往无能为力。Tom 等人在一项研究中应用深度强化学习（DRL）解决四轮独立转向农田机器人的导航问题。他们将农田环境和作物行信息输入 DRL 智能体，成功训练机器人在不规则排列的作物行间自主行驶。

特别是，该机器人能够根据强化学习策略灵活调整转向模式，例如零半径转弯或横移，以适应不同田垄布局，实现了多种复杂地形下的自动导航。相比预先编程的规则，RL 大模型使机器人具备了自主学习避障和循行的能力，大幅提升了田间移动的适应性。

## 6.5.2 视觉感知与目标检测

在田间作业（如收获、喷药）中，视觉感知是机器人决策的基础，大模型在这一环节发挥着关键作用。农作物和果实的检测与定位一直是农业机器人研究的重点难题之一。近年来，研究者将最先进的目标检测和分割模型应用于农作物识别上，以提高机器人作业的精准度。

例如，在果蔬采摘机器人中，常用的目标检测模型包括 Faster R-CNN、YOLO 系列以及视觉 Transformer 模型等。Seo 等比较了这三类检测大模型在苹果和桃子检测数据集上的表现，均采用预训练模型进行微调以克服小数据集的限制。结果显示，Transformer 架构在检测精度上略胜一筹，而 YOLOv8 在速度上具有优势。

深度模型的引入，使得机器人视觉系统能够在复杂背景下准确识别出树上的果实，并计算其位置和成熟度，从而指导机械臂的采摘动作。值得一提的是，传统评价检测模型优劣的标准是平均精度（AP），但在机器人采摘场景下，研究者引入了新的评估指标“抓取成功率”，直接衡量检测结果转化为机械抓取的成功概率。这进一步促进了感知模型与机器人动作的结合，倒逼感知大模型提升对抓取友好的检测质量。

在感知层面，基础视觉模型可以帮助机器人识别多种田间目标并进行精确定位。例如，上文提到的 SAM 模型已用于家禽养殖场的自动个体识别与跟踪：研究者将 SAM 及 YOLOX 检测器和 ByteTracker 算法结合，实现了对鸡群的单体跟踪。SAM 首先在每帧图像分割出每只鸡的掩膜和边界框，随后跟踪算法根据 SAM 提供的位置将个体在视频中关联，从而自动统计并分析鸡只行为。这种将基础分割与目标跟踪相结合的方法，在很大程度上减少了人工干预，被视为迈向农场动物监控自动化的重要一步。

## 6.5.3 语义分割的应用

农业机器人还依赖分割模型来理解作业环境的语义信息。以田间除草机器人为例，其需要识别每个像素属于作物、杂草或土壤，从而决定哪些区域需要除草。语义分割的大模型（如 DeepLab、U-Net 以及最新的 Vision Transformer 分割模型）被广泛用于这一任务。

这些模型可以将摄像头图像转化为一幅精细的语义地图，结合 GPS 位姿，机器人便能在厘米级精度下获取田间各目标的位置。基于这样的信息，机器人能够对准杂草位置进行精确喷药，或用机械装置铲除单株杂草，实现逐株防除而不伤及作物。PhenoRob 卓越研究中心的试验表明，在温室和露天环境下，通过对现有分割模型进行无监督域自适应训练，可让同一模型胜任不同作物品种和不同田间环境的杂草分割任务。这体现了大模型强大的可迁移能力，使农业机器人能够“一专多能”地适应多样化的作业场景。

## 6.5.4 大模型与机器人设计

除了静态感知，大模型正逐步拓展至农业机器人的决策与控制。大模型（LLM）能够理解人类指令并推理复杂任务规划。Stella 等利用 ChatGPT 辅助设计了一个西红柿采摘机器人的末端执行器。在概念设计阶段，研究者通过与 ChatGPT 对话获取关于番茄采摘挑战和潜在方案的灵感；在详细设计阶段，再让 LLM 对具体机械结构和代码实现提出建议。

尽管当前 LLM 尚不能直接生成可用的机械模型或控制代码，但人机协同设计显著加速了机器人原型开发。这一案例表明，大模型可以作为智能助手参与农业机器人研发，全程提供知识支持。未来，随着多模态大模型能够同时处理视觉、语言和空间信息，大模型驱动的田间机器人或可“看见”作物和障碍物，“听懂”语音指令，并自主规划路径完成指定农事，有望实现更高级的自主性。

总的来说，大模型为农业机器人的自主作业提供了有力支撑。从导航决策的强化学习模型、到环境感知的视觉 Transformer 模型和语义分割网络，这些模型大幅提升了机器人对农业环境的理解和适应能力，使真正的无人农场逐步成为可能。当然，实现这一目标还需要应对许多挑战，包括户外环境下模型的鲁棒性、实时性要求以及安全可靠的多传感融合等。不过可以预见，随着大模型与机器人技术的深度结合，未来的农业机器人将能够在更加复杂的场景中自主感知和行动，承担起播种、植保、收获等繁重工作，从而解放劳动力、提高农业生产效率。未来研究需要在模型轻量化、实时性提升以及多传感器协同方面发力。例如，可通过知识蒸馏训练小型模型以嵌入机器人，或发展强化学习类的大模型（如 DeepMind 的 Gato）用于决策控制，从而真正赋能自主农机系统。

## 6.6 智能育种与基因组预测

育种领域同样开始受益于大模型带来的范式转变。传统植物育种依赖育种家在田间对表型性状的观察和世代累积的经验，结合统计遗传学模型进行决策。近年来，随着基因测序和高通量表型技术的发展，海量的基因组和环境数据涌现，如何从中挖掘信息加速育种成为关键挑战。人工智能，特别是大规模深度学习模型，为此提供了新的解决途径。

### 6.6.1 集成基因组-环境预测方法

"智能育种"理念强调利用大数据和 AI 提升育种效率。Xu 等提出了集成基因组-环境预测（integrated genomic-environmental prediction, iGEP）的智慧育种方案。该方案利用集成的多组学信息（基因组、表型、环境）和大数据技术，结合机器学习与深度学习模型，对作物品种的多性状进行综合预测。

简单来说，就是将作物全基因组数据与历年多地点试验的环境数据一起输入深度模型，让模型学习基因型与环境互作对产量、抗性的影响，从而在育种决策时既考虑品种本身的遗传潜力也考虑其适应的环境条件。这种思路突破了传统育种分别进行遗传分析和环境分析的局限，实现了更全面的预测。据报道，iGEP 框架在玉

米等作物上表现出优于经典统计基因组选择模型的预测能力，可更准确地锁定优良组合。

### 6.6.2 DNA 语言模型

在作物遗传改良领域，大模型同样展现出巨大潜能。典型的例子是 **Agronomic Nucleotide Transformer (AgroNT)**，一个专为可食用植物基因组打造的大型 DNA 语言模型。研究者收集了 48 种不同植物（涵盖主要粮食作物和经济作物）的参考基因组序列，使用无监督的 **Masked Language Model** 训练策略，让 AgroNT 从约 6000bp 长度的 DNA 片段中预测被随机遮蔽的碱基序列。

这种方式迫使模型学习 DNA 序列的潜在模式和结构特征，获得对基因组语言的"理解"。训练完成后，AgroNT 在多个下游基因组分析任务中表现出色。例如，在不同物种的基因多聚腺苷酸化位点识别任务中，AgroNT 的 AUC 达到 0.89–0.96，平均准确率大幅领先于以往的浅层模型。又如在长链非编码 RNA 功能预测中，该模型同样取得领先，展示出跨物种的泛化能力。这意味着育种专家可以用一个预训练的 AgroNT，通过少量已知标记的数据，快速预测新的作物品种中重要基因元件的位置和功能。

### 6.6.3 大模型驱动的育种决策支持

育种领域的大模型不仅帮助"算"出哪个品系有潜力，还可以辅助决策"为何"选择。大模型能够从海量育种数据中归纳出隐含模式，例如某些基因组合在特定环境下往往导致高产。这些模式可转化为育种知识，反过来指导育种家设计更优的杂交组合。

大模型也可能在育种领域发挥作用，例如结合文献和数据库构建育种知识图谱，提供智能问答辅助。虽然目前植物育种主要侧重于利用深度学习进行预测，但随着农业知识的数字化积累，未来或将出现面向育种咨询的专业对话模型，帮助研究者快速获取历史试验结果和文献信息，从而制定育种策略。

大模型不仅能加速基因组数据的解读，更有望参与育种方案的设计。如果有一个准确的模型能够预示哪些突变会提高产量，则可大幅减少无效试验。大模型朝这一方向迈出了步伐：通过学习海量已知基因编辑和性状数据，它们或可预测特定 DNA 变异对性状的影响。一旦模型足够精确，研究者就能在计算机上"筛选"最佳的基因改良方案，然后再实施有限的试验验证。

## 6.7 气象与作物生长建模

农业生产高度依赖气候环境，因而将气象要素与作物生长过程进行一体化建模，是数字农业的核心课题之一。大模型凭借对跨模态时空数据的统一建模能力，为这一复杂系统提供了新的解决方案。

### 6.7.1 气候-作物一体化模型

一方面，大模型能够同化大尺度的气象观测和预报数据，与遥感和地面观测结合，模拟作物生长的全过程。上文介绍的 MMST-ViT 模型即充分考虑了天气和气候因素对产量的影响：通过多模态 Transformer 融合逐旬气象数据，Temporal Transformer 捕捉多年气候趋势，模型能够区分出季节内异常高温干旱和长期气候变暖各自对作物的影响。这类模型实际上构建了一个“数据驱动的气候-作物模型”，可用于评估例如厄尔尼诺年景对特定区域粮食产量的冲击，以及不同适应性措施（灌溉、抗旱品种）在模型中的作用反馈。

### 6.7.2 农业气象灾害预警与影响评估

另一方面，大模型还可以服务于农业气象预报和灾变预警。传统作物生长模型如 WOFOST、DSSAT 需要手工设定参数，难以及时反映极端天气的影响。而大模型可以通过学习历史灾害和减产案例，提高对非常态情况的模拟能力。

例如，NASA 开源的 HLS 地理空间大模型被寄望于监测自然灾害对农业的影响。研究人员可以利用该模型快速比对灾前灾后的遥感影像，量化洪涝、风灾造成的作物受损面积，从而为救灾和补偿提供科学依据。另外，多模态大模型还可用于农业气象数据的智能分析与解释。大模型可以被训练来阅读和解读复杂的气象报告、卫星云图等，并以自然语言生成对农民友好的天气建议。例如，一个多模态 GPT 模型或许能够在接受降雨雷达图等输入后，告知农场主“未来两天有强降雨，不宜施肥”。虽然此类应用尚在探索中，但技术趋势表明，将深度学习和气象科学结合，可以更好地服务农业生产决策。

## 6.8 知识问答与决策支持

农业生产涉及复杂的知识体系和决策过程，包括病虫害防治、作物栽培措施、气象灾害应对等方面的知识。以往农民主要通过农业技术推广人员（农业 Extension 服务）获取指导，但传统推广服务存在覆盖面有限、个性化不足的问题。大语言模型（LLM）的出现为农业知识获取和决策支持提供了新的可能。借助训练自海量文本的大模型，可以构建面向农业领域的智能问答系统和决策支持助手，实现对农户和农业从业者的 7×24 小时知识服务。

### 6.8.1 农业领域的大模型评测

将大模型应用于农业知识的问答系统，可以大幅提升农业技术信息的获取效率。在广袤的农业知识领域，包括作物栽培、植物保护、农业政策等，大模型经过预训练已经积累了大量相关常识和专业知识。通过精心设计，这些模型可以为农民、农技推广人员提供交互式的问答服务。

Silva 等评估了 GPT-4 等大模型在农业领域的应考能力。他们选取巴西、印度、美国三国的农业执业资格考试题和农学专业试题，让模型作答并与人类成绩对比。结果显示，GPT-4 在巴西农艺师资格续证考试中正确率达 93%，超过了人类

考生的及格线和一些往年平均表现。在部分测试中，GPT-4 的得分甚至高于人类平均水平。这一成绩表明，大模型已经具备了相当于资深农业技术员的知识储备，能够回答高难度的农业专业问题。这为开发智能农技顾问奠定了基础。

Tzachor 等评估了大模型对农业推广服务的潜在影响。他们聚焦于 LLM（特别是 GPT 类模型）将复杂农业科学知识转化为通俗实用建议的能力，并探讨了 LLM 提供个性化、基于数据的种植方案的可能性。研究通过让 GPT 模型为尼日利亚木薯种植户生成技术建议进行测试，结果发现这些模型确实能够根据土壤和气候等信息给出一定合理性的种植与管理建议。然而，他们也指出现阶段 LLM 在农业领域存在明显短板，例如在病虫害具体防治和土壤肥力管理上，模型可能给出不准确甚至错误的建议。

### 6.8.2 针对农业的领域预训练模型

为提升大模型在农业领域回答专业问题的能力，一些研究致力于构建面向特定领域的预训练模型。Yang 等开发了"PLLaMa"模型，它基于 LLaMA-2 大语言模型，通过加入超过 150 万篇植物科学文献语料进行再训练，极大地丰富了模型在植物和农业科学方面的知识。初步测试表明，经过领域知识增强的 PLLaMa 在植物病理、作物生理等相关问答上表现出比通用模型更深刻的理解力。

此外，该团队还组建了一个包含植物学家、农学工程师、育种专家在内的国际专家小组，对 PLLaMa 回答的专业问题进行验证。专家反馈用于不断改进模型，使其回答更加严谨准确。这种"专家校准+开放源码"的模式确保了领域大模型既有高水平的知识储备，又逐步纠正错误、贴近实际需求。PLLaMa 的问世标志着面向农业科研和生产问答的专用大模型成为可能，未来类似的专业模型（如畜牧业 LLM、土壤肥料 LLM 等）也有望出现。

### 6.8.3 知识融合与问答系统

除了训练领域专用模型，另一方向是将知识库与 LLM 结合，构建更可靠的农业决策支持系统。例如前文提到的赵新艳等的工作，将农业知识图谱用于增强 LLM 在植物病害问答中的准确性。他们通过在 LLM 检索答案时引入权威的结构化知识，避免了模型凭空编造不实信息，从而提高了回答的可信度。

同样，Jiang 等提出了一种"知识整合"的农业大语言模型框架：通过让 LLM 学习融合现有农业数据库和文献的知识，将显著提升模型对专业问题的作答水平。这些尝试反映出一个趋势——纯粹让 LLM"记住"一切农业知识并不现实，更可行的是让其与现有知识体系联动，在需要时调用外部知识来源来辅助推理。在保证知识的新颖性和广度，提高了准确性。

为了提高农业问答系统的可靠性，近期研究还探索了检索增强型生成（RAG）等技术，将大模型与农业知识库相结合。具体做法是先让系统从权威农业资料（如 FAO 手册、科研论文、国家推广指南）中检索出与提问相关的文本段落，再提供给大模型参考作答。这样生成的答案不仅准确率更高，而且可以给出依

据来源，增加说服力。在 Silva 等的试验中，采用检索增强和算法优化后的 GPT-4 对一些复杂农业问答的准确率相比纯 GPT 提升了 5-10 个百分点。这表明，将通用大模型与领域知识紧密结合是提升专业问答质量的有效路径。

#### 6.8.4 实际应用案例

更贴近应用层面，大模型驱动的问答系统可以为广大农民提供定制化的信息服务。传统的农业咨询往往受限于人力，很多小农户难以及时得到专家指导。ChatGPT 等通用对话模型的出现，使构建农业聊天助手成为可能。

科研人员对 ChatGPT 的农业问答能力进行了初步测试：Tzachor 等收集了尼日利亚水稻种植户提出的 32 个实际问题（涵盖施肥、病虫、灌溉等），让 ChatGPT 和当地 6 位农技推广员分别作答。然后请资深专家对回答的质量和本地相关性进行盲评。结果 ChatGPT 的答案平均得分显著高于人类农技员提供的答案，78% 的问题评审更偏好 ChatGPT 的回答。尤其在回答施肥技巧、防治措施等方面，AI 助手给出了更加详细和规范的建议，在 40% 的问题上被评为“最佳答案”，而人类推广员仅在 7% 的问题上最佳。

不过，研究也发现 ChatGPT 对于一些需要具体本地参数的问题（如适宜播种期、用种量和肥料用量）回答不够准确。这是由于模型缺乏当地经验数据支持。因此作者强调，应将 AI 助手与本地知识相结合，例如接入本地农业知识图谱或数据库，以提供因地制宜的建议。

#### 6.8.5 多模态农业知识服务

在农场管理决策支持方面，大模型也开始崭露头角。例如，Dofitas 等研究了利用多个大语言模型集成来回答农业查询，以提高答案可靠性的策略。他们的系统针对同一农学问题调用多个 LLM 并综合它们的回答，从中挑选最符合专家知识的答案，从而减少单一模型出错的风险。此类“模型组协作”方式有望为农业决策提供更稳健的建议。同时，一些针对特定决策问题的模型也在开发中，比如面向农产品市场预测的时间序列大模型、用于种植结构优化的规划模型等。这些都属于广义的决策支持范畴。

目前，各类面向农业的智能问答和决策支持系统正蓬勃兴起。例如，有的团队开发了面向养殖场的智能助手，可以回答畜禽疾病诊断和配方饲料调制问题；有的则面向农业政策，为农场主解读补贴条款和贷款信息。这些系统可以基于预训练语言模型，通过指令微调和知识整合实现。

展望未来，农业知识服务有望进入一个智能化新阶段。大模型驱动的问答系统将不仅限于文字交流，还可以通过语音对话、图片识别等多模态交互，更友好地服务一线从业者。想象一个场景：农民用手机拍摄了田间生病作物的照片上传，AI 助手借助视觉大模型诊断病害并语音讲解防治措施，同时将建议发送到农民的信息终端。这背后涉及的图像识别（可由如 AgriCLIP、SAM 等模型完成）和语言对答（由 GPT 类模型完成）都属于大模型的应用范畴。目前微软等公司提出的多模态

大模型（如 Kosmos-1/2）正朝这个方向发展。可以预期，在不久的将来，一个融合视觉、语音和文本的大型多模态模型将成为农业数字助理的核心，引领农业知识服务进入智能时代。

### 6.8.6 伦理考量与人机协作模式

在应用大模型进行农业问答和决策时，也需注意其局限和伦理问题。首先是幻觉和错误：LLM 有时会给出看似权威但实则错误的回答，如果直接被农民采纳可能造成损失。因此必须建立信息校验机制，如上述专家审核或知识库交叉验证。

为此，提出一个理想的农业 LLM 设计流程：在模型生成建议的过程中引入人工专家审核环节（human-in-the-loop），以确保内容安全可靠。这个研究为农业知识问答系统的开发提供了重要指导，即大模型可以作为强大的信息引擎，但最终建议的把关仍需要领域专家参与。

其次是本地化问题：农业实践高度依赖本地环境，一个在北美训练的模型未必适用于非洲小农情境。因此需要通过少样本微调来本地化模型，让其了解本地作物品种和气候土壤特征。再次是数据隐私和安全：农场的生产数据如果用于训练决策模型，需注意保护农户隐私，以及模型建议中不要涉及敏感信息。最后，不能忽视人机协作的重要性。真正有效的农业智能系统应当是"AI+专家"的模式，模型提供初步方案，专家根据实际经验调整优化，这样才能兼具效率和可靠性。

综上，大模型在农业知识问答与决策支持方面展现出广阔前景。从农业知识的获取、问题解答，到种植方案的制定，都可以看到大模型的身影。然而，要让农民和农业从业者真正信任并受益于这些 AI 助手，仍需要技术和应用模式上的完善。随着领域大模型的不断涌现和人机协同机制的成熟，我们有理由期待，一个懂农业、会思考的"数字农业顾问"将走进千家万户，帮助人们做出更明智的农业决策。

## 6.9 结论与展望

大模型技术在农业领域的应用正逐步从研究走向实践，为传统农业带来了智能化变革。首先，大模型的预训练-微调范式在农业中显示出独特优势。由于农业数据的获取成本高、标注难度大，传统深度学习方法常受限于小样本问题。而大模型通过大规模预训练获得的通用特征表示，能够在极少标注数据的情况下，快速迁移到特定农业任务，实现"小数据大能力"。无论是作物识别、病害诊断还是产量预测，都能从这一特性中受益。

其次，多模态融合成为农业大模型的重要发展方向。农业生产涉及视觉（卫星、无人机图像）、文本（专业知识）、时序（气象、传感器数据）等多种信息源，而大模型提供了统一表示和处理这些异构数据的框架。例如多模态时空 Transformer 能同时处理卫星影像和气象数据预测产量；视觉-语言模型可用于病害识别与解释；大语言模型可与知识图谱结合提供专业咨询。这些多模态应用有效打破了农业信息孤岛，为决策提供了更全面的依据。

第三，大模型推动了农业决策的智能化和自动化。从田间作业层面的机器人控制、到农场管理层面的资源分配、再到区域层面的产量预测，大模型的决策能力展现出层次性。特别是结合强化学习技术，大模型有望优化动态生产过程，在不确定环境中做出适应性决策，比如优化灌溉方案或制定植保策略。

然而，大模型在农业中的应用仍面临挑战。一方面是技术适应性问题：农业环境复杂多变，区域差异巨大，如何保证模型在不同条件下保持一致性能是关键挑战。另一方面是落地部署问题：农村地区网络和算力受限，如何实现大模型的轻量化和边缘部署成为实际应用的瓶颈。此外，还有可解释性、数据隐私和伦理问题需要关注。

展望未来，随着更多专用农业大模型的出现、边缘计算能力的提升以及人机协作模式的成熟，大模型技术将能更好地服务于农业生产的各个环节。我们可以期待一个智能农业新时代：田间有自主决策的农业机器人，农民手中有智能农技顾问，决策者面前有精准的农情分析系统，这些都将由不同形式的大模型作为核心引擎来驱动。最终，大模型技术的广泛应用有望助力农业提质增效、减轻劳动强度、应对气候变化和保障粮食安全，为实现可持续农业发展贡献力量。但也需要强调，技术发展应当以人为本，大模型应作为辅助工具而非替代农业专家和农民的经验智慧，只有将 AI 与人类知识有机结合，才能发挥出最大效益，创造更加美好的农业未来。

## 第 6 章参考文献

- [1] Alexander Kirillov et al. “Segment anything”. In: Proceedings of the IEEE/CVF international conference on computer vision. 2023, pp. 4015–4026.
- [2] Rutuja Gurav et al. “Can SAM recognize crops? Quantifying the zero-shot performance of a semantic segmentation foundation model on generating crop-type maps using satellite imagery for precision agriculture”. In: arXiv preprint arXiv:2311.15138 (2023).
- [3] Dominic Williams, Fraser Macfarlane, and Avril Britten. “Leaf only SAM: A segment anything pipeline for zero-shot automated leaf segmentation”. In: Smart Agricultural Technology 8 (2024), p. 100515.
- [4] Umair Nawaz et al. “AgriCLIP: Adapting CLIP for Agriculture and Livestock via Domain-Specialized Cross-Model Alignment”. In: arXiv preprint arXiv:2410.01407 (2024).
- [5] Xue Jiang et al. “PlantCaFo: An efficient few-shot plant disease recognition method based on foundation models”. In: Plant Phenomics 7.1 (2025), p. 100024.

- [6] Yiyi Cao et al. “Cucumber disease recognition with small samples using image-text-label-based multi-modal language model”. In: *Computers and electronics in agriculture* 211 (2023), p. 107993.
- [7] Muhammad Arbab Arshad et al. “Leveraging Vision Language Models for Specialized Agricultural Tasks”. In: *2025 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*. IEEE. 2025, pp. 6320–6329.
- [8] Thanh-Dat Truong et al. “Insect-Foundation: A Foundation Model and Large Multimodal Dataset for Vision-Language Insect Understanding”. In: *arXiv preprint arXiv:2502.09906* (2025).
- [9] Roberta Calone et al. “Analysing the potential of ChatGPT to support plant disease risk forecasting systems”. In: *Smart Agricultural Technology* (2025), p. 100824.
- [10] Fudong Lin et al. “Mmst-vit: Climate change-aware crop yield prediction via multimodal spatial-temporal vision transformer”. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2023, pp. 5774–5784.
- [11] Luning Bi et al. “A transformer-based approach for early prediction of soybean yield using time-series images”. In: *Frontiers in Plant Science* 14 (2023), p. 1173036.
- [12] Boje Deforce, Bart Baesens, and Estefanía Serral Asensio. “Time-Series Foundation Models for Forecasting Soil Moisture Levels in Smart Agriculture”. In: *arXiv preprint arXiv:2405.18913* (2024).
- [13] Bhumika Fattepur et al. “Cultivating Prosperity: A Fusion of IoT Data with Machine Learning and Deep Learning for Precision Crop Recommendations”. In: *2024 5th International Conference for Emerging Technology (INCET)*. IEEE. 2024, pp. 1–6.
- [14] Yuji Saikai, Allan Peake, and Karine Chenu. “Deep reinforcement learning for irrigation scheduling using high-dimensional sensor feedback”. In: *PLoS Water* 2.9 (2023), e0000169.
- [15] Dong Chen and Yanbo Huang. “Integrating reinforcement learning and large language models for crop production process management optimization and control through a new knowledge-based deep learning paradigm”. In: *Computers and Electronics in Agriculture* 232 (2025), p. 110028.
- [16] Bruno Silva et al. “GPT-4 as an agronomist assistant? Answering agriculture exams using large language models”. In: *arXiv preprint arXiv:2310.06225* (2023).
- [17] Dasom Seo and Il-Seok Oh. “Gripping Success Metric for Robotic Fruit Harvesting”. In: *Sensors (Basel, Switzerland)* 25.1 (2024), p. 181.

- [18] Xiao Yang et al. “Sam for poultry science”. In: arXiv preprint arXiv:2305.10254 (2023).
- [19] Francesco Stella, Cosimo Della Santina, and Josie Hughes. “How can LLMs transform the robotic design process?” In: *Nature machine intelligence* 5.6 (2023), pp. 561–564.
- [20] Yunbi Xu et al. “Smart breeding driven by big data, artificial intelligence, and integrated genomic-enviromic prediction”. In: *Molecular Plant* 15.11 (2022), pp. 1664–1695.
- [21] Javier Mendoza-Revilla et al. “A foundational large language model for edible plant genomes”. In: *Communications Biology* 7.1 (2024), p. 835.
- [22] Asaf Tzachor et al. “Large language models and agricultural extension services”. In: *Nature food* 4.11 (2023), pp. 941–948.
- [23] Xianjun Yang et al. “Pllama: An open-source large language model for plant science”. In: arXiv preprint arXiv:2401.01600 (2024).
- [24] Jingchi Jiang et al. “Knowledge assimilation: Implementing knowledge-guided agricultural large language model”. In: *Knowledge-based systems* 314 (2025), p. 113197.
- [25] Cyreneo Dofitas, Yong-Woon Kim, and Yung-Cheol Byun. “Advanced Agricultural Query Resolution Using Ensemble-Based Large Language Models”. In: *IEEE Access* (2025).

# 7.大语言模型在作物育种与精准农业中的应用

作物育种与田间管理正处于“数据爆发+技术迭代”的关键时期。几乎每天都有新的基因组测序数据和育种实验报告面世，各类遥感影像与地面传感数据铺天盖地而来，专家经验和科研文献中蕴藏的知识流如涓涓细流涌向数字化平台。面对如此海量且多样的信息源，传统的人工检索难以应对，简单的规则匹配难以深入。大语言模型恰如其时地被引入这一领域，凭借对自然语言的深度理解能力和对多模态信息的融合潜力，为基因组学文本挖掘、田间环境监测与智能决策交付提供了全新的思路。

第七章围绕四大核心场景展开技术论述，其整体应用框架可直观呈现为图 7-1。该框架以“数据输入—技术处理—决策输出”三层架构，系统展示了大语言模型从信息整合到智能决策的全链条能力：在基因组学与育种文本分析中，通过命名实体识别（NER）与关系抽取（RE）技术构建“基因-性状-环境”知识图谱，辅助高通量筛选；在田间管理环节，通过多模态数据融合与自然语言生成技术，将遥感指标转化为可读的田间管理建议；在智能水肥交互场景中，结合作物生长模型与模型预测控制（MPC）算法，通过对话交互输出精准灌溉施肥策略；在病虫害防治领域，依托检索增强生成（RAG）技术与知识图谱，实现病害诊断与防治方案的自动化生成。

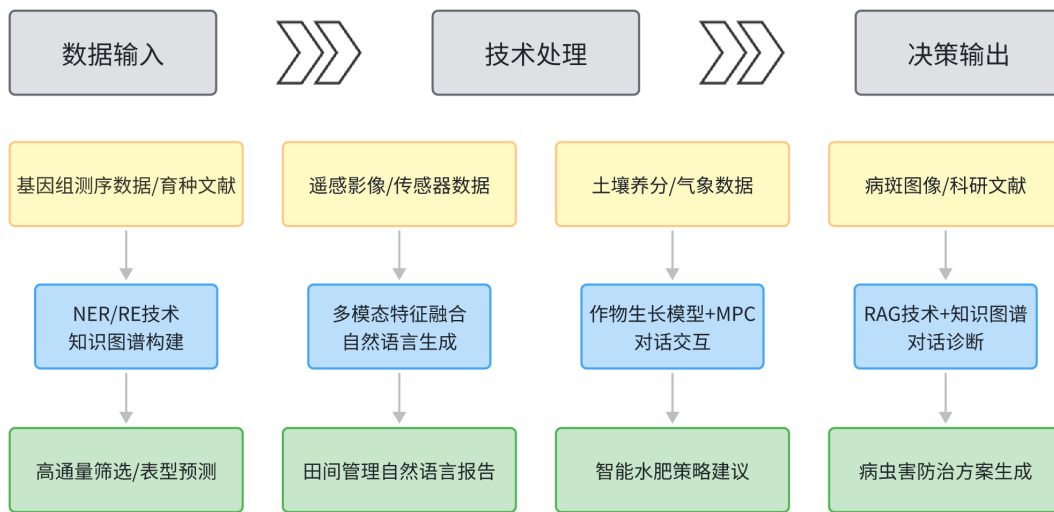


图 7-1 大语言模型在作物育种与精准农业中的应用框架图

作物育种过程中，基因与表型之间的关联是一张错综复杂的大网。过去需要大量人工梳理文献、挖掘实验结果，才能定位有价值的基因位点并制定育种策略。大语言模型通过对海量育种文献和基因组注释的深度学习与语义表示，能够自动提取基因名称、突变类型、性状描述等信息，并借助关系抽取技术绘制“基因-性状-环境”知识图谱。借助这一图谱，研究者在进行高通量筛选时能够快速锁定潜在候选基因组合，并结合历史实验数据进行精准预测，将繁琐的手动分析过程转化为自动

化的数据驱动流程。与此同时，将基因组序列视作“生物语言”并进行预训练，能够让模型更好地理解基因片段和功能注释之间的深层语义关系，从而在小样本条件下也能提供精准的表型预测，为下一步选育试验提供方向。

田间管理环节中，遥感图像、无人机航拍和地面传感器实时监测共同构成了一套复杂的多模态数据体系。大语言模型能够把图像中的植被指数、土壤含水量等指标解码为自然语言报告，让农户以“可读的”形式快速掌握田间状况。例如，一张多光谱遥感图判定作物长势偏弱后，模型可利用图像字幕技术生成“该地块植被指数偏低，可能需补充氮肥并增加灌溉量”的建议。再联合气象模型提供的温度与降雨预报，将多个数据源关联效果融入一段可执行的灌溉策略描述。通过这种方式，田间管理变得直观、可操作，农户无需深入学习专业指标，就能凭借通俗的文字报告完成精准决策。

在智能施肥与灌溉辅助交互场景中，大语言模型承担的角色更像一名数字农技顾问。农户通过自然语言提问，“今天要不要给小麦追加氮肥？”“明早田间是否适合灌溉？”系统便在后台完成对土壤养分、作物生长期、遥感植被指数与未来天气预报的多源数据整合。将这些特征输入到集成了作物生长模型与预测控制算法的代理模型后，得出最优水肥方案，再由大语言模型将复杂的数值计算结果翻译为“今晚安排 8 毫米灌溉，分两次进行；明天傍晚补施 20 公斤尿素”的清晰建议。整个过程流畅自然，既保留了科学依据，又降低了用户理解门槛。

病虫害防治环节的智能化，更依赖于对多源信息的一体化理解。科研文献中关于病原类型、传播途径和防治配方的描述往往繁杂难读，遥感或无人机拍回的作物病斑图像又需要专业知识才能识别。大语言模型通过检索增强生成技术，能将用户上传的叶片照片与知识库中对应的病害图谱进行快速匹配，结合对话式交互迅速定位病害类型。随后，系统自动检索对应该病害的防治方案文本，并生成“当前田块发现叶斑病初期症状，推荐喷施铜制剂 0.3%，并在三日后复查。如雨后高温，请避免过度施药造成作物灼伤”的防治建议。知识图谱与对话模块协同，确保方案既有权威文献支撑，又易于农户理解与执行。

作物育种与精准农业的发展呼唤更加紧密的技术与生产融合。大语言模型与多模态数据的协同应用，为农技工作者和科研人员提供了从文献挖掘到田间执行的端到端解决路径。借助基因组学文本分析，研究者能够快速构建针对性知识图谱并辅助高通量试验；通过遥感与传感数据融合解读，田间管理人员可在自然语言报告中获取全局视角；在交互式灌溉与施肥系统中，模型担当智能顾问，让农户时刻掌握最佳水肥策略；在智能防治知识库中，模型将复杂病虫害防治逻辑浓缩为可操作建议，实现“对话即决策”。第七章正围绕这四大场景展开，旨在展示大语言模型如何在作物育种与精准农业领域打开新的应用格局，帮助农业生产迈向更高效率、更低成本和更可持续的未来。

## 7.1 基因组学与育种文本数据分析

随着基因组学的迅速发展和高通量测序技术的广泛应用，作物育种领域正逐渐步入一个信息大爆发的时代。每年发表的基因组相关文献、育种实验报告和表型数据集正以指数级速度增长。这些文献和实验报告中蕴藏着丰富的遗传信息、基因功能描述、性状关联发现，以及育种策略的经验和实验成果。然而，传统的人工检索、分类、阅读和分析方法已经难以高效处理这种规模庞大、类型多样、更新迅速的海量文本信息，导致大量有价值的数据和知识难以被充分挖掘和利用。为应对这种挑战，大语言模型开始被逐步引入基因组学与育种研究，通过其强大的自然语言理解与知识表示能力，实现对高通量文本信息的快速处理、自动化知识抽取与高效的综合分析。这种方法不仅大幅提高了文献分析和数据利用效率，也为作物育种的创新性研究提供了新的数据驱动型技术范式。

基因组学与作物育种领域的文献资源具有显著的结构化与非结构化信息交织的特征：一方面，文献中包含大量规范化描述的实验数据、基因序列、突变信息、性状关联的统计学分析结果等结构化数据；另一方面，也存在大量研究者的推测性叙述、实验方法细节、观察结果及推论等非结构化文本。大语言模型因其在自然语言理解方面的强大泛化能力，特别适合处理这种结构化与非结构化并存的复杂文献资源。例如，BERT[2]、GP 等预训练模型在经过特定领域的微调后，能够迅速识别出文本中的基因位点、蛋白质序列及其对应的功能注释信息，提取出不同基因与具体表型之间的关系，并进而形成清晰的知识图谱。与传统的人工标注或基于规则的抽取方法相比，基于大语言模型的自动抽取方法在效率和准确性上都有显著提高，特别是对跨学科、跨物种研究成果的集成与分析更具优势。基于这种方法，研究人员可以高效地构建涵盖大量物种、基因、性状和实验条件的综合知识库，从而为深入的关联研究与育种策略优化奠定坚实的数据基础。

利用大语言模型对基因组学和育种文本数据进行信息抽取的流程一般包括两个关键步骤：首先是利用命名实体识别（Named Entity Recognition, NER）技术，从大量文本中自动检测和识别涉及基因组位点、基因名称、突变类型、相关蛋白质和具体的农艺表型（如抗旱、耐盐、抗病等）等重要信息。这一步骤旨在从复杂的文本描述中快速、准确地捕获涉及育种研究核心概念的语义单元。随后，再利用关系抽取（Relation Extraction, RE）技术，进一步分析文本中各个实体之间的逻辑关系，比如明确某个特定基因与特定作物表型之间的因果或关联关系，从而提取出具有高研究价值的结构化信息。这种由大语言模型驱动的自动化流程相比于传统人工标注或基于规则的抽取方法，具有更高的泛化能力和更强的跨文献适应性，能够高效地处理不同研究机构、不同研究团队乃至不同物种间发布的大量文献和实验报告。这种高度自动化的信息抽取能力使研究人员能够更迅速地建立起涵盖多种基因与表型关系的高质量知识库，从而有效缩短从信息获取到实际育种策略制定的周期。

在利用大语言模型对基因组学和育种文本数据进行信息抽取时，NER 是实现自动化知识提取的基础环节。通过 NER 技术，模型能够从非结构化文本中精准定

位基因名称、突变类型等核心实体，为后续关系抽取与知识图谱构建奠定基础。以 BERT 模型为代表的预训练架构在基因实体识别中展现出显著优势，以下通过具体工程化实现示例，展示从文本中提取基因名称的完整技术流程：

```
# 基于 BERT 的基因实体识别工程化实现示例

from transformers import BertTokenizer, BertForTokenClassification
import torch
import numpy as np

# 加载农业领域微调后的 BERT-NER 模型（以拟南芥基因识别为例）
# 注：实际应用中可使用 TAIR 数据库标注数据进行领域适配
tokenizer = BertTokenizer.from_pretrained("agri-bert-ner", do_lower_case=False)
model = BertForTokenClassification.from_pretrained("agri-bert-ner",
num_labels=3)

def gene_ner_pipeline(text: str) -> list:
    """基因实体识别完整流程：文本分词→模型推理→实体解码"""
    # 1. 文本预处理与分词
    inputs = tokenizer(
        text,
        return_tensors="pt",
        padding="max_length",
        truncation=True,
        max_length=128
    )

    # 2. 模型推理获取实体标签概率
    with torch.no_grad():
        outputs = model(** inputs)
        logits = outputs.logits # 输出形状: [batch_size, seq_length, num_labels]
```

```

# 3. 标签解码（映射 ID 到实体类型）

label_map = {0: "O", 1: "B-GENE", 2: "I-GENE"} # O=非实体, B=基因实体
起始, I=基因实体延续

predictions = torch.argmax(logits, dim=2).squeeze().tolist()
tokens = tokenizer.convert_ids_to_tokens(inputs["input_ids"].squeeze())

# 4. 实体边界识别与组合

entities = []
current_entity = []

for token, pred in zip(tokens, predictions):
    if pred == 1: # 新实体起始
        if current_entity:
            entities.append((" ".join(current_entity), "GENE"))
            current_entity = []
        current_entity.append(token)
    elif pred == 2 and current_entity: # 实体延续
        current_entity.append(token)
    elif current_entity: # 实体结束
        entities.append((" ".join(current_entity), "GENE"))
        current_entity = []

# 5. 还原原始文本中的实体位置（去除分词标记）

return _filter_bert_tokens(entities, text)

def _filter_bert_tokens(entities: list, original_text: str) -> list:
    """过滤 BERT 分词产生的特殊标记（如##），匹配原始文本实体"""
    filtered_entities = []

```

```

for entity_text, entity_type in entities:
    # 去除 BERT 分词添加的##前缀
    clean_text = entity_text.replace("##", "")
    # 匹配原始文本中的实体位置（简化实现）
    if clean_text in original_text:
        filtered_entities.append((clean_text, entity_type))
return filtered_entities

# 应用示例：识别文献摘要中的基因实体

example_text = "The transcription factor TaDREB2A was found to enhance drought
tolerance in wheat by regulating the expression of stress-responsive genes. Another gene,
TaNAC67, showed similar functions in rice under salt stress."

gene_entities = gene_ner_pipeline(example_text)
print("识别到的基因实体：")

for entity, typ in gene_entities:
    print(f"- {entity} (类型: {typ})")

# 输出结果：

# 识别到的基因实体：

# - TaDREB2A (类型: GENE)

# - TaNAC67 (类型: GENE)

```

以示例文本为例，模型准确识别出“TaDREB2A”和“TaNAC67”两个基因实体，为后续构建“基因 - 耐旱性 - 小麦”“基因 - 耐盐性 - 水稻”等关系三元组提供了基础数据。这种从非结构化文本到结构化实体的转换能力，正是大语言模型驱动育种知识图谱构建的核心技术支撑。

在基因组学研究育种实践中，大语言模型所构建的基因—表型关联信息库，进一步为高通量筛选技术（High-throughput Screening, HTS）提供了强大的智能辅助。高通量筛选技术通常涉及在短时间内对大量遗传变异体或突变体进行表型测试与评估，以快速识别对目标性状（如抗病、抗逆境或产量提升）有积极贡献的基因变异组合。然而，这种技术所产生的海量数据通常需要后续复杂的分析与解释，尤其是要从大量初步筛选结果中确定真正有价值的目标基因或突变类型，并设计下一

步育种实验。通过大语言模型的介入，研究人员可以快速地将高通量实验数据与已有的文献知识进行自动比对与整合，利用模型强大的推理和决策能力自动过滤掉无关或冗余的信息，将重要的潜在基因或性状信息突出显示。同时，模型还能根据历史文献和实验经验，智能推荐进一步实验所需的最优基因组合或育种策略。这种方法不仅显著加速了基因功能验证和目标性状的发现过程，还有效地降低了传统方法中由于人工判断和经验局限性带来的偏差和遗漏，极大地提高了育种流程的准确性与效率。

在进一步应用大语言模型辅助高通量筛选与作物品种改良的过程中，关键的技术突破点在于如何实现对基因组—表型关联信息的高效融合与深度挖掘。其中一个重要的技术环节便是基于大语言模型的“表型预测”（Phenotype Prediction）。表型预测的基本任务可以定义为：在给定一组基因型数据的前提下，通过已有的基因与表型关联知识，预测该基因型组合可能表现出来的作物性状。这类预测任务本质上是对基因型—表型映射关系的一种条件概率建模（Conditional Probability Modeling），形式化地，可以描述为：

$$P(Y|G) = f_{\theta}(G)$$

其中 $G$ 表示输入的基因型数据，通常以特定基因座上的遗传变异、基因表达谱或单核苷酸多态性标记形式出现；而 $Y$ 为目标预测的农艺性状表现（例如抗旱性、生长期、产量潜力等）， $f_{\theta}$ 则是由大语言模型及其扩展模块共同构成的预测函数，参数 $\theta$ 在训练阶段通过历史实验数据与文献知识进行优化调整。大语言模型可以首先从大量育种文献和实验记录中自动抽取已知基因型—表型关联数据，并将其存储在结构化或半结构化的知识库中，以此为基础训练一个专门的预测模块。当新的基因型数据进入时，该预测模块便能够快速结合已有知识，根据历史数据推断该基因型可能表现出的性状特征。与传统统计学方法（例如线性混合模型或回归分析）不同，大语言模型驱动预测模块能够同时处理大规模异构数据，并且能捕捉到基因组内部复杂的非线性相互作用和交叉效应。这种方法不仅可以提高对作物性状预测的准确性，也能极大降低育种过程中的时间和资源投入，使育种人员能够快速聚焦到最有潜力的候选基因组合或品种上，从而大幅提升育种工作的整体效率和创新能力。

除了上述基因互作网络分析之外，大语言模型还能够为育种研究提供更进一步的“智能文献挖掘与假设生成”（Literature-based Discovery, LBD）能力。这种方法旨在利用已公开发表的海量研究文献，从已有知识的交集和边界区域中自动生成新的科研假设，以启发下一步的研究方向和实验设计。这一过程通常涉及三个步骤：

- **第一步：知识检索和整合。**利用大语言模型的语义搜索和文本检索能力，从各大公共数据库（如PubMed、Web of Science）中筛选出与特定研究问题高度相关的文献集合。这些问题可能包括特定作物性状的基因控制机制、特定环境胁迫下的作物响应途径、以及潜在的未被充分研究的基因功能等。
- **第二步：知识图谱构建和推理。**基于检索到的文献集，大语言模型进一步通过自动化信息抽取与融合，建立综合性的育种领域知识图谱（Breeding

Knowledge Graph, BKG)。BKG 包含多种节点类型（如基因、蛋白质、表型、环境因素）和多种关系类型（如作用关系、因果关系、伴随关系），为下一步推理奠定基础。

- **第三步：自动假设生成与筛选。**在构建好的知识图谱上，应用知识推理方法（如链式推理、路径分析等），自动探索尚未直接研究但逻辑上可能存在关联的知识节点。例如，如果文献中已分别描述“基因 A 影响性状 B”以及“性状 B 与环境因素 C 存在关联”，模型可能推导出“基因 A 在环境因素 C 下可能具有特殊的功能或表达模式”，从而生成具有科研价值的新假设。

假设生成的质量可通过计算推理路径的可信度和支持文献数量进行量化评估。例如，可定义假设生成的可信度由路径长度、支持文献、语义相似性决定，路径长度越短、支持文献越多、语义相似性越高，则假设可信度越高。研究人员据此对自动生成的假设进行人工或半自动筛选后，可选择最具价值的假设进行下一步实验验证或深入研究。

尽管基于大语言模型的育种文本数据分析和信息抽取技术已取得了初步成功，但在实际应用中仍然面临一些重要的技术性挑战。其中最主要的是育种领域的专业术语规范化与同义实体消歧问题。育种与基因组学领域的文献通常涉及大量跨物种、跨实验、跨实验室的术语与命名惯例差异，许多相同或高度相似的基因、蛋白质或性状在不同研究中可能采用不同的命名方式或代码（例如不同的数据库编号、命名缩写等）。如果这些术语和实体无法实现准确、统一的标准化映射，将严重制约信息抽取结果的可靠性与泛化能力。

针对这一问题，目前较为常用的解决方案是采用基于大语言模型与领域知识库结合的联合消歧方法（Joint Disambiguation Method）。将术语规范化问题描述为：给定文献中的一个术语或实体表达 $t$ ，以及一个标准领域知识库 $KB$ 中的实体集合 $E = \{e_1, e_2, \dots, e_n\}$ ，目标是找到一个或多个最佳匹配的标准实体 $e^* \in E$ ，满足条件：

$$e^* = \operatorname{argmax}_{e \in E} P(e|t, C)$$

其中 $C$ 表示术语或实体所在的上下文信息（如相邻词汇、句子语义、篇章语义），而条件概率 $P(e|t, C)$ 可通过大语言模型来学习或预测。具体方法包括：

- **基于语义嵌入（Semantic Embedding）的方法：**通过大语言模型构建实体或术语的语义向量表示（Embeddings），并利用余弦相似度（Cosine Similarity）或其他相似度指标在标准实体库中进行匹配。
- **基于多任务学习（Multi-task Learning）的方法：**在训练大语言模型时，加入术语消歧和规范化的辅助任务，引导模型在预训练和微调阶段自动学习同义实体的映射关系，提升模型在真实育种文献数据中的消歧表现。
- **基于知识增强（Knowledge-enhanced）的方法：**结合外部领域知识库（如TAIR、MaizeGDB、Rice Genome Annotation Project等权威植物基因库），

利用大语言模型的注意力机制（Attention Mechanism）实现领域知识与文献语境的精确匹配，从而提升术语规范化和实体消歧效果。

通过以上方法，有望有效解决育种领域中术语标准化的技术瓶颈，从而为后续更精准的知识图谱构建、基因网络分析、表型预测和智能假设生成等复杂任务奠定可靠的数据基础。这种标准化处理方式不仅提高了大语言模型分析育种文本的准确性和泛化性，也极大地增强了模型在实际育种研究场景中的可落地性。

综上所述，基于大语言模型的基因组学与育种文本数据分析技术，已初步展现出在海量文献信息处理、基因-表型关联知识抽取、高通量基因筛选辅助、基因互作网络分析以及智能假设生成等多个方向的巨大潜力。这些创新技术与方法，不仅有效地缓解了传统育种信息处理手段面临的效率瓶颈，更深刻地改变了作物育种领域从数据获取、分析到决策支持的整体范式。特别是通过自然语言理解能力的持续进步，大语言模型为育种研究人员提供了一种全新的、自动化的知识发现工具，帮助其快速定位关键基因、精确识别育种策略、并优化实验设计，从而显著提高了育种研发效率。然而，当前该领域的研究与应用仍处于发展阶段，面临一些不容忽视的技术挑战。育种领域专业术语的规范化与实体消歧问题依然严峻，尤其在跨物种和跨实验环境的数据处理中表现明显，亟需发展更加鲁棒且高效的术语标准化方法。大语言模型在基因型-表型预测任务中的泛化性与鲁棒性尚待进一步提升，尤其是在数据稀疏或噪声较大的实际育种环境下，模型的表现仍存在较大波动。此外，大语言模型的决策过程可解释性问题也亟待解决，研究人员和育种专家更倾向于理解和信任基于模型做出的预测与建议，而非将其作为“黑盒”来盲目信赖。

面向未来，基因组学与育种文本数据分析的研究应从以下几个方向深入推进：一是发展融合领域知识与大语言模型的混合方法，提高模型在复杂育种场景下的信息抽取和预测能力；二是加强跨学科协作，利用更多高质量、多模态的实验数据和真实农业场景信息，不断优化和校正大语言模型在实际场景中的表现；三是探索模型的可解释性和透明性框架，使其能够为研究人员提供可追溯的推理链条，提升科研决策的可信度和接受度。随着这些技术挑战逐步得到解决，基于大语言模型的基因组学与育种文本数据分析方法必将对农业现代化与可持续发展作出更为突出的贡献。

## 7.2 田间管理与遥感数据的融合解读

随着遥感技术与传感器网络的广泛应用，田间管理领域逐步进入了一个精细化与数据驱动的新时代。卫星遥感、无人机航拍和地面传感器网络构成了农业数据采集的重要支撑体系，这些系统可以提供覆盖面积大、空间分辨率高且时间连续的田间数据，包括土壤湿度、植被指数、作物生长状况、病虫害分布情况等。然而，这类高维度、多源异构的数据通常以复杂图像和时空序列数据的形式呈现，直接供给农户或农业管理者往往难以快速准确地理解和决策。为了解决数据与用户间的沟通鸿沟，将这些遥感数据和图像分析结果精准、高效地转化为人类易于理解的自然语言描述变得尤为重要。大语言模型凭借其出色的自然语言生成（Natural Language Generation, NLG）和跨模态推理能力，正逐渐成为解决这一问题的重要技术手

段。通过将遥感数据处理结果自动转化为清晰易懂、逻辑严谨的文字报告，不仅能够提高数据的可用性与用户体验，也能帮助农业生产者和决策者更及时、更准确地做出适宜的田间管理决策。

遥感数据向自然语言的自动转换，涉及跨模态信息融合（Cross-modal Information Fusion）这一技术核心。跨模态信息融合可定义为从不同感知渠道获取的数据（例如遥感图像、土壤湿度传感器读数、气象数据等），通过统一的语义映射和高层次理解，自动转化成一致的自然语言描述。这种过程通常包含两个关键步骤：首先是对遥感数据与地面监测数据进行预处理、特征抽取与模式识别；其次是利用大语言模型对这些抽取后的特征和模式进行语义转化，生成自然语言报告。

在第一个步骤中，一般使用卷积神经网络、循环神经网络或 Transformer 等模型，对多源数据进行特征抽取和整合，得到描述作物长势、土壤状态或病害分布的高层语义特征。这些特征可以通过空间、光谱或时序分析算法生成，如常用的归一化植被指数（NDVI）定义为：

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

其中，NIR 为近红外波段反射率，Red 为红色波段反射率。NDVI 能够有效地反映作物的健康状况、生物量以及光合作用能力。在第二个步骤中，大语言模型将自动抽取的遥感特征及指标转化为直观易懂的文字叙述，例如“当前田块植被指数高于历史同期水平，表明作物生长状态良好，无明显干旱胁迫迹象。”这一转化过程通常采用基于预训练的大语言模型（如 GPT 系列），通过微调方式适配农业遥感数据的特定语境，自动生成能够辅助农户、专家或决策者进行快速、有效决策的文本报告。这种方式显著提高了遥感数据利用效率，使农业决策过程更为透明、高效。

具体到遥感数据自动解读的技术实现上，利用大语言模型将图像分析结果转化为自然语言的过程一般采用图像-文本生成（Image-to-Text Generation）框架。这一框架的技术核心即为图像字幕（Image Captioning）任务，可以被严格定义为：给一幅图像或遥感数据处理的特征图，生成一段准确描述其内容的文本序列。形式化地，图像字幕任务可以用以下条件概率模型表示：

$$P(Y|I; \theta) = \prod_{t=1}^T P(y_t | y_1, y_2, \dots, y_{t-1}, I; \theta)$$

其中  $I$  表示输入图像（或遥感数据特征图）， $Y = (y_1, y_2, \dots, y_T)$  表示生成的自然语言描述， $\theta$  为模型的参数，通常通过深度学习方法训练获得。在实践中，这类任务通常采用“编码器-解码器”（Encoder-Decoder）框架，其中编码器负责从遥感图像或时序数据中抽取特征并生成一个语义嵌入（Semantic Embedding），解码器（如基于 Transformer 架构的 GPT 模型）则通过注意力机制（Attention Mechanism）动态地关注图像特征的不同区域或时序数据的不同时间步，并逐步生成自然语言描述。例如，当输入一幅无人机拍摄的田块高光谱图像时，编码器首先提取出植被指数、叶绿素含量或水分胁迫相关的空间特征，随后解码器利用注意力机制决定每个

生成步骤关注图像中的哪些特定区域，从而生成描述文本如“田块北部区域叶绿素含量低于正常值，可能存在氮肥缺乏或病害感染风险”。相比传统人工解读或依赖专家经验的方式，这种方法极大地提高了分析的效率和可扩展性，并且可自动、实时、批量地处理大范围遥感数据，为农业专家和农户提供及时的田间管理指导信息。

在精准农业决策中，除了利用遥感图像，土壤和气象传感器数据也扮演着至关重要的角色。为实现多源数据的深度融合，可定义一个统一的跨模态嵌入表示 $h$ ：

$$h = W_r v_{img} + W_s v_{soil} + W_c v_{climate},$$

其中 $v_{img}$ 为遥感图像编码器（如 CNN 或 ViT）提取的视觉特征向量； $v_{soil}$ 为土壤传感器（湿度、pH、养分含量等）数据通过时间序列模型（如 LSTM 或 Temporal Transformer）生成的特征向量； $v_{climate}$ 为气象数据（温度、降雨量、风速等）编码后的时空特征； $W_r$ ， $W_s$ ， $W_c$ 为可学习的融合权重矩阵。该融合表示 $h$ 既包含了空间分辨的图像信息，又整合了时序的土壤与气象动态，为下游的自然语言生成提供了丰富的上下文语义基础。随后，将融合特征 $h$ 输入至微调后的大语言模型解码器，通过条件文本生成方法，模型就可以生成个性化、情境化的田间管理建议。例如，当 $h$ 同时显示土壤湿度偏低、近期气温高、植被指数下降时，模型可能输出：“当前土壤含水量已低于安全阈值，请在未来 24 小时内进行灌溉约 20mm，并结合夜间低温时段检查作物蒸腾情况，以防昼夜温差导致干裂。”这种方式将多源传感信息与农业专家经验逻辑无缝映射到自然语言报告中，显著提高了建议的精准度和可操作性。

在实际田间管理中，土壤与气象传感器网络产生的大量时序数据也需要经过专业化指标计算后才能为种植者提供决策参考。其中，作物水分胁迫指数（Crop Water Stress Index, CWSI）即是一个常用的关键参数，可表示为：

$$CWSI = \frac{T_{canopy} - T_{wet}}{T_{dry} - T_{wet}},$$

其中， $T_{canopy}$ 为植被冠层温度，通常由红外传感器测定； $T_{wet}$ 和 $T_{dry}$ 分别对应完全湿润和干旱参考条件下的冠层温度，可通过气象数据与标准模型预先估算或实地校准得到。值接近 1 表示高度水分胁迫，接近 0 则说明水分充足。

将这一指标与土壤电导率（Soil Electrical Conductivity, EC）、土壤水分含量（Volumetric Water Content, VWC）和气象参数（如蒸散发速率 $ET_0$ ）等多源数据融合后，可构建一个综合“田间环境胁迫矩阵” $E_t$ ：

$$E_t = [CWSI_t, EC_t, VWC_t, ET_{0t}] \in \mathbb{R}^4,$$

此矩阵作为上下文输入，通过微调后的大语言模型解码器生成富有操作性的自然语言建议。例如：“当前田块西南角冠层温度较湿润参考温度高出 5°C

（ $CWSI \approx 0.75$ ），土壤含水量仅为 18%，建议今晚进行间歇灌溉 15 分钟，并在灌后 6 小时复测土壤湿度以评估效果。此外，若未来 48 小时无降雨，请于明早 8–10

点间段再次灌溉，以减少蒸散发损失。”这种做法不仅将多源传感器数据的专业指标以自然语言呈现，还结合了时间段选择与后续监测建议，真正满足了种植者对“何时、何量、如何操作”的精准需求。

为了更好地将这些基于多源传感和遥感数据生成的管理建议落地，大语言模型还可被部署为交互式对话系统，提供“可解释的交互式辅助”。在此模式中，用户不仅能接收系统自动生成的报告，还可通过自然语言提出后续问题，如“为什么西南角水分胁迫更严重？”、“若连续三日高温应如何调整灌溉策略？”系统则利用同一融合表示 $h$ 以及已构建的知识图谱实时回答，并引用具体指标和推理链条。例如，系统可能回应：“西南角下风向导致蒸散发速率提高15%，加之土壤含水量低于邻区4%，形成了更高水分胁迫。若预计未来三日高温，请将灌溉间隔缩短至每12小时，并在中午前后检查冠层温度，及时补水。”这一人机闭环交互方式，能动态更新上下文状态，并在对话历史中累积用户偏好和操作记录，为后续推荐提供个性化支持。此外，通过日志记录用户的疑问及系统生成的解释，还可用于后续模型微调，进一步提升系统对本地化环境和农户需求的适应能力。

本节深入探讨了如何运用大语言模型将遥感图像、土壤及气象传感数据，通过多模态信息融合与图像—文本生成技术，转换为可操作的自然语言报告，并结合关键指标（如NDVI、CWSI、土壤电导率与蒸散发速率等）生成精准的灌溉与施肥建议。我们介绍了跨模态嵌入表征的构建方法，以及在多源数据对齐后的推理流程，演示了模型在理解植被健康、土壤水分胁迫和环境条件变化中的应用场景。同时，借助交互式对话系统，模型能够在用户提问时动态调用先前融合的传感信息与知识图谱，为专家与农户提供可追溯的决策逻辑与补充建议，实现了真正意义上的田间管理智能化。

尽管技术取得了显著进展，但在多源时空数据的标准化校准、模型推理过程的可解释性保障、以及在算力受限环境下的实时部署等方面仍面临挑战。不同传感器和遥感平台在分辨率与测量误差上的差异，需要通过更精细的数据预处理和自适应对齐策略来加以解决；同时，让用户信任模型所生成的自然语言建议，要求系统能够在报告中清晰呈现其内部推理路径。针对这些困难，未来可朝着更加深度的多模态自监督预训练和数字孪生仿真环境方向努力，以提升模型对新场景的泛化与试验效率。此外，将可解释性AI方法应用于农业决策，有助于构建透明的决策图谱；而结合轻量化模型与分布式边缘部署，则可以实现对小型无人机、田间传感节点等终端设备的实时支持。通过构建长期闭环反馈机制，系统得以在专家与农户的持续交互中不断自我校正与优化，最终为精准农业的自动化与可持续发展提供坚实的智能支撑。

### 7.3 智能施肥与灌溉辅助文本交互

面向农户和田间管理者的自然语言交互平台，旨在将复杂的施肥与灌溉决策流程简化为一次自然对话。用户只需通过语音或文字提出问题——例如“现在这块菜地土壤缺氮吗？”或“明天有雨，今天该浇水吗？”——系统便会自动识别需求，抓取作物类型、地块位置和环境条件等关键参数，并实时调用传感器监测数据与气象

预测。随后，依托大语言模型的多轮对话引擎，平台以贴近农事场景的专业口吻，生成精准的施肥配比、灌溉时机与操作要点，甚至对可能的风险因素进行提前预警。整个流程无需用户掌握任何专业术语，只需以日常语言交流，即可获得可执行、可追溯的田间管理建议，真正实现技术对农业生产环节的无感助力。

在精准灌溉策略中，可以依照联合国粮农组织（FAO）发布的《作物参考蒸散发指南》（FAO-56）来估算参考作物蒸散发量，这一标准深受农业水资源管理领域的推崇。该方法将净辐射、气温、风速与空气湿度等多项气象要素纳入同一方程中，计算出代表开阔水面蒸散发能力的基础指标 $ET_0$ 。具体而言，我们通过下面的公式，将日均气温 $T$ 、2米高度风速 $u_2$ 、净辐射 $R_n$ 与土壤热通量 $G$ 等参数有机结合，同时以水汽压曲线斜率 $\Delta$ 与干湿常数 $\gamma$ 为调节因子，得到：

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)}$$

在此基础上，结合特定作物的作物系数 $K_c$ ，可进一步计算出实际蒸散发量 $ET_0 = K_c \times ET_0$ ，准确反映作物在当前气候条件下的需水特性。大语言模型接入这一物理水文计算流程后，不仅能够自动提取并填入最新的气象预报与传感器数据，还会基于不同作物生育阶段选取相应的 $K_c$ 值，生成针对性的灌溉文本建议。例如，在预计未来五天无降水、日均温度接近 $30^\circ\text{C}$ 的情境下，模型会将计算出的每日需水量与当前土壤含水水平进行比对，最终以“请于今日傍晚进行8mm灌溉，并在两日后结合冠层温度监测评估补灌需求”的形式输出操作步骤。这种无缝衔接复杂物理模型与自然语言生成的能力，使得灌溉决策既拥有科学依据，又易于农户直观理解和执行。

在精准施肥的应用场景中，系统首先将土壤养分、含水量、作物生长阶段的遥感指数（如叶绿素含量、叶面积指数LAI）以及未来一周的天气预报（降雨量和温度）整合为一个高维特征向量 $x$ 。该向量输入到一个经大规模田间试验数据校准的神经网络代理模型 $f_\phi(x)$ ，模型通过对历史肥效与作物产量间的复杂非线性关系进行学习，直接输出一组最优的氮、磷、钾投放量建议 $\hat{F}$ 。在此基础上，大语言模型将 $\hat{F}$ 与实时环境条件结合起来，生成具备时序分配策略的文本指导，例如推荐在灌溉前释放40%的氮肥以加速根区吸收，剩余部分则在关键分生期与灌后48小时内均匀施放，以减少高温蒸散和降雨冲刷带来的肥料损失。通过这种“数据—代理模型—语言生成”的一体化流程，农户既能获得科学、可追溯的施肥参数，又能理解每一步操作背后的机理逻辑，大幅提升了肥料利用效率并有效降低了环境风险。

在现代精准灌溉中，仅靠经验和规则集难以满足多变气候与严格水资源管理的需求，因而需要引入模型预测控制（Model Predictive Control, MPC）等优化技术。MPC将未来一段时间的气象预报、作物生长模型和土壤水分动力学纳入统一的决策框架，通过连续滚动时域优化确定最优灌溉水量与时机。系统内部首先建立形式化的动态模型：用连续时间的Richards方程描述土壤水分渗流，用作物水分响应曲线模拟蒸散发与生长需求，再通过离散化近似得到可用于数值优化的状态空间表示。具体而言，我们定义状态向量 $s_k = [\theta_k, x_k]$ ，其中 $\theta_k$ 表示时刻 $k$ 的土壤含水

率,  $x_k$  为作物生长指标 (如叶面积指数 LAI)。控制变量为灌溉流量  $u_k$ , 目标函数设定为在保证作物生长需求的同时最小化总水量消耗与潜在地下水补给缺口。通过在每个样本滚动窗口内求解有限时域最优问题, 系统为用户生成“本阶段灌溉 10mm、分两次进行, 每次间隔 6 小时”的建议。将 MPC 优化结果与大语言模型对话接口结合, 可实现在自然语言中呈现“经过模型预测, 下周连续高温会导致土壤含水率下降至 20% 以下, 为保证番茄高光合效率, 建议在今日晚间和明日清晨分别灌溉 5mm”, 并在用户反馈“我明天白天有打药计划”后动态重算, 提供新的灌溉安排。这样不仅让复杂的优化过程对农户“可见”, 也保证了调度策略的实时更新与多轮自适应。

在大规模农场或多田块管理场景中, 单一中央调度往往难以兼顾各区域的异质性需求, 因而可采用多智能体协同 (Multi-Agent Coordination) 的方式, 将每个田块视为一个自治单元, 各自运行本地化的施肥与灌溉代理, 通过自然语言接口与中央模型共享状态信息并协同决策。具体实现时, 每个田块代理基于自身的传感器读数 (如土壤水分、养分、作物长势指标) 运行一个轻量级的局部控制器, 同时与中央大语言模型建立对话通道, 上报关键状态与需求。中央模型则在获得来自多个田块的自然语言摘要 (例如“北区土壤含水量已降至 18%, 氮素消耗加速”) 后, 综合考虑整体水资源和肥料库存情况, 通过跨区资源调度算法分配有限资源, 并以自然语言下达差异化指导, 如“对北区追加 8mm 灌溉, 并将南区施肥量下调 10% 以保障总体水肥平衡”。

在这种协同框架下, 每个田块代理不仅是决策执行者, 还是重要的反馈源——它会在执行完灌溉或施肥操作后, 以自然语言形式报告实施效果与环境响应, 例如“灌后土壤含水量提升 12%, 冠层温度下降 2°C”或“施肥后叶绿素指数比前期提升 0.06”。中央模型据此进一步调整参数与策略, 实现对田块的动态自适应优化。随着季节更替和作物生长周期的推进, 系统会将每次决策的执行反馈累积到长期学习库, 通过定期精调大语言模型和本地代理的策略网络, 使其在下一个生育期开始时即具备更贴近本地气候、土壤与作物品种的决策能力。这种多层次的闭环学习过程, 使得智能施肥与灌溉不仅能满足即时需求, 还能在跨季节、跨年际的尺度上不断提升调度精度与资源利用效率, 真正实现对农业生产全生命周期的智能化支持。

在衡量智能施肥与灌溉方案对经济和环境的整体影响时, 需要引入了一种动态收益—成本—环境损失一体化评估框架。该框架将作物产量增益、资源投入成本节约与环境外部性 (如氮素淋失、水土流失、甲烷和氧化亚氮排放) 联合建模为一个时间连续的效益函数:

$$B(t) = \underbrace{Y(t) p_Y}_{\text{产量收益}} - \underbrace{C_{\text{water}}(t) p_W + C_{\text{fert}}(t) p_F}_{\text{资源投入成本}} - \underbrace{\int_{\Omega} L(x, t) \lambda(x) dx}_{\text{环境损失代价}}$$

其中  $Y(t)$  是模型预测的作物即期产量,  $p_Y$  是市场售价;  $C_{\text{water}}$  和  $C_{\text{fert}}$  分别为智能灌溉与施肥所消耗的水量和肥料量,  $p_W, p_F$  为对应的单位价格; 最后的积分项则对田间空间区域  $\Omega$  内的环境损失量  $L(x, t)$  包括氮素淋失强度、土壤侵蚀速率和温室气体排


放密度)按不同区域敏感度 $\lambda(x)$ 加权求和。通过对 $B(t)$ 在生育期 $[0, T]$ 上的数值积分,系统能够量化整个生产周期的综合净收益,并将关键影响因素映射到自然语言报告中,例如“精准灌溉与施肥在本季节为您带来净增收益 1,200 美元,同时减少了约 15 吨氮素流失,相当于降低地下水富营养化风险指标 0.8 级”。这一方法使农户能够直观洞察技术投入带来的多维度回报,并在不同管理策略之间做出数据驱动的最优选择。

面向农户的对话式系统将“今天要不要浇水”“如何调整氮肥用量”等口语化问题,自动转换为意图识别与槽位抽取的结构化请求;系统再结合土壤水分传感、遥感植被指数和短期气象预报,通过集成学习模型和模型预测控制算法,计算出精确的灌溉量与施肥配比,并以易于操作的自然语言报告给出操作步骤与注意事项。多田块管理场景下,各区块代理实时上报地块状态、接收集中资源调度,形成联合决策网络;而通过对比历史灌溉与施肥方案对作物产量、水分利用效率和养分利用效率的影响,还能直观量化经济收益和环境外部性。实时对话和可视化界面进一步降低了用户的学习成本,提高了信任度。面对多源数据标准化、模型可解释性与部署算力限制等挑战,这套系统通过多模态融合、可追溯的决策链路和轻量化部署,正向着让精准灌溉与施肥真正普惠于每一位农事生产者的目标迈进。

依赖多源传感与遥感数据的智能灌溉和施肥系统在真实田间部署时,常面临数据对齐精度不足、气象预报不确定性以及传感器故障带来的信息丢失。用户对“黑箱”式决策的信任度也亟须通过可解释 AI 机制来提升。同时,大规模模型在低算力终端的实时响应能力和隐私保护也需要更高效的轻量化与联邦学习解决方案。未来研究可聚焦于开发更鲁棒的多模态自监督预训练框架,以在极端天气或设备异常时保持高质量决策;引入可解释性 AI 与交互式故障诊断,确保每条建议都能提供可追溯的推理链路;以及结合微服务化部署与边缘计算,实现在带宽受限的田间环境中稳定运行。此外,将经济风险评估和碳足迹量化纳入决策闭环,能够帮助系统在满足产量需求的同时,真正实现资源节约与环境保护的可持续发展目标。

## 7.4 病虫害智能防治知识库

在农业病虫害防治中,构建一个兼具深度语义与多模态信息的智能知识库是提升诊断与处置效率的关键。该知识库需汇集来自学术期刊、病虫害图谱、高分辨率田间影像以及农户上报的病例数据,通过自然语言处理(NLP)技术对文献进行精准分段、实体识别与关系抽取,再辅以计算机视觉算法对图谱和影像进行病斑检测与特征提取。此外,利用知识图谱技术,将“病原体—宿主—症状—防治方法”这些核心概念以节点—边结构表示,并为每条边分配多源数据支持的置信度指标;同时,针对农户上报的病例文本,经由强化学习微调的语言模型可实现症状描述与知识库实体的自动对齐,确保案例与文献研究成果无缝衔接。最终,这一智能化平台能够在“大数据+深度学习+知识图谱”框架下,为后续的实时问答和对话式防治策略提供坚实的数据支撑。



**图 7-2 大语言模型在病虫害智能防治的应用框架图**

在实时问答与对话式防治策略环节，系统依托检索增强生成（Retrieval-Augmented Generation, RAG）框架，将用户的自然语言询问与底层知识库紧密耦合。用户输入诸如“叶片出现褐色斑点，如何处理？”之类的问句后，首先通过双塔模型（Bi-Encoder）将查询文本 $q$ 与知识库中所有候选段落 $d_i$ 分别映射为 embedding 向量 $e_q$ 与 $e_d$ ，并以余弦相似度为度量进行前 $k$ 项检索：

$$\text{Score}(q, d_i) = \frac{e_q \cdot e_{d_i}}{\|e_q\| \|e_{d_i}\|}, \text{top}k = \underset{i}{\operatorname{argmax}} \text{Score}(q, d_i).$$

检索出的高相关段落随后被送入生成模型（如基于 Transformer 的 Seq2Seq 架构），与对话历史上下文一同作为条件，共同驱动响应生成。这一生成过程不仅在参数层面调用了大语言模型预训练所得的深层知识，还通过微调融入了农业防治领域的专业语料，实现对“病斑模型”、“物候期”等专业概念的精准运用。

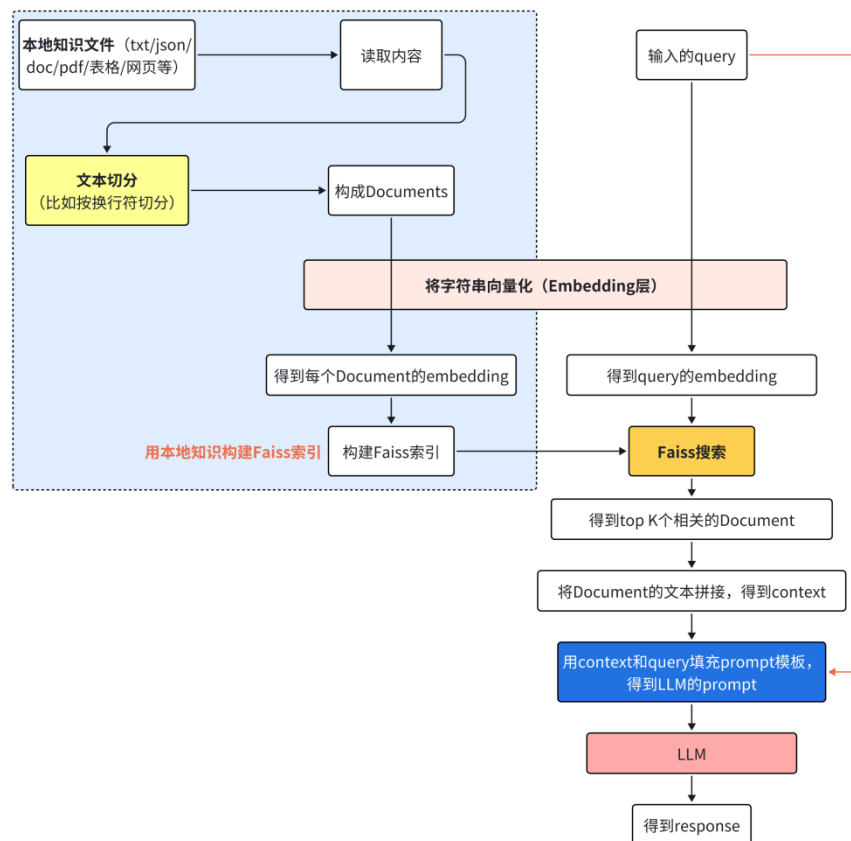


图 7-3 实时问答与对话式防治策略流程

对话状态跟踪（Dialogue State Tracking, DST）模块则负责维护多轮交互中的槽位填充与意图演变，例如记录已知症状、作物品种和田块位置，以便在后续回合继续补充或校正。当系统在生成阶段遇到不确定或新颖场景时，还会触发“在线学习”子流程，将该对话及后续用户评价反馈给强化学习微调器，用以动态调整检索-生成策略。通过这种 RAG + DST + 在线微调的多层闭环，对话机器人能够在几乎零延迟的情境下，为农户提供涵盖病因诊断、药剂推荐、施药时间窗和风险提示在内的全流程防治方案，对话示例可能为：

用户：“玉米叶尖发黄，有点干枯。”

系统：“根据当前叶绿素含量下降 15% 和土壤含氮量仅为 12 mg/kg，初步判断为氮素不足。建议立即喷施 0.5% 硝态氮水溶液，并在 5 天后复测叶片颜色。如有黄化加剧，请结合田间湿度再行补施。”

这一智能问答系统将知识库检索结果、表型诊断模型与实证案例融合于同一条回复中，既保证了信息的准确性，也兼顾了可操作性与可解释性，真正实现了病虫害防治的“即问即答”与“策略可视”功能。

在病虫害防治决策流程中，经济损害阈值（EIL）与经济阈值（ET）并非孤立的静态数值，而是建立在作物—害虫群体动力学模型、市场波动模型和控制技术响应模型三者耦合基础之上的动态指标。群体动力学常通过黎氏矩阵（Leslie Matrix）或离散时间 Logistic 方程模拟害虫数量随时间的演变，并结合温湿度对卵孵化与成虫繁殖率的影响，生成未来几日的密度预测曲线；市场波动模型则以上月成交价、区域供需及政策补贴为主要变量，动态输出每单位产量的经济价值；控制响应模型则通过历史防治试验数据拟合不同防治措施（化学、生物、农业）在不同环境下的实际有效率。当上述三大子模型在系统中完成联合仿真后，就可以获得在给定时间窗口内的动态 EIL 与 ET——即在不同温湿度背景下、不同市场价格和不同防治手段响应效率组合中，害虫密度应介入防控的最小临界值。智能问答机器人在对话中只需引用这一动态阈值并结合当前田块的实时密度和环境参数，就能够输出诸如“当前害虫潜势量为 2200 只/地块，已超过动态经济阈值 1800，建议在未来 24 小时内采用 X 剂量 Y 方法进行施药，并在施后 3 日进行二次监测”的精准策略，而无需用户了解阈值背后的复杂模型，真正实现了“将高阶数值模拟隐匿于自然语言背后”的智能化防治新范式。

在防治流程闭环的设计中，需要将病虫害控制效果、成本投入与生态影响纳入同一时序优化框架，以保证每一次干预既有效又可持续。基于多目标强化学习（Multi-Objective Reinforcement Learning, MORL）[12]的方法，可将病虫害防治策略视为智能体在环境中执行的动作序列，而其累积回报函数 $J$ 则由产量增益 $R_Y$ 、经济成本节省 $R_C$ 和环境足迹降低 $R_E$ 三部分加权组合：

$$J = \mathbb{E} \left[ \sum_{t=0}^T \gamma^t (w_Y R_Y(s_t, a_t) + w_C R_C(s_t, a_t) - w_E R_E(s_t, a_t)) \right]$$

其中 $\gamma$ 是折扣因子， $w_Y, w_C, w_E$ 分别为产量、成本与环境模块的权重，可动态依据区域可持续发展目标调整， $R_Y$ 通过作物生长模型预测策略执行后的增产量， $R_C$ 由资源单价和用量确定的成本差异计算获得， $R_E$ 则依据生命周期评估（Life Cycle Assessment, LCA）方法量化的温室气体排放与生态影响得出。在实际系统中，语言模型参与生成的策略不仅要考虑即时回报，还需根据长期反馈不断更新策略网络参数，形成“预测—执行—评估—优化”的闭环。例如，每次防治后系统会自动记录执行结果（如害虫密度降幅、农膜残留、非目标生物影响指标等），并将这些数据与回报函数中的 $R_Y, R_C, R_E$ 对应项进行匹配，交由策略更新模块进行梯度调整，优化未来的策略分配。最终，问答接口在与用户对话时，不仅给出“在当前温湿度条件下建议喷施 A 药剂 0.3 kg/ha”，还会附上“预计本次干预可提高产量 2%，节省药剂成本 15%，并减少  $N_2O$  排放约 0.2 kgCO<sub>2e</sub>”的多维度数据支持，使防治决策既具备科学严谨性，又兼顾生态可持续性。

为了保证知识库的时效性，新上报的田间病例与最新文献需要被快速整合并驱动模型持续适应。增量知识图谱更新过程首先将新增三元组 $(h, r, t)$ 插入现有图谱，同时对图谱嵌入（Graph Embedding）进行局部微调。以常见的 TransE 模型为例，新增实体对 $(h, r, t)$ 的嵌入向量 $h, t$ 会依据以下边缘化损失进行在线更新：

$$L_{\text{new}} = \max(0, \gamma + d(h + r, t) - d(h' + r, t')),$$

其中 $(h', r, t')$ 为采样的负例， $\gamma$ 为边际超参数，距离函数 $d$ 通常采用欧氏距离或余弦距离。此方式使得原有嵌入 $h, t$ 仅在必要的局部子图上发生变化，避免整图重训带来的高昂开销。

与此同时，基于检索增强生成（RAG）的问答模型也在新案例对话中进行微调：将每次用户与系统的问答对 $(q, a)$ 通过混合蒸馏（Knowledge Distillation）技术加入训练集中，使用交叉熵损失 $L_{CE} = -\sum_t a_t \log p_\theta(a_t|q)$ 对生成模型参数进行逐步优化。这种双管齐下的增量学习策略，既保持了知识图谱的结构一致性，也让语言模型在防治策略输出时能够自动吸纳最新经验，使诊断推荐的准确率与实时性不断提升。

在确保系统在实际应用中持续高效可靠运行的同时，对问答与知识检索模块的评估也至关重要。检索阶段常以 Precision@k 与 Recall@k 衡量前 k 条检索结果的相关性：

$$\text{Precision@}k = \frac{|\{\text{Relevant}\} \cap \{\text{Retrieved}_k\}|}{k},$$

$$\text{Recall@}k = \frac{|\{\text{Relevant}\} \cap \{\text{Retrieved}_k\}|}{|\{\text{Relevant}\}|},$$

生成阶段则结合自动评价指标与人工评估：BLEU、ROUGE 可量化回答与专家标准文本的匹配度，而基于标注的准确率（Accuracy）和覆盖率（Coverage）则评估回答的正确性与全面性。为捕捉用户体验，还需定期进行 A/B 测试与问卷调查，将用户满意度 $S$ （量表 1-5 分）与回答响应延迟 $L$ （秒）联合纳入服务质量指标：

$$\text{QoS} = \alpha \bar{S} - \beta \bar{L}, \alpha + \beta = 1,$$

以此动态调整检索深度、生成长度与并发吞吐量。通过上述多维评估与持续优化，病虫害防治知识库能够在大规模真实环境中保持高精度、高可用与高用户信任度。

病虫害智能防治知识库汇集来自学术文献、病虫图谱和田间病例的多源信息，通过自然语言处理与计算机视觉技术实现实体与关系的精确抽取，并以知识图谱形式统一呈现。检索增强生成架构帮助系统在用户描述病症后快速定位相关知识段，结合动态经济阈值与环境足迹模型生成可执行的防治策略。多目标强化学习框架确保防治方案在提升产量、控制成本与减少环境影响之间保持平衡，增量更新机制和在线评估指标持续优化知识图谱与生成模型，最终通过对话机器人以清晰、易于操作的自然语言完成全流程防治指导。

未来研究可以探索在弱监督和自监督预训练下，提升系统对少量标注或新兴病虫害数据的自适应能力。可解释 AI 方法将使防治建议中的推理链条更加透明，增强农户信任。基于联邦学习与差分隐私的多方协同训练可在保护数据安全的前提下实现知识共享。跨语言与跨区域的本地化适配技术将推动系统在全球多样化农业场景

中的应用。与专家协同的在线评审平台和模拟仿真试验环境能够加速新防治策略的验证与落地。

## 第 7 章参考文献

- [1] Mohsen Yoosefzadeh-Najafabadi. “From text to traits: exploring the role of large language models in plant breeding”. In: *Frontiers in Plant Science* 16 (2025), p. 1583344.
- [2] Jacob Devlin et al. “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding”. In: *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics*. 2019, pp. 4171–4186.
- [3] Alec Radford et al. “Improving language understanding by generative pre-training”. In: (2018).
- [4] Tanya Z Berardini et al. “The Arabidopsis information resource: making and mining the “gold standard” annotated reference plant genome”. In: *genesis* 53.8 (2015), pp. 474–485.
- [5] John L Portwood et al. “MaizeGDB 2018: the maize multi-genome genetics and genomics database”. In: *Nucleic acids research* 47.D1 (2019), pp. D1146–D1154.
- [6] Shu Ouyang et al. “The TIGR rice genome annotation resource: improvements and new features”. In: *Nucleic acids research* 35.suppl\_1 (2007), pp. D883–D887.
- [7] Compton J Tucker. “Red and photographic infrared linear combinations for monitoring vegetation”. In: *Remote sensing of Environment* 8.2 (1979), pp. 127–150.
- [8] Alexey Dosovitskiy et al. “An Image is Worth 16×16 Words: Transformers for Image Recognition at Scale”. In: *International Conference on Learning Representations* (2021).
- [9] Sepp Hochreiter and Jürgen Schmidhuber. “Long Short-Term Memory”. In: *Neural Computation* 9.8 (1997), pp. 1735–1780.
- [10] Bryan Lim et al. “Temporal fusion transformers for interpretable multi-horizon time series forecasting”. In: *International Journal of Forecasting* 37.4 (2021), pp. 1748–

- [11] Richard G Allen et al. “Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56”. In: Fao, Rome 300.9 (1998), p. D05109.
- [12] Conor F Hayes et al. “A practical guide to multi-objective reinforcement learning and planning”. In: Autonomous Agents and Multi-Agent Systems 36.1 (2022), p. 26.
- [13] Antoine Bordes et al. “Translating embeddings for modeling multi-relational data”. In: Advances in neural information processing systems 26 (2013).
- [14] Patrick Lewis et al. “Retrieval-augmented generation for knowledge-intensive nlp tasks”. In: Advances in neural information processing systems 33 (2020), pp. 9459– 9474.

# 7.大语言模型在作物育种与精准农业中的应用

作物育种与田间管理正处于“数据爆发+技术迭代”的关键时期。几乎每天都有新的基因组测序数据和育种实验报告面世，各类遥感影像与地面传感数据铺天盖地而来，专家经验和科研文献中蕴藏的知识流如涓涓细流涌向数字化平台。面对如此海量且多样的信息源，传统的人工检索难以应对，简单的规则匹配难以深入。大语言模型恰如其时地被引入这一领域，凭借对自然语言的深度理解能力和对多模态信息的融合潜力，为基因组学文本挖掘、田间环境监测与智能决策交付提供了全新的思路。

第七章围绕四大核心场景展开技术论述，其整体应用框架可直观呈现为图 7-1。该框架以“数据输入—技术处理—决策输出”三层架构，系统展示了大语言模型从信息整合到智能决策的全链条能力：在基因组学与育种文本分析中，通过命名实体识别（NER）与关系抽取（RE）技术构建“基因-性状-环境”知识图谱，辅助高通量筛选；在田间管理环节，通过多模态数据融合与自然语言生成技术，将遥感指标转化为可读的田间管理建议；在智能水肥交互场景中，结合作物生长模型与模型预测控制（MPC）算法，通过对话交互输出精准灌溉施肥策略；在病虫害防治领域，依托检索增强生成（RAG）技术与知识图谱，实现病害诊断与防治方案的自动化生成。




图 7-1 大语言模型在作物育种与精准农业中的应用框架图

作物育种过程中，基因与表型之间的关联是一张错综复杂的大网。过去需要大量人工梳理文献、挖掘实验结果，才能定位有价值的基因位点并制定育种策略。大语言模型通过对海量育种文献和基因组注释的深度学习与语义表示，能够自动提取基因名称、突变类型、性状描述等信息，并借助关系抽取技术绘制“基因-性状-环境”知识图谱。借助这一图谱，研究者在进行高通量筛选时能够快速锁定潜在候选基因组合，并结合历史实验数据进行精准预测，将繁琐的手动分析过程转化为自动

化的数据驱动流程。与此同时，将基因组序列视作“生物语言”并进行预训练，能够让模型更好地理解基因片段和功能注释之间的深层语义关系，从而在小样本条件下也能提供精准的表型预测，为下一步选育试验提供方向。

田间管理环节中，遥感图像、无人机航拍和地面传感器实时监测共同构成了一套复杂的多模态数据体系。大语言模型能够把图像中的植被指数、土壤含水量等指标解码为自然语言报告，让农户以“可读的”形式快速掌握田间状况。例如，一张多光谱遥感图判定作物长势偏弱后，模型可利用图像字幕技术生成“该地块植被指数偏低，可能需补充氮肥并增加灌溉量”的建议。再联合气象模型提供的温度与降雨预报，将多个数据源关联效果融入一段可执行的灌溉策略描述。通过这种方式，田间管理变得直观、可操作，农户无需深入学习专业指标，就能凭借通俗的文字报告完成精准决策。

在智能施肥与灌溉辅助交互场景中，大语言模型承担的角色更像一名数字农技顾问。农户通过自然语言提问，“今天要不要给小麦追加氮肥？”“明早田间是否适合灌溉？”系统便在后台完成对土壤养分、作物生长期、遥感植被指数与未来天气预报的多源数据整合。将这些特征输入到集成了作物生长模型与预测控制算法的代理模型后，得出最优水肥方案，再由大语言模型将复杂的数值计算结果翻译为“今晚安排 8 毫米灌溉，分两次进行；明天傍晚补施 20 公斤尿素”的清晰建议。整个过程流畅自然，既保留了科学依据，又降低了用户理解门槛。

病虫害防治环节的智能化，更依赖于对多源信息的一体化理解。科研文献中关于病原类型、传播途径和防治配方的描述往往繁杂难读，遥感或无人机拍回的作物病斑图像又需要专业知识才能识别。大语言模型通过检索增强生成技术，能将用户上传的叶片照片与知识库中对应的病害图谱进行快速匹配，结合对话式交互迅速定位病害类型。随后，系统自动检索对应该病害的防治方案文本，并生成“当前田块发现叶斑病初期症状，推荐喷施铜制剂 0.3%，并在三日后复查。如雨后高温，请避免过度施药造成作物灼伤”的防治建议。知识图谱与对话模块协同，确保方案既有权威文献支撑，又易于农户理解与执行。

作物育种与精准农业的发展呼唤更加紧密的技术与生产融合。大语言模型与多模态数据的协同应用，为农技工作者和科研人员提供了从文献挖掘到田间执行的端到端解决路径。借助基因组学文本分析，研究者能够快速构建针对性知识图谱并辅助高通量试验；通过遥感与传感数据融合解读，田间管理人员可在自然语言报告中获取全局视角；在交互式灌溉与施肥系统中，模型担当智能顾问，让农户时刻掌握最佳水肥策略；在智能防治知识库中，模型将复杂病虫害防治逻辑浓缩为可操作建议，实现“对话即决策”。第七章正围绕这四大场景展开，旨在展示大语言模型如何在作物育种与精准农业领域打开新的应用格局，帮助农业生产迈向更高效率、更低成本和更可持续的未来。

## 7.1 基因组学与育种文本数据分析

随着基因组学的迅速发展和高通量测序技术的广泛应用，作物育种领域正逐渐步入一个信息大爆发的时代。每年发表的基因组相关文献、育种实验报告和表型数据集正以指数级速度增长。这些文献和实验报告中蕴藏着丰富的遗传信息、基因功能描述、性状关联发现，以及育种策略的经验和实验成果。然而，传统的人工检索、分类、阅读和分析方法已经难以高效处理这种规模庞大、类型多样、更新迅速的海量文本信息，导致大量有价值的数据和知识难以被充分挖掘和利用。为应对这种挑战，大语言模型开始被逐步引入基因组学与育种研究，通过其强大的自然语言理解与知识表示能力，实现对高通量文本信息的快速处理、自动化知识抽取与高效的综合分析。这种方法不仅大幅提高了文献分析和数据利用效率，也为作物育种的创新性研究提供了新的数据驱动型技术范式。

基因组学与作物育种领域的文献资源具有显著的结构化与非结构化信息交织的特征：一方面，文献中包含大量规范化描述的实验数据、基因序列、突变信息、性状关联的统计学分析结果等结构化数据；另一方面，也存在大量研究者的推测性叙述、实验方法细节、观察结果及推论等非结构化文本。大语言模型因其在自然语言理解方面的强大泛化能力，特别适合处理这种结构化与非结构化并存的复杂文献资源。例如，BERT、GP 等预训练模型在经过特定领域的微调后，能够迅速识别出文本中的基因位点、蛋白质序列及其对应的功能注释信息，提取出不同基因与具体表型之间的关系，并进而形成清晰的知识图谱。与传统的人工标注或基于规则的抽取方法相比，基于大语言模型的自动抽取方法在效率和准确性上都有显著提高，特别是对跨学科、跨物种研究成果的集成与分析更具优势。基于这种方法，研究人员可以高效地构建涵盖大量物种、基因、性状和实验条件的综合知识库，从而为深入的关联研究与育种策略优化奠定坚实的数据基础。

利用大语言模型对基因组学和育种文本数据进行信息抽取的流程一般包括两个关键步骤：首先是利用命名实体识别（Named Entity Recognition, NER）技术，从大量文本中自动检测和识别涉及基因组位点、基因名称、突变类型、相关蛋白质和具体的农艺表型（如抗旱、耐盐、抗病等）等重要信息。这一步骤旨在从复杂的文本描述中快速、准确地捕获涉及育种研究核心概念的语义单元。随后，再利用关系抽取（Relation Extraction, RE）技术，进一步分析文本中各个实体之间的逻辑关系，比如明确某个特定基因与特定作物表型之间的因果或关联关系，从而提取出具有高研究价值的结构化信息。这种由大语言模型驱动的自动化流程相比于传统人工标注或基于规则的抽取方法，具有更高的泛化能力和更强的跨文献适应性，能够高效地处理不同研究机构、不同研究团队乃至不同物种间发布的大量文献和实验报告。这种高度自动化的信息抽取能力使研究人员能够更迅速地建立起涵盖多种基因与表型关系的高质量知识库，从而有效缩短从信息获取到实际育种策略制定的周期。

在利用大语言模型对基因组学和育种文本数据进行信息抽取时，NER 是实现自动化知识提取的基础环节。通过 NER 技术，模型能够从非结构化文本中精准定

位基因名称、突变类型等核心实体，为后续关系抽取与知识图谱构建奠定基础。以 BERT 模型为代表的预训练架构在基因实体识别中展现出显著优势，以下通过具体工程化实现示例，展示从文本中提取基因名称的完整技术流程：

```
# 基于 BERT 的基因实体识别工程化实现示例

from transformers import BertTokenizer, BertForTokenClassification
import torch
import numpy as np

# 加载农业领域微调后的 BERT-NER 模型（以拟南芥基因识别为例）
# 注：实际应用中可使用 TAIR 数据库标注数据进行领域适配
tokenizer = BertTokenizer.from_pretrained("agri-bert-ner", do_lower_case=False)
model = BertForTokenClassification.from_pretrained("agri-bert-ner",
num_labels=3)

def gene_ner_pipeline(text: str) -> list:
    """基因实体识别完整流程：文本分词→模型推理→实体解码"""
    # 1. 文本预处理与分词
    inputs = tokenizer(
        text,
        return_tensors="pt",
        padding="max_length",
        truncation=True,
        max_length=128
    )

    # 2. 模型推理获取实体标签概率
    with torch.no_grad():
        outputs = model(** inputs)
        logits = outputs.logits # 输出形状: [batch_size, seq_length, num_labels]
```

```

# 3. 标签解码（映射 ID 到实体类型）

label_map = {0: "O", 1: "B-GENE", 2: "I-GENE"} # O=非实体, B=基因实体
起始, I=基因实体延续

predictions = torch.argmax(logits, dim=2).squeeze().tolist()
tokens = tokenizer.convert_ids_to_tokens(inputs["input_ids"].squeeze())

# 4. 实体边界识别与组合

entities = []
current_entity = []

for token, pred in zip(tokens, predictions):
    if pred == 1: # 新实体起始
        if current_entity:
            entities.append(" ".join(current_entity), "GENE")
            current_entity = []
        current_entity.append(token)
    elif pred == 2 and current_entity: # 实体延续
        current_entity.append(token)
    elif current_entity: # 实体结束
        entities.append(" ".join(current_entity), "GENE")
        current_entity = []

# 5. 还原原始文本中的实体位置（去除分词标记）

return _filter_bert_tokens(entities, text)

def _filter_bert_tokens(entities: list, original_text: str) -> list:
    """过滤 BERT 分词产生的特殊标记（如##），匹配原始文本实体"""
    filtered_entities = []

```

```

for entity_text, entity_type in entities:
    # 去除 BERT 分词添加的##前缀
    clean_text = entity_text.replace("##", "")
    # 匹配原始文本中的实体位置（简化实现）
    if clean_text in original_text:
        filtered_entities.append((clean_text, entity_type))
return filtered_entities

# 应用示例：识别文献摘要中的基因实体

example_text = "The transcription factor TaDREB2A was found to enhance drought
tolerance in wheat by regulating the expression of stress-responsive genes. Another gene,
TaNAC67, showed similar functions in rice under salt stress."

gene_entities = gene_ner_pipeline(example_text)
print("识别到的基因实体：")

for entity, typ in gene_entities:
    print(f"- {entity} (类型: {typ})")

# 输出结果：

# 识别到的基因实体：

# - TaDREB2A (类型: GENE)

# - TaNAC67 (类型: GENE)

```

以示例文本为例，模型准确识别出“TaDREB2A”和“TaNAC67”两个基因实体，为后续构建“基因 - 耐旱性 - 小麦”“基因 - 耐盐性 - 水稻”等关系三元组提供了基础数据。这种从非结构化文本到结构化实体的转换能力，正是大语言模型驱动育种知识图谱构建的核心技术支撑。

在基因组学研究与育种实践中，大语言模型所构建的基因—表型关联信息库，进一步为高通量筛选技术（High-throughput Screening, HTS）提供了强大的智能辅助。高通量筛选技术通常涉及在短时间内对大量遗传变异体或突变体进行表型测试与评估，以快速识别对目标性状（如抗病、抗逆境或产量提升）有积极贡献的基因变异组合。然而，这种技术所产生的海量数据通常需要后续复杂的分析与解释，尤其是要从大量初步筛选结果中确定真正有价值的目标基因或突变类型，并设计下一

步育种实验。通过大语言模型的介入，研究人员可以快速地将高通量实验数据与已有的文献知识进行自动比对与整合，利用模型强大的推理和决策能力自动过滤掉无关或冗余的信息，将重要的潜在基因或性状信息突出显示。同时，模型还能根据历史文献和实验经验，智能推荐进一步实验所需的最优基因组合或育种策略。这种方法不仅显著加速了基因功能验证和目标性状的发现过程，还有效地降低了传统方法中由于人工判断和经验局限性带来的偏差和遗漏，极大地提高了育种流程的准确性与效率。

在进一步应用大语言模型辅助高通量筛选与作物品种改良的过程中，关键的技术突破点在于如何实现对基因组—表型关联信息的高效融合与深度挖掘。其中一个重要的技术环节便是基于大语言模型的“表型预测”（Phenotype Prediction）。表型预测的基本任务可以定义为：在给定一组基因型数据的前提下，通过已有的基因与表型关联知识，预测该基因型组合可能表现出来的作物性状。这类预测任务本质上是对基因型—表型映射关系的一种条件概率建模（Conditional Probability Modeling），形式化地，可以描述为：

$$P(Y|G) = f_{\theta}(G)$$

其中 $G$ 表示输入的基因型数据，通常以特定基因座上的遗传变异、基因表达谱或单核苷酸多态性标记形式出现；而 $Y$ 为目标预测的农艺性状表现（例如抗旱性、生长期、产量潜力等）， $f_{\theta}$ 则是由大语言模型及其扩展模块共同构成的预测函数，参数 $\theta$ 在训练阶段通过历史实验数据与文献知识进行优化调整。大语言模型可以首先从大量育种文献和实验记录中自动抽取已知基因型—表型关联数据，并将其存储在结构化或半结构化的知识库中，以此为基础训练一个专门的预测模块。当新的基因型数据进入时，该预测模块便能够快速结合已有知识，根据历史数据推断该基因型可能表现出的性状特征。与传统统计学方法（例如线性混合模型或回归分析）不同，大语言模型驱动预测模块能够同时处理大规模异构数据，并且能捕捉到基因组内部复杂的非线性相互作用和交叉效应。这种方法不仅可以提高对作物性状预测的准确性，也能极大降低育种过程中的时间和资源投入，使育种人员能够快速聚焦到最有潜力的候选基因组合或品种上，从而大幅提升育种工作的整体效率和创新能力。

除了上述基因互作网络分析之外，大语言模型还能够为育种研究提供更进一步的“智能文献挖掘与假设生成”（Literature-based Discovery, LBD）能力。这种方法旨在利用已公开发表的海量研究文献，从已有知识的交集和边界区域中自动生成新的科研假设，以启发下一步的研究方向和实验设计。这一过程通常涉及三个步骤：

- **第一步：知识检索和整合。**利用大语言模型的语义搜索和文本检索能力，从各大公共数据库（如PubMed、Web of Science）中筛选出与特定研究问题高度相关的文献集合。这些问题可能包括特定作物性状的基因控制机制、特定环境胁迫下的作物响应途径、以及潜在的未被充分研究的基因功能等。
- **第二步：知识图谱构建和推理。**基于检索到的文献集，大语言模型进一步通过自动化信息抽取与融合，建立综合性的育种领域知识图谱（Breeding

Knowledge Graph, BKG)。BKG 包含多种节点类型（如基因、蛋白质、表型、环境因素）和多种关系类型（如作用关系、因果关系、伴随关系），为下一步推理奠定基础。

- **第三步：自动假设生成与筛选。**在构建好的知识图谱上，应用知识推理方法（如链式推理、路径分析等），自动探索尚未直接研究但逻辑上可能存在关联的知识节点。例如，如果文献中已分别描述“基因 A 影响性状 B”以及“性状 B 与环境因素 C 存在关联”，模型可能推导出“基因 A 在环境因素 C 下可能具有特殊的功能或表达模式”，从而生成具有科研价值的新假设。

假设生成的质量可通过计算推理路径的可信度和支持文献数量进行量化评估。例如，可定义假设生成的可信度由路径长度、支持文献、语义相似性决定，路径长度越短、支持文献越多、语义相似性越高，则假设可信度越高。研究人员据此对自动生成的假设进行人工或半自动筛选后，可选择最具价值的假设进行下一步实验验证或深入研究。

尽管基于大语言模型的育种文本数据分析和信息抽取技术已取得了初步成功，但在实际应用中仍然面临一些重要的技术性挑战。其中最主要的是育种领域的专业术语规范化与同义实体消歧问题。育种与基因组学领域的文献通常涉及大量跨物种、跨实验、跨实验室的术语与命名惯例差异，许多相同或高度相似的基因、蛋白质或性状在不同研究中可能采用不同的命名方式或代码（例如不同的数据库编号、命名缩写等）。如果这些术语和实体无法实现准确、统一的标准化映射，将严重制约信息抽取结果的可靠性与泛化能力。

针对这一问题，目前较为常用的解决方案是采用基于大语言模型与领域知识库结合的联合消歧方法（Joint Disambiguation Method）。将术语规范化问题描述为：给定文献中的一个术语或实体表达 $t$ ，以及一个标准领域知识库 $KB$ 中的实体集合 $E = \{e_1, e_2, \dots, e_n\}$ ，目标是找到一个或多个最佳匹配的标准实体 $e^* \in E$ ，满足条件：

$$e^* = \operatorname{argmax}_{e \in E} P(e|t, C)$$

其中 $C$ 表示术语或实体所在的上下文信息（如相邻词汇、句子语义、篇章语义），而条件概率 $P(e|t, C)$ 可通过大语言模型来学习或预测。具体方法包括：

- **基于语义嵌入（Semantic Embedding）的方法：**通过大语言模型构建实体或术语的语义向量表示（Embeddings），并利用余弦相似度（Cosine Similarity）或其他相似度指标在标准实体库中进行匹配。
- **基于多任务学习（Multi-task Learning）的方法：**在训练大语言模型时，加入术语消歧和规范化的辅助任务，引导模型在预训练和微调阶段自动学习同义实体的映射关系，提升模型在真实育种文献数据中的消歧表现。
- **基于知识增强（Knowledge-enhanced）的方法：**结合外部领域知识库（如TAIR、MaizeGDB、Rice Genome Annotation Project等权威植物基因库），

利用大语言模型的注意力机制（Attention Mechanism）实现领域知识与文献语境的精确匹配，从而提升术语规范化和实体消歧效果。

通过以上方法，有望有效解决育种领域中术语标准化的技术瓶颈，从而为后续更精准的知识图谱构建、基因网络分析、表型预测和智能假设生成等复杂任务奠定可靠的数据基础。这种标准化处理方式不仅提高了大语言模型分析育种文本的准确性和泛化性，也极大地增强了模型在实际育种研究场景中的可落地性。

综上所述，基于大语言模型的基因组学与育种文本数据分析技术，已初步展现出在海量文献信息处理、基因-表型关联知识抽取、高通量基因筛选辅助、基因互作网络分析以及智能假设生成等多个方向的巨大潜力。这些创新技术与方法，不仅有效地缓解了传统育种信息处理手段面临的效率瓶颈，更深刻地改变了作物育种领域从数据获取、分析到决策支持的整体范式。特别是通过自然语言理解能力的持续进步，大语言模型为育种研究人员提供了一种全新的、自动化的知识发现工具，帮助其快速定位关键基因、精确识别育种策略、并优化实验设计，从而显著提高了育种研发效率。然而，当前该领域的研究与应用仍处于发展阶段，面临一些不容忽视的技术挑战。育种领域专业术语的规范化与实体消歧问题依然严峻，尤其在跨物种和跨实验环境的数据处理中表现明显，亟需发展更加鲁棒且高效的术语标准化方法。大语言模型在基因型-表型预测任务中的泛化性与鲁棒性尚待进一步提升，尤其是在数据稀疏或噪声较大的实际育种环境下，模型的表现仍存在较大波动。此外，大语言模型的决策过程可解释性问题也亟待解决，研究人员和育种专家更倾向于理解和信任基于模型做出的预测与建议，而非将其作为“黑盒”来盲目信赖。

面向未来，基因组学与育种文本数据分析的研究应从以下几个方向深入推进：一是发展融合领域知识与大语言模型的混合方法，提高模型在复杂育种场景下的信息抽取和预测能力；二是加强跨学科协作，利用更多高质量、多模态的实验数据和真实农业场景信息，不断优化和校正大语言模型在实际场景中的表现；三是探索模型的可解释性和透明性框架，使其能够为研究人员提供可追溯的推理链条，提升科研决策的可信度和接受度。随着这些技术挑战逐步得到解决，基于大语言模型的基因组学与育种文本数据分析方法必将对农业现代化与可持续发展作出更为突出的贡献。

## 7.2 田间管理与遥感数据的融合解读

随着遥感技术与传感器网络的广泛应用，田间管理领域逐步进入了一个精细化与数据驱动的新时代。卫星遥感、无人机航拍和地面传感器网络构成了农业数据采集的重要支撑体系，这些系统可以提供覆盖面积大、空间分辨率高且时间连续的田间数据，包括土壤湿度、植被指数、作物生长状况、病虫害分布情况等。然而，这类高维度、多源异构的数据通常以复杂图像和时空序列数据的形式呈现，直接供给农户或农业管理者往往难以快速准确地理解和决策。为了解决数据与用户间的沟通鸿沟，将这些遥感数据和图像分析结果精准、高效地转化为人类易于理解的自然语言描述变得尤为重要。大语言模型凭借其出色的自然语言生成（Natural Language Generation, NLG）和跨模态推理能力，正逐渐成为解决这一问题的重要技术手

段。通过将遥感数据处理结果自动转化为清晰易懂、逻辑严谨的文字报告，不仅能够提高数据的可用性与用户体验，也能帮助农业生产者和决策者更及时、更准确地做出适宜的田间管理决策。

遥感数据向自然语言的自动转换，涉及跨模态信息融合（Cross-modal Information Fusion）这一技术核心。跨模态信息融合可定义为从不同感知渠道获取的数据（例如遥感图像、土壤湿度传感器读数、气象数据等），通过统一的语义映射和高层次理解，自动转化成一致的自然语言描述。这种过程通常包含两个关键步骤：首先是对遥感数据与地面监测数据进行预处理、特征抽取与模式识别；其次是利用大语言模型对这些抽取后的特征和模式进行语义转化，生成自然语言报告。

在第一个步骤中，一般使用卷积神经网络、循环神经网络或 Transformer 等模型，对多源数据进行特征抽取和整合，得到描述作物长势、土壤状态或病害分布的高层语义特征。这些特征可以通过空间、光谱或时序分析算法生成，如常用的归一化植被指数（NDVI）定义为：

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

其中，NIR 为近红外波段反射率，Red 为红色波段反射率。NDVI 能够有效地反映作物的健康状况、生物量以及光合作用能力。在第二个步骤中，大语言模型将自动抽取的遥感特征及指标转化为直观易懂的文字叙述，例如“当前田块植被指数高于历史同期水平，表明作物生长状态良好，无明显干旱胁迫迹象。”这一转化过程通常采用基于预训练的大语言模型（如 GPT 系列），通过微调方式适配农业遥感数据的特定语境，自动生成能够辅助农户、专家或决策者进行快速、有效决策的文本报告。这种方式显著提高了遥感数据利用效率，使农业决策过程更为透明、高效。

具体到遥感数据自动解读的技术实现上，利用大语言模型将图像分析结果转化为自然语言的过程一般采用图像-文本生成（Image-to-Text Generation）框架。这一框架的技术核心即为图像字幕（Image Captioning）任务，可以被严格定义为：给一幅图像或遥感数据处理的特征图，生成一段准确描述其内容的文本序列。形式化地，图像字幕任务可以用以下条件概率模型表示：

$$P(Y|I; \theta) = \prod_{t=1}^T P(y_t | y_1, y_2, \dots, y_{t-1}, I; \theta)$$

其中  $I$  表示输入图像（或遥感数据特征图）， $Y = (y_1, y_2, \dots, y_T)$  表示生成的自然语言描述， $\theta$  为模型的参数，通常通过深度学习方法训练获得。在实践中，这类任务通常采用“编码器-解码器”（Encoder-Decoder）框架，其中编码器负责从遥感图像或时序数据中抽取特征并生成一个语义嵌入（Semantic Embedding），解码器（如基于 Transformer 架构的 GPT 模型）则通过注意力机制（Attention Mechanism）动态地关注图像特征的不同区域或时序数据的不同时间步，并逐步生成自然语言描述。例如，当输入一幅无人机拍摄的田块高光谱图像时，编码器首先提取出植被指数、叶绿素含量或水分胁迫相关的空间特征，随后解码器利用注意力机制决定每个

生成步骤关注图像中的哪些特定区域，从而生成描述文本如“田块北部区域叶绿素含量低于正常值，可能存在氮肥缺乏或病害感染风险”。相比传统人工解读或依赖专家经验的方式，这种方法极大地提高了分析的效率和可扩展性，并且可自动、实时、批量地处理大范围遥感数据，为农业专家和农户提供及时的田间管理指导信息。

在精准农业决策中，除了利用遥感图像，土壤和气象传感器数据也扮演着至关重要的角色。为实现多源数据的深度融合，可定义一个统一的跨模态嵌入表示 $h$ ：

$$h = W_r v_{\text{img}} + W_s v_{\text{soil}} + W_c v_{\text{climate}},$$

其中 $v_{\text{img}}$ 为遥感图像编码器（如 CNN 或 ViT）提取的视觉特征向量； $v_{\text{soil}}$ 为土壤传感器（湿度、pH、养分含量等）数据通过时间序列模型（如 LSTM[9] 或 Temporal Transformer）生成的特征向量； $v_{\text{climate}}$ 为气象数据（温度、降雨量、风速等）编码后的时空特征； $W_r$ ， $W_s$ ， $W_c$ 为可学习的融合权重矩阵。该融合表示 $h$ 既包含了空间分辨的图像信息，又整合了时序的土壤与气象动态，为下游的自然语言生成提供了丰富的上下文语义基础。随后，将融合特征 $h$ 输入至微调后的大语言模型解码器，通过条件文本生成方法，模型就可以生成个性化、情境化的田间管理建议。例如，当 $h$ 同时显示土壤湿度偏低、近期气温高、植被指数下降时，模型可能输出：“当前土壤含水量已低于安全阈值，请在未来 24 小时内进行灌溉约 20mm，并结合夜间低温时段检查作物蒸腾情况，以防昼夜温差导致干裂。”这种方式将多源传感信息与农业专家经验逻辑无缝映射到自然语言报告中，显著提高了建议的精准度和可操作性。

在实际田间管理中，土壤与气象传感器网络产生的大量时序数据也需要经过专业化指标计算后才能为种植者提供决策参考。其中，作物水分胁迫指数（Crop Water Stress Index, CWSI）即是一个常用的关键参数，可表示为：

$$\text{CWSI} = \frac{T_{\text{canopy}} - T_{\text{wet}}}{T_{\text{dry}} - T_{\text{wet}}},$$

其中， $T_{\text{canopy}}$ 为植被冠层温度，通常由红外传感器测定； $T_{\text{wet}}$ 和 $T_{\text{dry}}$ 分别对应完全湿润和干旱参考条件下的冠层温度，可通过气象数据与标准模型预先估算或实地校准得到。值接近 1 表示高度水分胁迫，接近 0 则说明水分充足。

将这一指标与土壤电导率（Soil Electrical Conductivity, EC）、土壤水分含量（Volumetric Water Content, VWC）和气象参数（如蒸散发速率 $ET_0$ ）等多源数据融合后，可构建一个综合“田间环境胁迫矩阵” $E_t$ ：

$$E_t = [\text{CWSI}_t, \text{EC}_t, \text{VWC}_t, \text{ET}_{0t}] \in \mathbb{R}^4,$$

此矩阵作为上下文输入，通过微调后的大语言模型解码器生成富有操作性的自然语言建议。例如：“当前田块西南角冠层温度较湿润参考温度高出 5°C

（ $\text{CWSI} \approx 0.75$ ），土壤含水量仅为 18%，建议今晚进行间歇灌溉 15 分钟，并在灌后 6 小时复测土壤湿度以评估效果。此外，若未来 48 小时无降雨，请于明早 8–10

点间段再次灌溉，以减少蒸散发损失。”这种做法不仅将多源传感器数据的专业指标以自然语言呈现，还结合了时间段选择与后续监测建议，真正满足了种植者对“何时、何量、如何操作”的精准需求。

为了更好地将这些基于多源传感和遥感数据生成的管理建议落地，大语言模型还可被部署为交互式对话系统，提供“可解释的交互式辅助”。在此模式中，用户不仅能接收系统自动生成的报告，还可通过自然语言提出后续问题，如“为什么西南角水分胁迫更严重？”、“若连续三日高温应如何调整灌溉策略？”系统则利用同一融合表示 $h$ 以及已构建的知识图谱实时回答，并引用具体指标和推理链条。例如，系统可能回应：“西南角下风向导致蒸散发速率提高15%，加之土壤含水量低于邻区4%，形成了更高水分胁迫。若预计未来三日高温，请将灌溉间隔缩短至每12小时，并在中午前后检查冠层温度，及时补水。”这一人机闭环交互方式，能动态更新上下文状态，并在对话历史中累积用户偏好和操作记录，为后续推荐提供个性化支持。此外，通过日志记录用户的疑问及系统生成的解释，还可用于后续模型微调，进一步提升系统对本地化环境和农户需求的适应能力。

本节深入探讨了如何运用大语言模型将遥感图像、土壤及气象传感数据，通过多模态信息融合与图像—文本生成技术，转换为可操作的自然语言报告，并结合关键指标（如NDVI、CWSI、土壤电导率与蒸散发速率等）生成精准的灌溉与施肥建议。我们介绍了跨模态嵌入表征的构建方法，以及在多源数据对齐后的推理流程，演示了模型在理解植被健康、土壤水分胁迫和环境条件变化中的应用场景。同时，借助交互式对话系统，模型能够在用户提问时动态调用先前融合的传感信息与知识图谱，为专家与农户提供可追溯的决策逻辑与补充建议，实现了真正意义上的田间管理智能化。

尽管技术取得了显著进展，但在多源时空数据的标准化校准、模型推理过程的可解释性保障、以及在算力受限环境下的实时部署等方面仍面临挑战。不同传感器和遥感平台在分辨率与测量误差上的差异，需要通过更精细的数据预处理和自适应对齐策略来加以解决；同时，让用户信任模型所生成的自然语言建议，要求系统能够在报告中清晰呈现其内部推理路径。针对这些困难，未来可朝着更加深度的多模态自监督预训练和数字孪生仿真环境方向努力，以提升模型对新场景的泛化与试验效率。此外，将可解释性AI方法应用于农业决策，有助于构建透明的决策图谱；而结合轻量化模型与分布式边缘部署，则可以实现对小型无人机、田间传感节点等终端设备的实时支持。通过构建长期闭环反馈机制，系统得以在专家与农户的持续交互中不断自我校正与优化，最终为精准农业的自动化与可持续发展提供坚实的智能支撑。

### 7.3 智能施肥与灌溉辅助文本交互

面向农户和田间管理者的自然语言交互平台，旨在将复杂的施肥与灌溉决策流程简化为一次自然对话。用户只需通过语音或文字提出问题——例如“现在这块菜地土壤缺氮吗？”或“明天有雨，今天该浇水吗？”——系统便会自动识别需求，抓取作物类型、地块位置和环境条件等关键参数，并实时调用传感器监测数据与气象

预测。随后，依托大语言模型的多轮对话引擎，平台以贴近农事场景的专业口吻，生成精准的施肥配比、灌溉时机与操作要点，甚至对可能的风险因素进行提前预警。整个流程无需用户掌握任何专业术语，只需以日常语言交流，即可获得可执行、可追溯的田间管理建议，真正实现技术对农业生产环节的无感助力。

在精准灌溉策略中，可以依照联合国粮农组织（FAO）发布的《作物参考蒸散发指南》（FAO-56）来估算参考作物蒸散发量，这一标准深受农业水资源管理领域的推崇。该方法将净辐射、气温、风速与空气湿度等多项气象要素纳入同一方程中，计算出代表开阔水面蒸散发能力的基础指标 $ET_0$ 。具体而言，我们通过下面的公式，将日均气温 $T$ 、2米高度风速 $u_2$ 、净辐射 $R_n$ 与土壤热通量 $G$ 等参数有机结合，同时以水汽压曲线斜率 $\Delta$ 与干湿常数 $\gamma$ 为调节因子，得到：

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)}$$

在此基础上，结合特定作物的作物系数 $K_c$ ，可进一步计算出实际蒸散发量 $ET_c = K_c \times ET_0$ ，准确反映作物在当前气候条件下的需水特性。大语言模型接入这一物理水文计算流程后，不仅能够自动提取并填入最新的气象预报与传感器数据，还会基于不同作物生育阶段选取相应的 $K_c$ 值，生成针对性的灌溉文本建议。例如，在预计未来五天无降水、日均温度接近 $30^\circ\text{C}$ 的情境下，模型会将计算出的每日需水量与当前土壤含水水平进行比对，最终以“请于今日傍晚进行8mm灌溉，并在两日后结合冠层温度监测评估补灌需求”的形式输出操作步骤。这种无缝衔接复杂物理模型与自然语言生成的能力，使得灌溉决策既拥有科学依据，又易于农户直观理解和执行。

在精准施肥的应用场景中，系统首先将土壤养分、含水量、作物生长阶段的遥感指数（如叶绿素含量、叶面积指数LAI）以及未来一周的天气预报（降雨量和温度）整合为一个高维特征向量 $x$ 。该向量输入到一个经大规模田间试验数据校准的神经网络代理模型 $f_\phi(x)$ ，模型通过对历史肥效与作物产量间的复杂非线性关系进行学习，直接输出一组最优的氮、磷、钾投放量建议 $\hat{F}$ 。在此基础上，大语言模型将 $\hat{F}$ 与实时环境条件结合起来，生成具备时序分配策略的文本指导，例如推荐在灌溉前释放40%的氮肥以加速根区吸收，剩余部分则在关键分生期与灌后48小时内均匀施放，以减少高温蒸散和降雨冲刷带来的肥料损失。通过这种“数据—代理模型—语言生成”的一体化流程，农户既能获得科学、可追溯的施肥参数，又能理解每一步操作背后的机理逻辑，大幅提升了肥料利用效率并有效降低了环境风险。

在现代精准灌溉中，仅靠经验和规则集难以满足多变气候与严格水资源管理的需求，因而需要引入模型预测控制（Model Predictive Control, MPC）等优化技术。MPC将未来一段时间的气象预报、作物生长模型和土壤水分动力学纳入统一的决策框架，通过连续滚动时域优化确定最优灌溉水量与时机。系统内部首先建立形式化的动态模型：用连续时间的Richards方程描述土壤水分渗流，用作物水分响应曲线模拟蒸散发与生长需求，再通过离散化近似得到可用于数值优化的状态空间表示。具体而言，我们定义状态向量 $s_k = [\theta_k, x_k]$ ，其中 $\theta_k$ 表示时刻 $k$ 的土壤含水

率,  $x_k$  为作物生长指标 (如叶面积指数 LAI)。控制变量为灌溉流量  $u_k$ , 目标函数设定为在保证作物生长需求的同时最小化总水量消耗与潜在地下水补给缺口。通过在每个样本滚动窗口内求解有限时域最优问题, 系统为用户生成“本阶段灌溉 10mm、分两次进行, 每次间隔 6 小时”的建议。将 MPC 优化结果与大语言模型对话接口结合, 可实现在自然语言中呈现“经过模型预测, 下周连续高温会导致土壤含水率下降至 20% 以下, 为保证番茄高光合效率, 建议在今日晚间和明日清晨分别灌溉 5mm”, 并在用户反馈“我明天白天有打药计划”后动态重算, 提供新的灌溉安排。这样不仅让复杂的优化过程对农户“可见”, 也保证了调度策略的实时更新与多轮自适应。

在大规模农场或多田块管理场景中, 单一中央调度往往难以兼顾各区域的异质性需求, 因而可采用多智能体协同 (Multi-Agent Coordination) 的方式, 将每个田块视为一个自治单元, 各自运行本地化的施肥与灌溉代理, 通过自然语言接口与中央模型共享状态信息并协同决策。具体实现时, 每个田块代理基于自身的传感器读数 (如土壤水分、养分、作物长势指标) 运行一个轻量级的局部控制器, 同时与中央大语言模型建立对话通道, 上报关键状态与需求。中央模型则在获得来自多个田块的自然语言摘要 (例如“北区土壤含水量已降至 18%, 氮素消耗加速”) 后, 综合考虑整体水资源和肥料库存情况, 通过跨区资源调度算法分配有限资源, 并以自然语言下达差异化指导, 如“对北区追加 8mm 灌溉, 并将南区施肥量下调 10% 以保障总体水肥平衡”。

在这种协同框架下, 每个田块代理不仅是决策执行者, 还是重要的反馈源——它会在执行完灌溉或施肥操作后, 以自然语言形式报告实施效果与环境响应, 例如“灌后土壤含水量提升 12%, 冠层温度下降 2°C”或“施肥后叶绿素指数比前期提升 0.06”。中央模型据此进一步调整参数与策略, 实现对田块的动态自适应优化。随着季节更替和作物生长周期的推进, 系统会将每次决策的执行反馈累积到长期学习库, 通过定期精调大语言模型和本地代理的策略网络, 使其在下一个生育期开始时即具备更贴近本地气候、土壤与作物品种的决策能力。这种多层次的闭环学习过程, 使得智能施肥与灌溉不仅能满足即时需求, 还能在跨季节、跨年际的尺度上不断提升调度精度与资源利用效率, 真正实现对农业生产全生命周期的智能化支持。

在衡量智能施肥与灌溉方案对经济和环境的整体影响时, 需要引入了一种动态收益—成本—环境损失一体化评估框架。该框架将作物产量增益、资源投入成本节约与环境外部性 (如氮素淋失、水土流失、甲烷和氧化亚氮排放) 联合建模为一个时间连续的效益函数:

$$B(t) = \underbrace{Y(t) p_Y}_{\text{产量收益}} - \underbrace{C_{\text{water}}(t) p_W + C_{\text{fert}}(t) p_F}_{\text{资源投入成本}} - \underbrace{\int_{\Omega} L(x, t) \lambda(x) dx}_{\text{环境损失代价}}$$

其中  $Y(t)$  是模型预测的作物即期产量,  $p_Y$  是市场售价;  $C_{\text{water}}$  和  $C_{\text{fert}}$  分别为智能灌溉与施肥所消耗的水量和肥料量,  $p_W, p_F$  为对应的单位价格; 最后的积分项则对田间空间区域  $\Omega$  内的环境损失量  $L(x, t)$  包括氮素淋失强度、土壤侵蚀速率和温室气体排

放密度)按不同区域敏感度 $\lambda(x)$ 加权求和。通过对 $B(t)$ 在生育期 $[0, T]$ 上的数值积分,系统能够量化整个生产周期的综合净收益,并将关键影响因素映射到自然语言报告中,例如“精准灌溉与施肥在本季节为您带来净增收益 1,200 美元,同时减少了约 15 吨氮素流失,相当于降低地下水富营养化风险指标 0.8 级”。这一方法使农户能够直观洞察技术投入带来的多维度回报,并在不同管理策略之间做出数据驱动的最优选择。

面向农户的对话式系统将“今天要不要浇水”“如何调整氮肥用量”等口语化问题,自动转换为意图识别与槽位抽取的结构化请求;系统再结合土壤水分传感、遥感植被指数和短期气象预报,通过集成学习模型和模型预测控制算法,计算出精确的灌溉量与施肥配比,并以易于操作的自然语言报告给出操作步骤与注意事项。多田块管理场景下,各区块代理实时上报地块状态、接收集中资源调度,形成联合决策网络;而通过对比历史灌溉与施肥方案对作物产量、水分利用效率和养分利用效率的影响,还能直观量化经济收益和环境外部性。实时对话和可视化界面进一步降低了用户的学习成本,提高了信任度。面对多源数据标准化、模型可解释性与部署算力限制等挑战,这套系统通过多模态融合、可追溯的决策链路和轻量化部署,正向着让精准灌溉与施肥真正普惠于每一位农事生产者的目标迈进。

依赖多源传感与遥感数据的智能灌溉和施肥系统在真实田间部署时,常面临数据对齐精度不足、气象预报不确定性以及传感器故障带来的信息丢失。用户对“黑箱”式决策的信任度也亟须通过可解释 AI 机制来提升。同时,大规模模型在低算力终端的实时响应能力和隐私保护也需要更高效的轻量化与联邦学习解决方案。未来研究可聚焦于开发更鲁棒的多模态自监督预训练框架,以在极端天气或设备异常时保持高质量决策;引入可解释性 AI 与交互式故障诊断,确保每条建议都能提供可追溯的推理链路;以及结合微服务化部署与边缘计算,实现在带宽受限的田间环境中稳定运行。此外,将经济风险评估和碳足迹量化纳入决策闭环,能够帮助系统在满足产量需求的同时,真正实现资源节约与环境保护的可持续发展目标。

## 7.4 病虫害智能防治知识库

在农业病虫害防治中,构建一个兼具深度语义与多模态信息的智能知识库是提升诊断与处置效率的关键。该知识库需汇集来自学术期刊、病虫害图谱、高分辨率田间影像以及农户上报的病例数据,通过自然语言处理(NLP)技术对文献进行精准分段、实体识别与关系抽取,再辅以计算机视觉算法对图谱和影像进行病斑检测与特征提取。此外,利用知识图谱技术,将“病原体—宿主—症状—防治方法”这些核心概念以节点—边结构表示,并为每条边分配多源数据支持的置信度指标;同时,针对农户上报的病例文本,经由强化学习微调的语言模型可实现症状描述与知识库实体的自动对齐,确保案例与文献研究成果无缝衔接。最终,这一智能化平台能够在“大数据+深度学习+知识图谱”框架下,为后续的实时问答和对话式防治策略提供坚实的数据支撑。

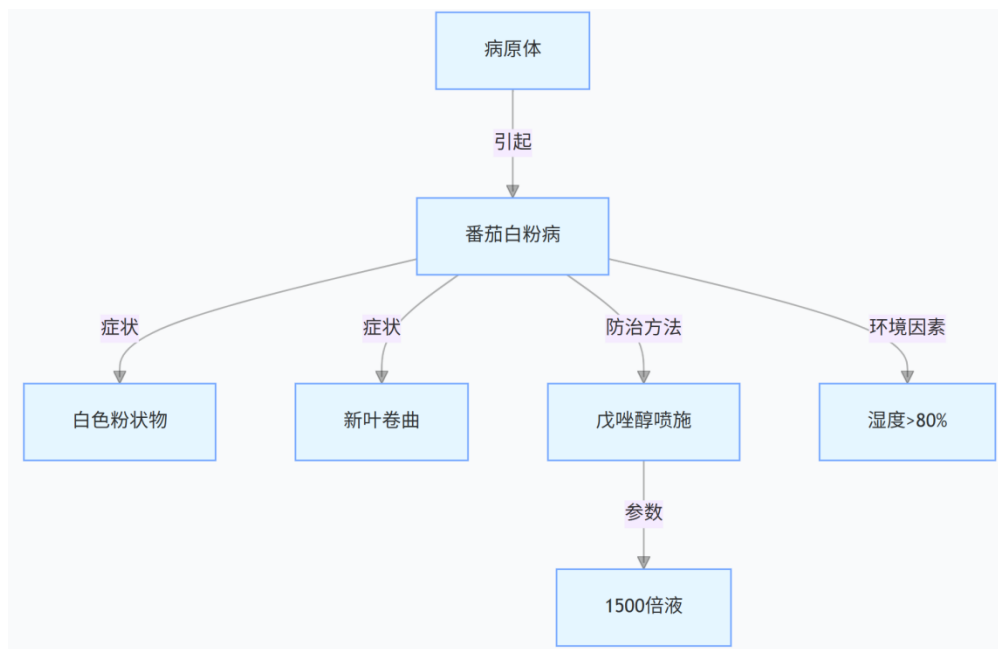


图 7-2 大语言模型在病虫害智能防治的应用框架图

在实时问答与对话式防治策略环节，系统依托检索增强生成（Retrieval-Augmented Generation, RAG）框架，将用户的自然语言询问与底层知识库紧密耦合。用户输入诸如“叶片出现褐色斑点，如何处理？”之类的问句后，首先通过双塔模型（Bi-Encoder）将查询文本 $q$ 与知识库中所有候选段落 $d_i$ 分别映射为 embedding 向量 $e_q$ 与 $e_d$ ，并以余弦相似度为度量进行前 $k$ 项检索：

$$\text{Score}(q, d_i) = \frac{e_q \cdot e_{d_i}}{\|e_q\| \|e_{d_i}\|}, \text{top}k = \underset{i}{\operatorname{argmax}} \text{Score}(q, d_i).$$

检索出的高相关段落随后被送入生成模型（如基于 Transformer 的 Seq2Seq 架构），与对话历史上下文一同作为条件，共同驱动响应生成。这一生成过程不仅在参数层面调用了大语言模型预训练所得的深层知识，还通过微调融入了农业防治领域的专业语料，实现对“病斑模型”、“物候期”等专业概念的精准运用。

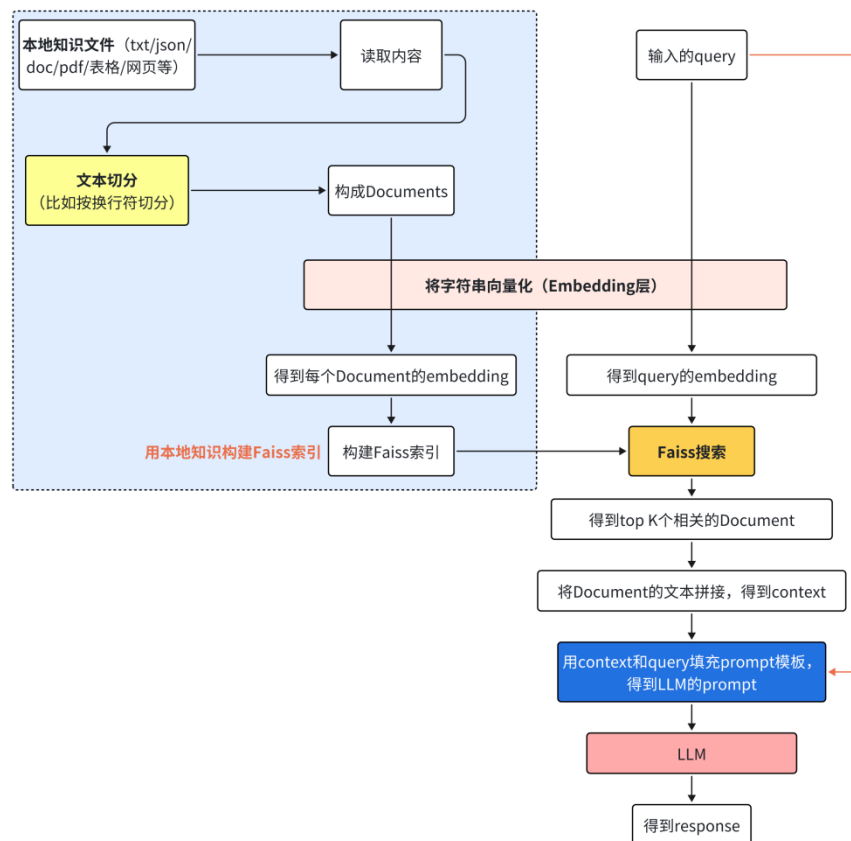


图 7-3 实时问答与对话式防治策略流程

对话状态跟踪（Dialogue State Tracking, DST）模块则负责维护多轮交互中的槽位填充与意图演变，例如记录已知症状、作物品种和田块位置，以便在后续回合继续补充或校正。当系统在生成阶段遇到不确定或新颖场景时，还会触发“在线学习”子流程，将该对话及后续用户评价反馈给强化学习微调器，用以动态调整检索-生成策略。通过这种 RAG + DST + 在线微调的多层闭环，对话机器人能够在几乎零延迟的情境下，为农户提供涵盖病因诊断、药剂推荐、施药时间窗和风险提示在内的全流程防治方案，对话示例可能为：

用户：“玉米叶尖发黄，有点干枯。”

系统：“根据当前叶绿素含量下降 15% 和土壤含氮量仅为 12 mg/kg，初步判断为氮素不足。建议立即喷施 0.5% 硝态氮水溶液，并在 5 天后复测叶片颜色。如有黄化加剧，请结合田间湿度再行补施。”

这一智能问答系统将知识库检索结果、表型诊断模型与实证案例融合于同一条回复中，既保证了信息的准确性，也兼顾了可操作性与可解释性，真正实现了病虫害防治的“即问即答”与“策略可视”功能。

在病虫害防治决策流程中，经济损害阈值（EIL）与经济阈值（ET）并非孤立的静态数值，而是建立在作物—害虫群体动力学模型、市场波动模型和控制技术响应模型三者耦合基础之上的动态指标。群体动力学常通过黎氏矩阵（Leslie Matrix）或离散时间 Logistic 方程模拟害虫数量随时间的演变，并结合温湿度对卵孵化与成虫繁殖率的影响，生成未来几日的密度预测曲线；市场波动模型则以上月成交价、区域供需及政策补贴为主要变量，动态输出每单位产量的经济价值；控制响应模型则通过历史防治试验数据拟合不同防治措施（化学、生物、农业）在不同环境下的实际有效率。当上述三大子模型在系统中完成联合仿真后，就可以获得在给定时间窗口内的动态 EIL 与 ET——即在不同温湿度背景下、不同市场价格和不同防治手段响应效率组合中，害虫密度应介入防控的最小临界值。智能问答机器人在对话中只需引用这一动态阈值并结合当前田块的实时密度和环境参数，就能够输出诸如“当前害虫潜势量为 2200 只/地块，已超过动态经济阈值 1800，建议在未来 24 小时内采用 X 剂量 Y 方法进行施药，并在施后 3 日进行二次监测”的精准策略，而无需用户了解阈值背后的复杂模型，真正实现了“将高阶数值模拟隐匿于自然语言背后”的智能化防治新范式。

在防治流程闭环的设计中，需要将病虫害控制效果、成本投入与生态影响纳入同一时序优化框架，以保证每一次干预既有效又可持续。基于多目标强化学习（Multi-Objective Reinforcement Learning, MORL）的方法，可将病虫害防治策略视为智能体在环境中执行的动作序列，而其累积回报函数  $J$  则由产量增益  $R_Y$ 、经济成本节省  $R_C$  和环境足迹降低  $R_E$  三部分加权组合：

$$J = \mathbb{E} \left[ \sum_{t=0}^T \gamma^t (w_Y R_Y(s_t, a_t) + w_C R_C(s_t, a_t) - w_E R_E(s_t, a_t)) \right]$$

其中  $\gamma$  是折扣因子， $w_Y, w_C, w_E$  分别为产量、成本与环境模块的权重，可动态依据区域可持续发展目标调整， $R_Y$  通过作物生长模型预测策略执行后的增产量， $R_C$  由资源单价和用量确定的成本差异计算获得， $R_E$  则依据生命周期评估（Life Cycle Assessment, LCA）方法量化的温室气体排放与生态影响得出。在实际系统中，语言模型参与生成的策略不仅要考虑即时回报，还需根据长期反馈不断更新策略网络参数，形成“预测—执行—评估—优化”的闭环。例如，每次防治后系统会自动记录执行结果（如害虫密度降幅、农膜残留、非目标生物影响指标等），并将这些数据与回报函数中的  $R_Y, R_C, R_E$  对应项进行匹配，交由策略更新模块进行梯度调整，优化未来的策略分配。最终，问答接口在与用户对话时，不仅给出“在当前温湿度条件下建议喷施 A 药剂 0.3 kg/ha”，还会附上“预计本次干预可提高产量 2%，节省药剂成本 15%，并减少  $N_2O$  排放约 0.2 kgCO<sub>2e</sub>”的多维度数据支持，使防治决策既具备科学严谨性，又兼顾生态可持续性。

为了保证知识库的时效性，新上报的田间病例与最新文献需要被快速整合并驱动模型持续适应。增量知识图谱更新过程首先将新增三元组  $(h, r, t)$  插入现有图谱，同时对图谱嵌入（Graph Embedding）进行局部微调。以常见的 TransE 模型为例，新增实体对  $(h, r, t)$  的嵌入向量  $h, t$  会依据以下边缘化损失进行在线更新：

$$L_{\text{new}} = \max(0, \gamma + d(h + r, t) - d(h' + r, t')),$$

其中 $(h', r, t')$ 为采样的负例， $\gamma$ 为边际超参数，距离函数 $d$ 通常采用欧氏距离或余弦距离。此方式使得原有嵌入 $h, t$ 仅在必要的局部子图上发生变化，避免整图重训带来的高昂开销。

与此同时，基于检索增强生成（RAG）的问答模型也在新案例对话中进行微调：将每次用户与系统的问答对 $(q, a)$ 通过混合蒸馏（Knowledge Distillation）技术加入训练集中，使用交叉熵损失 $L_{CE} = -\sum_t a_t \log p_\theta(a_t|q)$ 对生成模型参数进行逐步优化。这种双管齐下的增量学习策略，既保持了知识图谱的结构一致性，也让语言模型在防治策略输出时能够自动吸纳最新经验，使诊断推荐的准确率与实时性不断提升。

在确保系统在实际应用中持续高效可靠运行的同时，对问答与知识检索模块的评估也至关重要。检索阶段常以 Precision@k 与 Recall@k 衡量前 k 条检索结果的相关性：

$$\text{Precision@}k = \frac{|\{\text{Relevant}\} \cap \{\text{Retrieved}_k\}|}{k},$$

$$\text{Recall@}k = \frac{|\{\text{Relevant}\} \cap \{\text{Retrieved}_k\}|}{|\{\text{Relevant}\}|},$$

生成阶段则结合自动评价指标与人工评估：BLEU、ROUGE 可量化回答与专家标准文本的匹配度，而基于标注的准确率（Accuracy）和覆盖率（Coverage）则评估回答的正确性与全面性。为捕捉用户体验，还需定期进行 A/B 测试与问卷调查，将用户满意度 $S$ （量表 1-5 分）与回答响应延迟 $L$ （秒）联合纳入服务质量指标：

$$\text{QoS} = \alpha \bar{S} - \beta \bar{L}, \alpha + \beta = 1,$$

以此动态调整检索深度、生成长度与并发吞吐量。通过上述多维评估与持续优化，病虫害防治知识库能够在大规模真实环境中保持高精度、高可用与高用户信任度。

病虫害智能防治知识库汇集来自学术文献、病虫图谱和田间病例的多源信息，通过自然语言处理与计算机视觉技术实现实体与关系的精确抽取，并以知识图谱形式统一呈现。检索增强生成架构帮助系统在用户描述病症后快速定位相关知识段，结合动态经济阈值与环境足迹模型生成可执行的防治策略。多目标强化学习框架确保防治方案在提升产量、控制成本与减少环境影响之间保持平衡，增量更新机制和在线评估指标持续优化知识图谱与生成模型，最终通过对话机器人以清晰、易于操作的自然语言完成全流程防治指导。

未来研究可以探索在弱监督和自监督预训练下，提升系统对少量标注或新兴病虫害数据的自适应能力。可解释 AI 方法将使防治建议中的推理链条更加透明，增强农户信任。基于联邦学习与差分隐私的多方协同训练可在保护数据安全的前提下实现知识共享。跨语言与跨区域的本地化适配技术将推动系统在全球多样化农业场景

中的应用。与专家协同的在线评审平台和模拟仿真试验环境能够加速新防治策略的验证与落地。

## 第 7 章参考文献

- [15] Mohsen Yoosefzadeh-Najafabadi. “From text to traits: exploring the role of large language models in plant breeding”. In: *Frontiers in Plant Science* 16 (2025), p. 1583344.
- [16] Jacob Devlin et al. “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding”. In: *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics*. 2019, pp. 4171–4186.
- [17] Alec Radford et al. “Improving language understanding by generative pre-training”. In: (2018).
- [18] Tanya Z Berardini et al. “The Arabidopsis information resource: making and mining the “gold standard” annotated reference plant genome”. In: *genesis* 53.8 (2015), pp. 474–485.
- [19] John L Portwood et al. “MaizeGDB 2018: the maize multi-genome genetics and genomics database”. In: *Nucleic acids research* 47.D1 (2019), pp. D1146–D1154.
- [20] Shu Ouyang et al. “The TIGR rice genome annotation resource: improvements and new features”. In: *Nucleic acids research* 35.suppl\_1 (2007), pp. D883–D887.
- [21] Compton J Tucker. “Red and photographic infrared linear combinations for monitoring vegetation”. In: *Remote sensing of Environment* 8.2 (1979), pp. 127–150.
- [22] Alexey Dosovitskiy et al. “An Image is Worth 16×16 Words: Transformers for Image Recognition at Scale”. In: *International Conference on Learning Representations* (2021).
- [23] Sepp Hochreiter and Jürgen Schmidhuber. “Long Short-Term Memory”. In: *Neural Computation* 9.8 (1997), pp. 1735–1780.
- [24] Bryan Lim et al. “Temporal fusion transformers for interpretable multi-horizon time series forecasting”. In: *International Journal of Forecasting* 37.4 (2021), pp. 1748–

- [25] Richard G Allen et al. “Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56”. In: Fao, Rome 300.9 (1998), p. D05109.
- [26] Conor F Hayes et al. “A practical guide to multi-objective reinforcement learning and planning”. In: Autonomous Agents and Multi-Agent Systems 36.1 (2022), p. 26.
- [27] Antoine Bordes et al. “Translating embeddings for modeling multi-relational data”. In: Advances in neural information processing systems 26 (2013).
- [28] Patrick Lewis et al. “Retrieval-augmented generation for knowledge-intensive nlp tasks”. In: Advances in neural information processing systems 33 (2020), pp. 9459– 9474.

## 8. 大语言模型中的多智能体协作

在现代农业智能化进程中，单一的大语言模型虽具备强大的自然语言理解与生成能力，却很难独立完成覆盖从田间到市场、从感知到决策的全链路任务。农业场景下的信息流呈现“多维、多源、多时序”的特点：无人机与卫星遥感产生的高分辨率图像需要与土壤传感器的实时监测数据、气象站的历史气候记录相结合；农艺师现场观测形成的文字报告与政府颁布的政策文件同样为决策提供了重要线索；在供应链和市场环节，价格波动、政策补贴与物流成本的多模态信息又需要与田间生产状况紧密关联。若将所有这些任务都交由单一模型处理，不仅会导致性能瓶颈，还难以满足复杂决策中对多专业知识协同的需求。

“多智能体”（Multi-Agent）协作模式正是为应对这一挑战而提出的革新思路。与传统意义上的单一智能体不同，多智能体系统由若干个具备局部感知与决策能力的“子模型”或“代理”（Agent）构成，每个代理可专注于不同任务或专业领域，并通过协调与博弈实现协同优化。以智能种植管理为例，可以将“种植 Agent”负责作物生长模型与播种策略，“气象 Agent”专注于气候曲线与极端天气预警，“病害 Agent”聚焦于病虫害图像识别与危害预测等。在实际应用中，这些代理以结构化消息协议相互通信，共同为“协调 Agent”提供多源信息，由后者整合全局视角，输出最优的种植与灌溉建议。这种拆分与协作的思路，使得每个子系统在各自领域拥有足够的专业深度，又能通过统一的接口将各类信息无缝对接，从而在整体上形成“1+1>2”的协同效应。

与此同时，随着大语言模型与多种外部工具、插件的结合日益普及，LLM-Agent 架构迅速崛起。基于该架构，单一的语言模型不再仅限于文本生成与理解，而是能够在多轮对话中自主判断何时调用外部工具（如天气 API、数据库查询或图像处理模块），并结合这些模块的输出形成更高效、更准确的决策链路。例如，当农户在对话框输入“请帮我预测下周某地的气温和降雨概率”时，“对话 Agent”会识别出气象查询意图，调用“气象 Agent”所绑定的天气预报 API 获取最新数据，再将结果反馈给农户。同理，当用户询问“如何应对当前田间发现的病斑”时，“对话 Agent”会联合“病害 Agent”进行图像诊断并检索权威防治方案，最终生成可执行的防治建议。这样的多 Agent 架构不仅让大语言模型在动态场景中能够自动分解任务，还在分工协作中显著提升了系统的灵活性和扩展性。

在学术研究与工程实践中，LangChain、Auto-GPT、AgentGPT 等多 Agent 协作框架相继问世，它们从基础组件（如 Chains、Agents、Memory）开始，提供了从任务串联到策略规划的全流程支持。借助这些框架，开发者可以相对便捷地设计多 Agent 系统：先定义各 Agent 的角色与功能，再设定任务分解规则与对话协议，最后将各 Agent 绑定至不同的工具与数据源，实现顶层规划与底层执行的有机融合。例如，在 LangChain 框架中，开发者可利用 Chain 定义一个由“提问 Agent → 检索 Agent → 推理 Agent → 生成 Agent”组成的链式结构，实现复杂问答与推理任务的自动化；在 AgentGPT 平台上，用户只需通过一句话描述任务（如“为玉米抗

病育种设计实验方案”），系统就能自动拆解子任务，创建多个角色分工明确的代理并协调完成整个研究流程。

为何在农业场景尤其需要多 Agent 协作？关键在于农业任务本身的多专业、多阶段和多目标特性。传统农业决策往往依赖单一专家或模块进行局部优化，很难顾及全局。例如，在面对农田水肥平衡时，若仅依赖气象数据或土壤数据单一维度进行判断，就无法兼顾作物生长周期与区域水资源配给；若仅以市场价格为导向制定种植计划，就容易在遭遇极端天气时造成巨大损失。多 Agent 协作则能够将种植策略、气象监测、病虫害预警、市场预测等各个维度拆分为专门的子系统，由各代理各司其职并实时共享信息，最终由“协调 Agent”或“决策 Agent”在多目标约束下产生最优方案，既保证了各环节的专业深度，也提升了系统对动态环境的适应能力。

此外，多 Agent 协作还能够在分布式部署中发挥优势。在大型农业生产区域，不同子系统可以部署在不同的边缘侧节点或云端平台：地块现场的“病害 Agent”可直接部署在农机设备或无人机边缘设备上，利用本地计算资源进行实时影像分析；“气象 Agent”则可部署在云端获取全国气象数据并进行时空预测；“市场 Agent”则运行在电商或交易平台的服务器上，实时更新价格与供需信息。通过统一的消息总线或 API 网关，各代理之间可跨地域、跨平台地交换信息，实现真正意义上的“云—边—端”协同。这种部署方式既充分利用了本地算力，又兼顾云端大规模计算资源，使系统能够在保障实时性的同时控制总体成本。

在本章的后续内容中，我们将依次展开三个层面的深入探讨：

- **多 Agent 概念与在大语言模型中的延伸：**本节首先从多智能体系统（MAS）的基本概念入手，介绍智能体、环境与多智能体交互的形式化定义，以及共享与竞争博弈的基本范式。随后，我们分析大语言模型中“代理”概念的升级——在 LLM-Agent 架构下，单一大模型既可扮演“对话 Agent”角色，也能模拟成多个具备不同职责的“专家 Agent”，并通过插件机制或链式调用实现任务分工。最后，通过需求分解与数据多源等农业场景特点，阐述为何在复杂的农事管理、供应链优化与政策解读等情景下，必须引入多 Agent 协作才能满足系统对精度与效率的双重要求。

- **LLM-Agent 框架与工具链：**本节将重点介绍业界主流的 LLM-Agent 协作框架，如 LangChain、Auto-GPT 和 AgentGPT 的核心设计思路与组件功能。从 Chains、Agents、Memory 等概念入手，说明如何在不同框架下实现任务流水线的定义、角色设定与记忆管理；并剖析常见的对话管理、任务规划与工具调用机制，让读者能够根据自己的项目需求，与农业传感器平台、知识库和第三方 API 进行高效对接。此外，将提及如何利用这些框架构建农业专属“专家 Agent”“市场 Agent”“政策 Agent”等角色，并按需制定交互协议与团队协作流程。

- **协同与通信机制：**多 Agent 协作的核心在于代理间的高效通信与知识共享。本节将论述在大语言模型代理间设计对话协议的原则，包括如何制定统一的消息格式、事件触发规则与回路控制策略；如何通过共享知识图谱或分布式缓存实现信息同步与避免重复计算；以及在资源竞争与任务冲突场景下，如何运用博弈论或约束

规划等方法进行协商与冲突化解。我们还将探讨一种轻量级的“元代理协调器”模式，作为信息流转的核心枢纽，让各子代理能够在多重任务目标与资源约束下高效协作。

● **多 Agent 在农业智能决策的典型案例分析：**通过具体示例，将展示多 Agent 协作在农事管理、供应链和跨行业场景中的落地应用。首先介绍“种植 Agent”“气象 Agent”“病害 Agent”在田间管理闭环中的实时协同；随后，说明“价格预测 Agent”“物流调度 Agent”“政策解析 Agent”如何分工合作，实现供应链端到端的优化；最后展望跨行业融合场景下的“Global Registry Agent”“Semantic Middleware Agent”“Cross-Domain Service Agent”等角色，展示未来农业与金融、环境监测、法律监管等多领域的深度联动。

通过本章的学习，读者将能够深刻理解多 Agent 协作在大语言模型应用中的原理与价值，掌握基于主流框架搭建 LLM-Agent 系统的关键技术与实战技巧，并从农事管理与供应链优化等典型案例中汲取经验，为构建面向未来的智能农业生态打

下坚实基础。

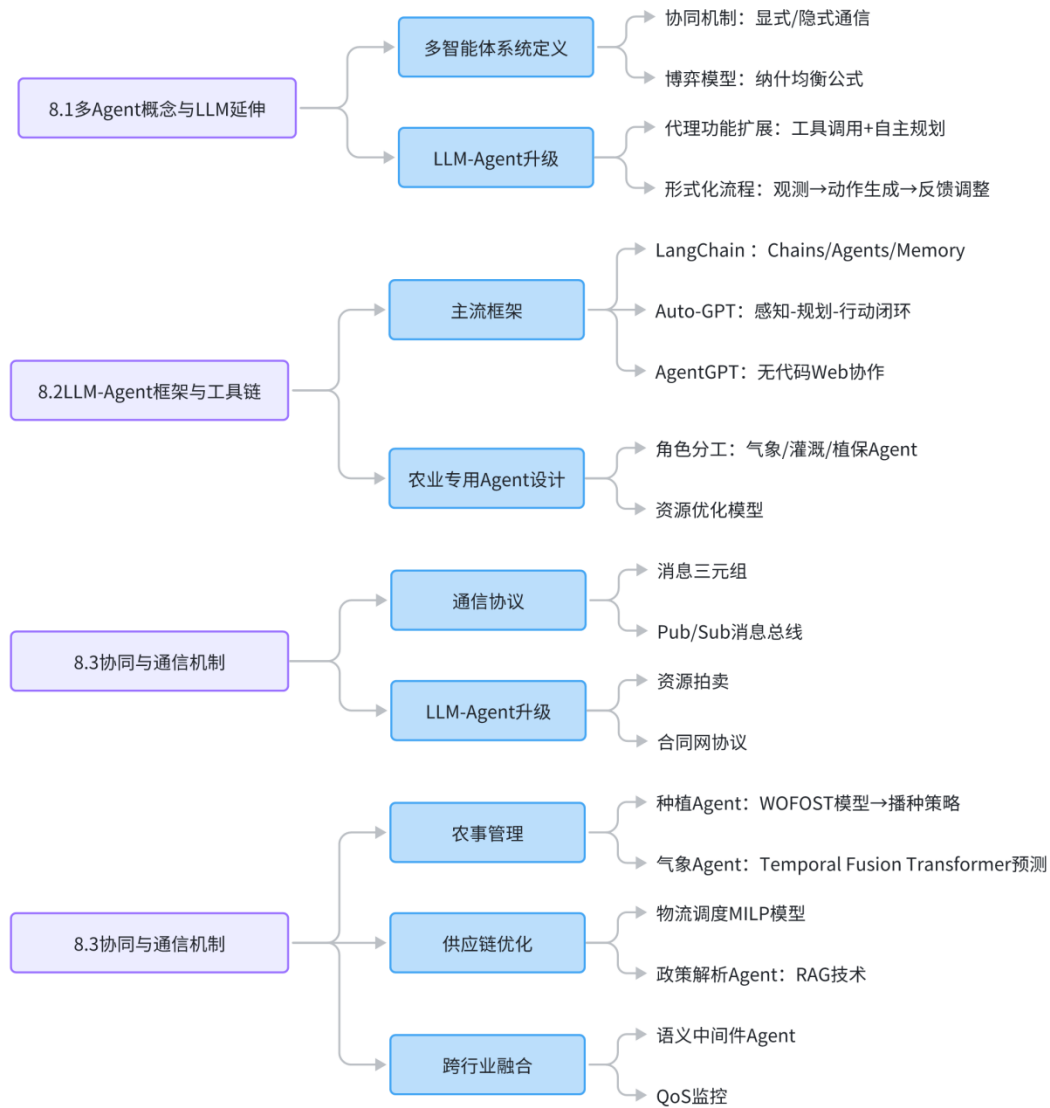


图 8-1 基于大语言模型的多智能体协作应用划分

## 8.1 多 Agent 概念与在大语言模型中的延伸

在人工智能研究领域，多智能体系统一般是指由多个自主且智能的个体组成的系统，这些个体能够自主感知环境信息、独立或协作地做出决策和执行动作，并通过一定的交互机制实现自身或系统整体的目标。从形式化的定义来看，一个典型的多智能体系统可表示为：

$$MAS = (\mathcal{N}, \mathcal{S}, \{\mathcal{A}_i\}_{i \in \mathcal{N}}, \{\mathcal{O}_i\}_{i \in \mathcal{N}}, \mathcal{T}, \{\mathcal{R}_i\}_{i \in \mathcal{N}})$$

其中,  $\mathcal{N}$  表示智能体的集合;  $\mathcal{S}$  为系统所处的共享状态空间;  $\mathcal{A}_i$  为每个智能体  $i$  的动作空间集合;  $\mathcal{O}_i$  为每个智能体对环境的观测空间;  $\mathcal{T}$  是状态转移函数, 用以描述系统状态在智能体动作作用下如何动态变化;  $R_i$  为智能体  $i$  在与环境及其他智能体交互过程中所获得的回报函数。在这种框架下, 智能体既可通过共享目标函数实现完全协作关系, 也可具有各自独立甚至冲突的回报函数, 形成竞争或博弈关系。此外, 多智能体系统中还广泛采用任务分解机制, 即将复杂任务分解为若干子任务并分配给不同的智能体执行, 以便显著提高整体系统的求解效率, 更加适用于现实中动态且复杂的应用场景。

多智能体系统的有效运行, 很大程度上依赖于智能体之间的协同

(Coordination) 能力。协同一般被定义为智能体之间为了完成共同任务或目标, 通过一定的机制 (显式或隐式) 实现信息共享与策略协调的过程。显式协同

(Explicit Coordination) 通常通过明确的通信协议实现, 各智能体可以直接交换各自观测到的状态、选择的动作或局部策略信息, 从而实现决策的统一或互补; 而隐式协同 (Implicit Coordination) 则不直接依靠明确的信息交换, 而是智能体根据观测到的环境状态或其他智能体的行动后果, 自发地调整自身的策略以达成协调效果。典型的隐式协同机制包括策略池 (Policy Pool) 共享和公共知识 (Common Knowledge) 推理等方式。特别是在智能体交互频繁但通信成本高昂或受限的情境下, 隐式协同机制的应用显得尤为重要。从理论角度讲, 协同的效果可通过多智能体联合策略 (Joint Policy) 进行形式化描述。联合策略定义为:

$$\pi(\mathbf{a}|\mathbf{o}) = \prod_{i \in \mathcal{N}} \pi(a_i|o_i)$$

其中,  $\pi_i(a_i|o_i)$  表示智能体  $i$  在观测到环境状态  $o_i$  时, 选择动作  $a_i$  的策略; 联合策略  $\pi(\mathbf{a}|\mathbf{o})$  则代表所有智能体在各自观测状态  $\mathbf{o}$  下同时选择动作组合  $\mathbf{a}$  的概率分布。通过合理优化联合策略, 使各个智能体的动作既相互协调又充分利用环境信息, 整个系统的性能得以大幅提升。此外, 为评估协同的有效性, 常用“联合收益” (Joint Reward) 作为衡量指标, 即在执行联合策略后, 整个智能体群体共同获得的综合性收益:

$$R_{\text{joint}}(\mathbf{s}, \mathbf{a}) = f(\{\mathcal{R}_i(s_i, a_i)\}_{i \in \mathcal{N}})$$

其中,  $f(\cdot)$  为智能体各自收益的聚合函数, 如加权求和或最小收益 (Minimax) 方式。通过对联合收益的优化, 智能体群体可在复杂环境中实现高度协同, 从而显著提高整体任务完成效率。

在多智能体系统中, 除了智能体之间的协同关系外, 还广泛存在着博弈

(Game) 的关系。博弈通常被定义为多个智能体在交互过程中追求各自收益最大化而形成的策略对抗局面, 具体而言, 每个智能体的回报函数在一定程度上依赖于其他智能体的策略选择和动作执行结果。因此, 每个智能体在决策时不仅需要考虑环境本身的状态, 还必须预测和评估其他智能体可能采取的行动, 以便最大化自身的期望收益。这种决策过程中智能体间相互策略选择与反应的动态关系即为博弈。形式上, 多智能体博弈通常以策略博弈 (Strategic Game) 或随机博弈 (Stochastic Game) 的形式加以描述。以随机博弈为例, 其可以用如下元组表示:

$$\mathcal{G} = (\mathcal{N}, \mathcal{S}, \{\mathcal{A}_i\}_{i \in \mathcal{N}}, \mathcal{T}, \{\mathcal{R}_i\}_{i \in \mathcal{N}}, \gamma)$$

其中， $\mathcal{N}$  表示参与博弈的智能体集合， $\mathcal{S}$  为系统所处的状态空间， $\mathcal{A}_i$  为每个智能体  $i$  的动作集合， $\mathcal{T}(s'|s, \mathbf{a})$  表示系统从状态  $s$  在联合动作  $\mathbf{a}$  下转移至状态  $s'$  的概率分布， $\mathcal{R}_i(s, \mathbf{a})$  为智能体  $i$  在状态  $s$  和联合动作  $\mathbf{a}$  下获得的即时回报， $\gamma \in [0, 1)$  则为折扣因子，用以衡量智能体对于未来收益的折现程度。在每个时间步  $t$ ，各智能体同时选择动作，系统状态随之更新并产生各自的即时回报。

在博弈场景下，多智能体系统中重要的均衡概念是纳什均衡（Nash Equilibrium）[2]。纳什均衡被定义为这样一种策略组合：当每个智能体在固定其他智能体策略不变的情况下，所选择的策略都是自身收益的最优反应。对于策略集合  $\pi_{i \in \mathcal{N}}$ ，若满足

$$\forall i \in \mathcal{N}, \quad \pi_i^* = \operatorname{argmax}_{\pi_i} V_i(\pi_i, \pi_{-i}^*)$$

则称策略组合  $\pi_i^*_{i \in \mathcal{N}}$  为纳什均衡。其中， $V_i(\pi_i, \pi_{-i})$  为智能体  $i$  在采取策略  $\pi_i$ ，其他智能体采取策略  $\pi_{-i}$  时获得的期望收益。这一均衡概念是分析智能体在竞争或部分竞争环境下策略稳定性的重要工具。尤其在资源有限、利益冲突显著的环境下，智能体通过学习纳什均衡策略能够有效避免策略不稳定所带来的系统波动与效率损失。

随着以 ChatGPT 为代表的大语言模型（Large Language Models, LLM）的迅速发展，“代理”（Agent）这一经典的人工智能概念在内涵与外延上都获得了显著扩展。传统意义上的 Agent 通常强调感知—决策—执行这一流程，并将环境信息映射至相应的动作空间；而在大语言模型的背景下，Agent 的功能则得以极大延伸，其不仅能够处理复杂的自然语言理解与生成任务，还可主动调用外部工具、执行自主规划（Autonomous Planning）和长期目标追踪（Goal Tracking），形成一种全新的交互式智能范式。例如，ChatGPT + Plugins 模式允许语言模型在与用户对话的过程中动态调用第三方 API 或外部知识库，从而实现单纯语言生成之外的更多高级功能。其核心机制可抽象为检索增强生成（Retrieval-Augmented Generation, RAG）的扩展形式：首先语言模型解析用户输入并判断所需的外部工具；然后将请求转换成对应工具的 API 调用格式，获取外部执行结果；最后再次将结果整合回语言生成流程，给用户完整且动态的回答。此外，诸如 Auto-GPT 和 MetaGPT[6] 之类的新型语言模型代理，则进一步将任务自主规划与多步决策引入了大语言模型的应用框架。Auto-GPT 使用自主任务分解（Autonomous Task Decomposition）机制，根据给定的目标自动生成一系列子任务，再依次调用语言模型或其他外部工具执行这些任务，并基于执行结果动态调整策略与目标。在此过程中，语言模型既扮演了任务规划者（Task Planner）的角色，也同时充当任务执行者（Executor）与评估反馈者（Evaluator），使得单一的大语言模型即可完成较为复杂的多步交互与规划

任务。

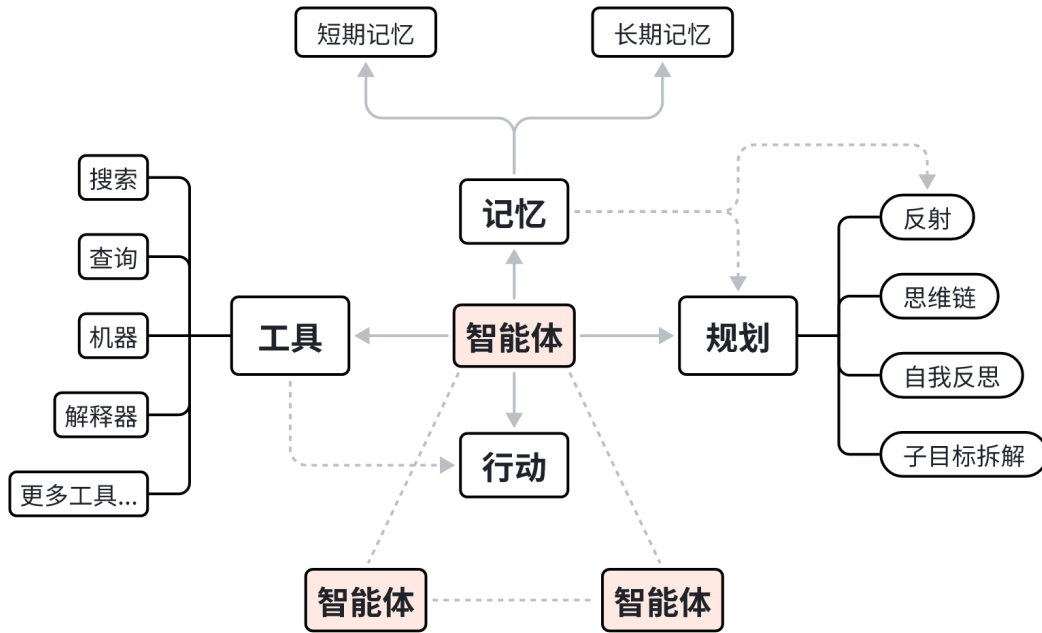


图 8-2 多智能体的多步交互与规划

从形式化的角度看，新型语言模型代理可表示为一种交互式决策流程，即在每个时间步 $t$ 中，根据当前观测到的用户输入或环境状态 $o_t$ ，语言模型代理首先生成一组候选的动作或工具调用序列 $a_t^{(1)}, a_t^{(2)}, \dots, a_t^{(n)}$ ，然后再依据外部环境反馈（External Feedback） $r_t$ 进行下一步的决策调整。通过这种方式，语言模型代理从单一的文本生成器演变为具备自主推理与决策能力的“虚拟智能体”，极大拓展了其应用空间。

农业生产场景天然具备多任务、多环节和异质数据高度分散的特征，这使得单一智能体往往难以独立高效地完成复杂农业决策。首先，农业领域的决策任务本身极为复杂且相互耦合，从播种施肥、灌溉管理到病虫害防治、市场预测，每一项任务背后都需要不同的专业知识和技术方案，若依靠单一智能体独立完成，势必会导致决策效率低下且缺乏鲁棒性。而多智能体协作机制能够将整体任务明确地划分成多个子任务，并由具备不同专业能力或知识库的专用 Agent 分别处理，从而显著提升决策精度与效率。农业场景中的数据往往来源广泛且分散，包括土壤传感器数据、遥感影像、气象预测、农机具状态和市场动态信息等，这些数据具有明显的异构性（Heterogeneity）与分布式特征（Distributed Nature）。单一智能体受限于自身计算与信息处理能力，难以在有限时间内实现高效的数据融合与分析；而通过多智能体架构，每个智能体可以分别接入特定的数据源，利用局部计算资源快速执行本地化数据处理和决策分析，并通过智能体之间的高效通信将信息有机融合，从而形成完整、实时的全局决策视图。再者，农业生产环境往往具备高度动态性（Dynamics）与不确定性（Uncertainty）。气候条件的剧烈波动、病虫害的突然爆

发或市场价格的意外变化都会直接影响农业决策的及时性与有效性。单一智能体难以快速响应复杂多变的外界环境，而通过多智能体协作，每个智能体可以基于自身专长对环境变化进行快速感知与局部响应，并通过有效的协同机制迅速协调形成全局决策。这种灵活的局部自治与全局协调相结合的特性，使多智能体系统具备更高的自适应性与容错能力。

在具体实践中，例如农业智能灌溉系统可分解为气象 Agent（土壤和天气预测）、灌溉 Agent（实时水量调度）、植保 Agent（监测病虫害状态并调整用药）和市场 Agent（监测市场行情与需求变化）等多个子智能体。这些智能体分别执行专属任务，并通过协同机制实现任务交互与决策融合。例如，当气象 Agent 预测到未来几日连续降雨时，会向灌溉 Agent 发送减少灌溉量的建议；植保 Agent 检测到害虫密度接近防治阈值时，则提前通知市场 Agent 准备相应的防治药剂供应，以保证决策过程的高效协作与资源优化。

## 8.2 LLM-Agent 框架与工具链

随着大语言模型与自主决策框架的深度融合，传统智能体（Agent）的内涵与外延正经历根本性变革。从架构演进视角看，LLM-Agent 已突破传统“感知—决策—执行”的三元组范式，形成如图 8.2 所示的多层级智能架构。

传统 Agent 架构遵循严格的线性流程：感知模块获取环境信息后，由决策模块通过预设规则生成动作，最终由执行模块作用于环境。这种架构在面对农业场景的多源数据融合与动态决策时，暴露出显著局限性——单一模块难以兼顾气象预测、病虫害诊断等跨领域知识，且缺乏对复杂任务的分层拆解能力。

LLM-Agent 通过分层设计实现“专业能力模块化”与“全局决策协同化”的统一：底层工具模块专注细分领域执行（如气象 Agent 处理数值预报），中层语言模型负责任务编排与知识整合，顶层规划器动态优化决策路径。这种设计使 LLM-Agent 在农业全链路决策中，既能应对单点技术挑战（如土壤墒情监测），又能实现跨环节协同（如将气象预测与灌溉调度联动），为多智能体协作奠定技术基础。

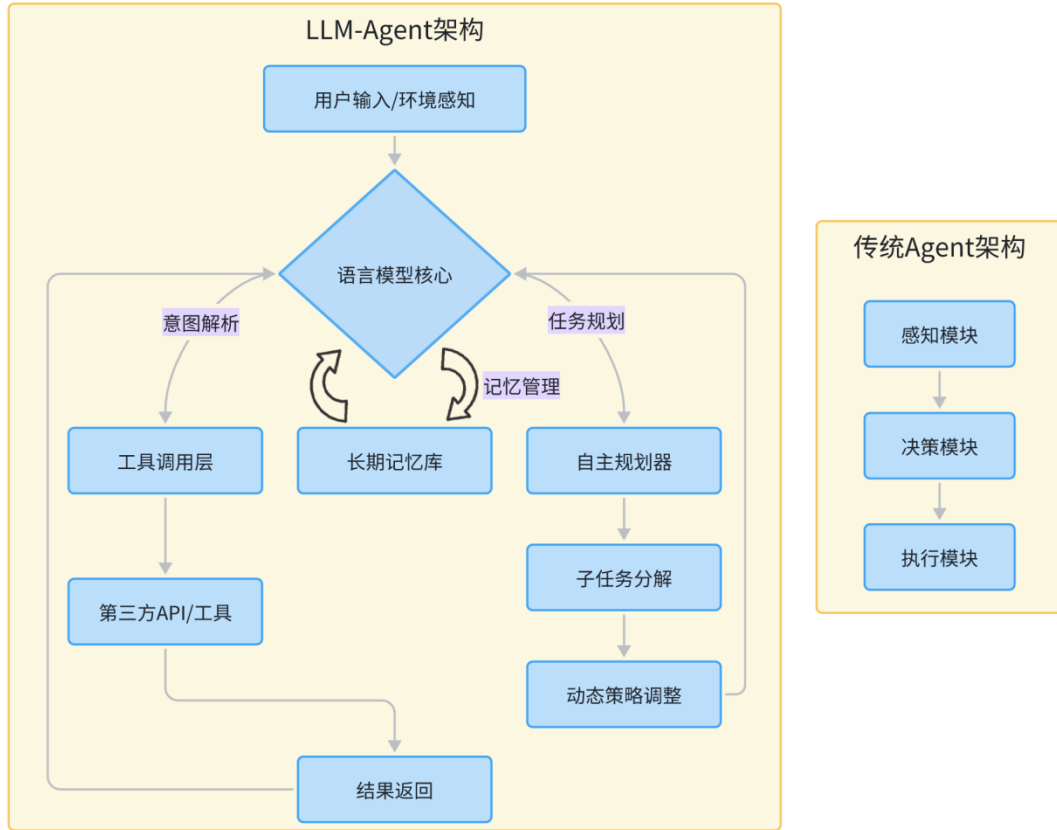


图 8-3 大语言模型中多智能体的框架与工具链

随着大语言模型在智能代理领域的快速发展，一系列专门为 LLM 设计的 Agent 框架与工具链逐步出现并得到广泛应用。其中，LangChain 作为面向 LLM 的开发框架，强调以模块化和标准化的方式连接语言模型与外部环境。LangChain 的核心组件包括 Chains（链式结构），用于定义多步任务的串联或并联调用；Agents（代理组件），允许语言模型自主决策何时调用外部工具以及选择合适的工具；Memory（记忆模块），负责跨多个交互步骤记录与管理上下文信息。这种模块化设计极大地简化了开发人员构建复杂交互式任务的过程，促进了多 Agent 场景下语言模型与环境或工具的高效融合与交互。

Auto-GPT 则进一步强化了语言模型的自主任务规划与执行能力。不同于传统的单次请求-响应模式，Auto-GPT 通过引入自主任务分解机制（Autonomous Task Decomposition），使智能代理能够根据用户定义的高级目标自动生成详细且具体的任务序列，并依次执行每个子任务。具体实现中，Auto-GPT 采用了经典的“感知—规划—行动—反馈”闭环机制：首先由语言模型感知用户的目标需求，生成初始任务计划并调用外部工具或接口进行执行；随后，模型基于外部执行结果持续监控任务进展，并对原始计划进行自适应调整或重新规划，直至整个目标成功完成。这种自主的多步规划与反馈机制，使 Auto-GPT 特别适用于动态环境下的复杂决策任务。

AgentGPT 则提供了一种更加易用且高度自动化的多智能体协作部署方案，它基于 Web 端的交互界面，使得用户无需具备编程背景即可快速配置与启动多个协作代理。不同于传统方法中需要人工定义复杂的智能体交互协议与角色划分，AgentGPT 可以自动识别用户提供的高级任务描述，并生成多个相互协作的代理，每个代理被赋予特定的角色与功能，彼此通过自然语言进行实时沟通与策略协调。此外，AgentGPT 在设计时还内置了一系列机制，包括角色动态分配、任务优先级设定以及资源调度，使其在处理复杂任务时表现出较高的灵活性与自适应能力。通过 Web 端实时交互界面，用户可以直观地观察每个智能体的决策过程、任务进展与协同效果，并可在任务执行过程中随时进行反馈或调整，极大地降低了多 Agent 系统部署的门槛。另一方面，AgentGPT 内置的对话管理（Dialogue Management）模块，负责实时监控智能体间的通信与交互状态，以确保多 Agent 系统运行的稳定性与策略协调的一致性。这种集成化、自动化的设计思路使 AgentGPT 在无需深入技术背景的条件下也能轻松实现复杂的多智能体协作任务。

除了上述几种典型的 LLM-Agent 框架，近期出现的 MetaGPT、BabyAGI 等系统也在语言模型驱动的智能代理技术中体现出独特的创新点与优势。MetaGPT 是一种面向软件开发场景的多智能体协作平台，其关键思想在于明确赋予每个 Agent 不同的软件工程角色，如产品经理、架构师、开发工程师和测试工程师等，每个 Agent 使用特定的 Prompt 模板与工具调用模式进行任务协作。通过角色驱动（Role-Driven）的任务分解与协作机制，MetaGPT 不仅能够有效地执行复杂的技术任务，还能在任务协作过程中自动产生结构化的交互记录与设计文档。具体实现时，MetaGPT 在 Prompt 设计中引入了结构化的指令模板（Structured Instruction Templates），并结合自定义的工具链，使智能体能够精准执行各自的角色任务并进行角色间的动态沟通。例如，产品经理角色的 Agent 会负责需求分析并输出用户故事（User Story），架构师角色的 Agent 则在用户故事基础上自动生成系统架构设计图并选择合适的技术方案，开发工程师和测试工程师角色的 Agent 分别负责代码实现和测试任务。这种基于角色的多 Agent 协作模式，为实现高效的软件自动化开发提供了一种全新的方法论，也进一步体现了 LLM 在复杂任务协作中强大的语义理解与任务规划能力。

以 BabyAGI 为例，采用“动态任务队列”（Dynamic Task Queue）与优先级调度机制，将高阶目标拆解为不断生成与执行的小任务，并基于执行结果自动调整任务列表及其优先级。每个任务  $t$  都有一个优先级评分函数

$$P(t) = \frac{\alpha \text{Imp}(t) + \beta \text{Urg}(t)}{1 + \log(1 + \text{Age}(t))},$$

其中， $\text{Imp}(t)$  表示任务的预估重要性（Importance）， $\text{Urg}(t)$  表示任务的紧迫度（Urgency）， $\text{Age}(t)$  为任务在队列中的存在时间， $\alpha$  和  $\beta$  为可调权重。评分高的任务会被优先从队列中取出，由 LLM-Agent 负责生成执行计划并调用相应工具；执

行完成后，结果反馈会触发新的子任务生成或对现有任务的优先级再评估，从而形成一个持续滚动的“生成—执行—评估—调度”闭环。

在这一框架下，Agent 不仅限于单一功能，而是根据需要扮演不同角色：任务生成 Agent 提出待办事项并赋予初始评分，执行 Agent 负责调用外部 API 或运行分析脚本，结果评估 Agent 则对执行效果进行量化打分并更新任务优先级，最后策略调整 Agent 综合全局队列状态对参数  $\alpha, \beta$  进行在线微调，以适配环境和用户反馈的变化。这种多 Agent 分工协作和闭环优先级调度机制，使得系统能够在复杂多变的农业场景中，动态响应突发病虫害报告、气象异常预警或市场价格波动等多源事件，始终保持高度敏捷与自适应。

在复杂农业应用中，对话管理（Dialogue Management）与角色设定（Role Assignment）是保证多 Agent 协作有序进行的关键。常见做法是引入“协调者”（Coordinator）Agent，对各子 Agent（如气象 Agent、灌溉 Agent、植保 Agent、市场 Agent）产生的建议进行统一调度，并维护全局状态；同时为每个子 Agent 明确分工边界与权限。例如，气象 Agent 专责处理多步气象预测与降雨概率计算，灌溉 Agent 则依据气象 Agent 的输出与土壤水分模型生成最优灌溉计划，植保 Agent 负责病虫害监测与防治方案，市场 Agent 则关注农产品供需与价格趋势预测。协调者 Agent 会定期收集各子 Agent 的局部行动提议  $a_{i=1}^n$ ，并通过加权汇总或多目标优化算法如混合整数规划（Mixed Integer Programming）

$$\min_x \sum_i (c_i(x_i) - u_i(x_i)) \quad \text{s.t.} \quad \sum_i x_i \leq R, x_i \geq 0$$

将各种资源或命令分配向量  $x_i$  下派至相应 Agent，其中  $c_i$  为资源成本函数， $u_i$  为产出效益函数， $R$  为资源总量约束。这种模式不仅能在全局层面协调各 Agent 的策略冲突，也能在本地使各 Agent 聚焦自身子任务，显著提高决策效率与执行一致性。对话管理层面，采用层次化状态跟踪（Hierarchical State Tracking）与事件驱动的消息总线（Event Bus）框架，各 Agent 可通过订阅-发布（Pub/Sub）方式实时接收彼此的更新，并在必要时触发多轮交互，使系统在面对突发气候变化或病虫害暴发时仍能保持高效、可靠的协同响应。

在农业场景中，多 Agent 协作往往需要将作物管理环节划分为多个专业智能体——例如气象预测代理、土壤湿度代理、灌溉代理、施肥代理、病虫监测代理与市场预测代理等。如果使用传统的多智能体强化学习范式控制，每个代理拥有独立的观测空间  $\mathcal{O}_i$  和动作空间  $\mathcal{A}_i$ ，并依据自身领域知识生成局部决策。为了实现全局优化，可采用中央评论器—去中心化执行（Centralized Critic, Decentralized Actor）框架：在训练阶段，使用联合状态和动作构建一个集中式价值函数  $Q_{\text{tot}}(s, \mathbf{a})$ ，并最小化 Bellman 残差

$$\mathcal{L}(\phi) = \mathbb{E}_{s, \mathbf{a}, r, s'} \left[ (r + \gamma \max_{\mathbf{a}'} Q_{\text{tot}}(s', \mathbf{a}'; \phi^-) - Q_{\text{tot}}(s, \mathbf{a}; \phi))^2 \right]$$

其中 $\phi^-$ 为目标网络参数；在执行阶段，每个 Agent  $i$ 根据自身观测 $o_i$ 选取动作 $a_i \sim \pi_{\theta_i}(a_i|o_i)$ ，实现去中心化决策。通过这种方式，系统既能在全局层面协调各环节资源（如水肥分配与病虫害防治优先级），又保证每个 Agent 可基于本地信息实现实时响应。在具体设计中，气象预测代理会基于数值天气预报与历史气象模型定期更新未来降雨概率与温湿度趋势，并以标准化的气候指标向其他 Agent 发布；土壤湿度代理则持续监测田间传感器数据，生成土壤含水率分布图并预测短期干旱风险；灌溉代理依据气象与土壤代理信息制定灌溉计划；施肥代理结合作物生长阶段与土壤养分模型调整 NPK 投放；病虫害监测代理运用遥感与现场图像检测病斑蔓延概率，并触发相应的农药或生物防治建议；市场预测代理同步分析市场供需与价格波动，为种植策略调整提供经济层面反馈。各 Agent 通过一个基于事件驱动的消息总线（Event Bus）实时交换关键数据，触发协作事件，并在统一时间步内基于全局状态更新策略，从而在动态农业环境中实现精准、高效且可持续的农业智能决策。

而在 LLM 驱动的多智能体架构中，核心在于让语言模型本身承担“协调者”与“规划者”的角色，而非依赖传统的强化学习策略。以 LangChain 的 Agent 框架为例，其通过定义一组可调用工具（Tool）和对应的“Tool-Handler”接口，将每一步决策映射为对外部能力的调用请求。具体流程为：语言模型首先解析用户意图与对话上下文，生成一段用于选择工具的查询指令；接着，通过内置的“Executor”模块将模型输出的工具调用格式（如“`\"tool\": \"WeatherAPI\", \"args\": \"location\": \"Field A\"`”）转发到相应的服务；最后，将工具返回的数据重注入到模型输入中，驱动下一轮推理或文本生成。整个过程中，模型依托 Prompt 模板和动态记忆（Memory）不断调整自身对各 Agent（工具）调用的优先级与次数，无需显式的策略网络或价值函数。这样，LLM 作为“神经级调度中心”，通过链式调用（Chain of Thought Prompting）实现了多智能体的灵活编排与实时协作，更贴合“工具即 Agent”的设计思路。

在 LLM 驱动的多智能体系统中，每个 Agent 更像是一个具备特定工具集（Toolset）的“语言微服务”，而整个协作过程则通过 Prompt Chain 与 Memory State 实现编排。以 LangChain AgentExecutor 为例，每个 Agent 被定义为：

- 一组可调用的工具接口（Tools），如天气查询、传感器读数、数据库检索、图像分析等；
- 一个 Prompt 模板（Prompt Template），负责将当前上下文与工具调用意图编码为模型输入；
- 一个 Memory Buffer，用于在多轮交互中保存自身历史调用结果与对话状态。

当协作流程开始时，Coordinator Agent 首先将用户需求按任务类型映射为高层意图（e.g. “灌溉调度”或“病虫害诊断”），并分别触发对应子 Agent 的 Chain of Thought Prompting。各子 Agent 接收到由 Coordinator 构造的 Prompt 后，依据 Toolset 动态生成“函数调用”格式的输出（JSON or function call），Executor 模块将其路由到外

部服务，返回结果后 Memory Buffer 更新上下文，并可能触发下一 Agent 的 Chain。整个过程无需显式的策略网络或强化学习算法，而是依赖于 Prompt 设计和工具接口契合度来保障多 Agent 间的协同与信息流通。

在实际系统中，需要让语言模型在给定当前对话上下文与任务需求后，动态选择最合适的“工具代理”（Tool Agent）来执行对应操作。为此，可在 Prompt 中加入“工具调用头”机制，让模型输出一系列候选调用及其优先级评分，再通过概率化策略确定最终调用。具体而言，令模型在生成阶段输出一组工具打分向量  $\mathbf{z} = [z_1, z_2, \dots, z_K]$ ，其中每个分量  $z_k$  表示模型对工具  $k$ （如“土壤湿度接口”“病虫害数据库检索”“气象预报服务”）的调用倾向度；再通过软最大化函数（softmax）将其转换为调用概率：

$$P(\text{tool}_k|\text{content}) = \frac{\exp(z_k)}{\sum_{j=1}^K \exp(z_j)}$$

系统按照阈值或前  $n$  策略选取概率最高的工具，并调用相应 API；调用结果回填模型输入，更新内存状态，并触发下一轮推理或工具调用。这一概率化工具选择机制，使得 Agent 能够在面对多种可用工具时，实现连续、可微且可调的“工具编排”，而非简单的规则匹配或固定链式调用。在农业场景中，例如需要同时处理土壤监测、灌溉调度和病虫害诊断时，上述机制可让同一次用户对话按需调用不同工具代理：首先，模型识别“浇水”意图并高概率选择“土壤湿度接口”与“气象预报服务”；得到水分数据后，再依据“病虫害监测”槽位动态降低或提升“病虫害数据库检索”工具的调用概率，如此多 Agent 在同一次对话中无缝协作，完成从数据获取到决策建议的闭环流程，而无需预定义固定的调用顺序。

### 8.3 协同与通信机制

在多 Agent LLM 系统中，Agent 之间的协同首先依赖于一种轻量级而严谨的对话协议，该协议将每条交互消息封装为结构化的“动作—意图—数据”三元组，形式化为

$$m_{i \rightarrow j} = (\text{action}, \text{intent}, \mathbf{d}),$$

其中 action 表示调用外部工具或请求信息的类型，intent 为高层任务意图标签， $\mathbf{d}$  是载荷数据（如查询参数、状态摘要或嵌入向量）。消息在 Agent 之间通过发布—订阅（Pub/Sub）总线传递，各 Agent 可对特定主题（Topic）进行订阅，实现高效的点对点或广播通信。为保证知识共享的连贯性，系统还设计了共享“知识白板”（Shared Knowledge Board），由所有 Agent 共同维护局部知识图谱的更新日志，每次当 Agent 提取到新的事实或决策规则（如作物需水阈值、病虫害防治策略）时，都将对应的节点 / 边信息以嵌入形式  $\mathbf{k}$  写入白板，并通过增量同步机制传播至订阅该主题的其他 Agent。

在资源分配与冲突化解场景下，Agent 将各自对资源使用的需求表示为一个优先级向量  $\mathbf{p}_i$ ，并在协调者 Agent 上发起“资源拍卖”对话：各 Agent 按照规范化协议提交自己的需求向量，协调者则通过求解如下凸优化问题

$$\max_{\mathbf{x}_i} \sum_i U_i(\mathbf{x}_i) \quad \text{s.t.} \sum \mathbf{x}_i \leq \mathbf{R}, \mathbf{x}_i \geq \mathbf{0}$$

在保证总体资源不超限的前提下分配最优解  $\mathbf{x}_i^*$ 。如果出现冲突（如两个 Agent 同时争夺有限资源），系统会启动“谈判子流程”，各 Agent 可基于博弈论中的交替提议模型（Alternating Offers Model）进行多轮让步与报价，直至达成共识。

各 Agent 之间的知识共享依赖于一个分布式的本体驱动架构，每个 Agent 持有自身领域的本体片段（Ontology Fragment）和本地知识库（Local KB），并通过“对等同步”（Peer-to-Peer Synchronization）或“星型汇聚”（Star Topology Aggregation）模式，定期将新增事实以 RDF 三元组的形式发布到全局知识图谱（Global Knowledge Graph）。这一过程采用基于版本向量（Version Vector）的冲突检测机制：每次更新皆附带向量标签  $\mathbf{v} = [v_1, v_2, \dots, v_N]$ ，其中  $v_i$  表示第  $i$  个 Agent 的更新计数，通过比较向量可判定因果关系或并发修改，并在发生冲突时自动触发“最近胜出”或“自定义合并策略”。基于 SPARQL 的联邦查询（Federated Query）能力，任一 Agent 都可以对整个知识图谱执行复杂的路径查询与推理，从而即时获得其他 Agent 的最新观测和决策要素，对本地决策提供全局语境支持。

在资源分配与冲突化解场景中，Agent 之间采用多种博弈与谈判机制以达成最优或公平的方案。合同网协议（Contract Net Protocol）是其中常用的一种：首先由发包 Agent（Manager）发布任务公告（Call for Proposals），写明任务需求、资源预算  $B$  与评价准则；各投标 Agent（Contractor）基于自身资源能力  $\mathbf{r}_i$  和成本函数  $c_i(\mathbf{r}_i)$  递交报价；Manager 对所有提案执行综合评估函数

$$U(\mathbf{r}_i) = v_i - c_i(\mathbf{r}_i)$$

其中  $v_i$  为任务所带来的预估价值，选择能使  $U(\mathbf{r}_i)$  最大的若干投标，并分配相应资源。若报价冲突或资源紧张，还可引入“多轮竞标”（Multi-Round Bidding），让投标 Agent 根据上轮结果调整报价，直至满足全局约束。

当多 Agent 在同一资源池中发生利益冲突时，还可利用“多约束拍卖”（Combinatorial Auction）机制：将资源看作离散项目  $R = r_1, \dots, r_m$ ，Agent  $i$  提交组合报价  $b_i(S_i)$ ，其中  $S_i \subseteq R$ ，系统通过解一个整数线性规划

$$\max \sum_i b_i(S_i)x_i \quad \text{s.t.} \sum_{i:j \in S_i} x_i \leq 1, x_i \in \{0,1\}$$

来确定中标组合，兼顾任务完成与资源互斥约束。此时，Agent 只需在对话中提供需求描述与偏好排序，系统背后的拍卖引擎便可完成复杂的资源分配与冲突化解，输出最终结果并以自然语言形式反馈给各方。

在分布式知识共享与命令传递中，消息聚合与路由效率至关重要。为了让每个 Agent 在高并发环境下既能快速接收必要信息，又能避免冗余通信，系统采用基于注意力的异构消息聚合（Heterogeneous Attention-based Message Aggregation）机制。每个 Agent  $i$  持有的本地状态表示为向量  $\mathbf{h}_i^t$ ，在时刻  $t$  会接收来自邻居 Agent  $\mathcal{N}(i)$  的消息  $\{\mathbf{m}_{j \rightarrow i}^t\}$ 。节点更新过程可表示为：

$$\mathbf{h}_i^{t+1} = \phi(\mathbf{h}_i^t, \sum_{j \in \mathcal{N}(i)} \alpha_{ij}^t W_m \mathbf{m}_{j \rightarrow i}^t),$$

其中  $\phi$  是可学习的融合函数（如带残差的前馈网络）， $W_m$  为消息投影矩阵，注意力权重  $\alpha_{ij}^t$  通过以下自注意力计算得到：

$$\alpha_{ij}^t = \frac{\exp(\langle W_q \mathbf{h}_i^t, W_k \mathbf{m}_{j \rightarrow i}^t \rangle)}{\sum_{k \in \mathcal{N}(i)} \exp(\langle W_q \mathbf{h}_i^t, W_k \mathbf{m}_{k \rightarrow i}^t \rangle)},$$

其中  $W_q$ ， $W_k$  分别为查询与键映射矩阵， $\langle \cdot, \cdot \rangle$  表示内积操作。该机制允许 Agent 根据自身状态动态聚焦于最相关的通信来源，并通过高维嵌入级联的方式融合多种信息，而非简单地将所有消息等比加权。结合稀疏化技术与阈值截断

（Thresholding），系统仅保留前  $k$  个最重要的邻居消息，显著降低通信开销并提升整体响应速度。这种注意力驱动的消息聚合框架，使得多 Agent 系统在大规模农业网络中既能保持高效协同，又能兼顾通信资源的有限性。

在实际部署中，LLM-Agent 系统往往需要在保持低延迟的同时，实现分布式知识与状态的高效同步。为此，可采用“向量化知识共享”机制，将每个 Agent 在交互过程中产生的新知识或决策要素映射为高维语义向量，并存储于一个分布式近邻检索索引（如 HNSW、Faiss 集群）。具体流程是：当 Agent  $i$  在执行过程中产生一条重要信息（如新的病虫害防治策略或土壤水分阈值）时，将该信息编码为向量  $\mathbf{v}_i \in \mathbb{R}^d$ ，并连同元数据  $\mathbf{m}_i$  写入索引；其他 Agent 在需要相关知识时，以查询向量  $\mathbf{q}$ （通常来源于当前上下文嵌入）调用近邻检索，得到最相似的向量集合  $\{\mathbf{v}_k\}$ 。这一过程形式化为：

$$N(\mathbf{q}) = \operatorname{argmax}_{\mathbf{v} \in \mathcal{V}} \operatorname{sim}(\mathbf{q}, \mathbf{v}),$$

其中  $\mathcal{V}$  为全局向量库， $\operatorname{sim}$  为余弦相似度或点积。检索结果再回注入本地上下文，驱动下一轮推理。通过这种“编码—索引—检索—解码”闭环，Agent 能在无需完整加载全局知识图谱的情况下，实时获取最相关的协作信息，并将本地创新快速扩散到其他 Agent。该方案不仅显著降低了跨节点通信带宽，还通过异步索引更新和分布式缓存，实现了对大规模农业场景中海量知识的高效共享与扩展。

## 8.4 多 Agent 在农业智能决策的典型案列

### 8.4.1 农事管理场景

在农事管理场景中，基于 LLM 的多 Agent 协作能够将“种植—监测—预警”闭环智能化拆解为若干专业 Agent。种植 Agent 负责作物生长模型的规划与播种密度计算，其核心功能是将用户输入的作物类型、土壤肥力等级与目标产量映射为高维种植策略向量；气象 Agent 则持续调用天气预报 API，生成包括降水、温度、风速等在内的时序气象特征；病害 Agent 利用遥感图像分析与病虫害知识库检索，对作物叶片病斑、虫洞分布进行实况诊断并预测扩散风险。三个 Agent 通过结构化消息协议交换：种植 Agent 将当前生长阶段和历史产量预测发布到“作物状态”主题；气象 Agent 提供短中期气象曲线和极端天气预警；病害 Agent 在检测到预警阈值时向“风险管理”主题推送防治建议。随后，Coordinator Agent 读取上述主题信息，用内置规则或轻量级优化模块计算最佳执行方案，比如调整播种行距、提前滴灌或局部喷药，并通过自然语言接口下达给农机调度系统，从而实现了从规划到执行的全流程协同。

- **种植 Agent:** 基于作物生长模型（如 WOFOST 或 DSSAT），将用户提供的作物品种、土壤肥力等级和目标产量等参数，计算出最优的播种密度、行距与播期，并将生成的高维种植策略向量发布到“作物状态”主题，供后续各 Agent 调用。
- **气象 Agent:** 持续调用天气预报 API，汇总并处理降水量、温度、风速等多源时序气象数据，生成短中期气象曲线与极端天气预警，发布到“气象监测”主题，为灌溉和施肥决策提供精细化环境输入。
- **病害 Agent:** 利用无人机或卫星遥感影像分析结合病虫害知识库检索，自动诊断叶片病斑与虫洞分布并评估扩散风险，一旦检测到超阈值情况即向“风险管理”主题推送防治建议。
- **协调 Agent:** 作为全局调度中枢，订阅“作物状态”“气象监测”“风险管理”三大主题，基于内置规则或轻量级优化模块（例如基于成本—收益评估的决策函数），综合计算出调整播种行距、提前滴灌或局部喷药等执行方案，并通过自然语言接口向农机调度系统下达可执行指令。

通过对多 Agent 协作理论框架与工具链的深入探讨，我们已建立起对 LLM-Agent 系统在农业场景中应用的技术认知。为更具体地展现这一协作机制如何在实际农事管理中落地生根，现以种植-监测-预警闭环为典型场景，通过结构化伪代码与协作流程图解构多智能体协同决策的全过程。如表 8.1 所示，种植 Agent、气象 Agent、病害 Agent 与协调 Agent 各司其职又紧密联动，共同构成覆盖农田全生命周期的智能决策网络。这种模块化分工与主题式通信的设计，正是多 Agent 系统解决农业‘多维、多源、多时序’挑战的核心实践路径。

表 8.1 农田全生命周期的智能决策网络

智能体	核心功能	输入参数	处理逻辑	输出/发布主题
种植 Agent	作物生长模型规划	crop_type (作物类型) soil_fertility (土壤肥力) target_yield (目标产量)	IF 水稻且高肥力 THEN 密度=30 株/m <sup>2</sup> , 行距=0.3m ELSE 密度=25 株/m <sup>2</sup> , 行=0.25m ENDIF	发布到作物状态主题： {种植策略向量}
气象 Agent	气象数据预测与预警	location (地块位置)	1. 调用天气API获取降水/温度/风速 2. IF 周降水总<100mm THEN 预警="干旱风险" ENDIF	发布到气象监测主题： {气象曲线, 极端预警}
病害 Agent	病虫害识别与风险评估	image_path (遥感影像路径)	1. 图像分析检测病斑/虫洞 2. IF 检测到稻瘟病 THEN 风险等级="中等" ELSE 风险等级="低" ENDIF	发布到风险管理主题： {病害类型, 风险等级}
协调 Agent	全局决策生成与指令下发	订阅三大主题数据	决策规则： 1. IF 气象主题.周降水<100mm THEN 灌溉方案="增加水量" 2. IF 风险主题.等级=="中等" THEN 植保方案="正常喷药" ENDIF	下发农机指令： {调整行距, 灌溉方案, 植保方案}

## 8.4.2 供应链与市场决策

在供应链与市场决策环节，价格预测 Agent 首先通过对历史价格序列与宏观经济指标的多模态分析，利用内置的时间序列预测模型（例如结合 Transformer 结构的 Temporal Fusion Transformer）生成未来各地块农产品价格走向  $\hat{P}_{t+1:t+H}$ ；同时，物流调度 Agent 在接收到价格预测后，将仓储成本、运输网络拓扑与车辆调度约束整合入以下混合整数线性规划模型

$$\min_{x_{ij}} \sum_{i,j} (c_{ij}x_{ij} + h_j I_j) \quad \text{s.t.} \quad \sum_j x_{ij} = S_i, \sum_j x_{ij} \leq C_j, x_{ij} \in \mathbb{Z}^+,$$

其中  $c_{ij}$  为从产地  $i$  到市场  $j$  的单元运输成本， $S_i$  是产地  $i$  的可供货量， $C_j$  为市场仓储容量， $h_j$  为单位库存持有成本， $I_j$  为市场剩余库存量。该模型的最优解  $x_{ij}^*$  决定了物流 Agent 应分配的车辆与路线。政策解析 Agent 则持续调用政府政策数据库，通过检索增强生成（RAG）技术实时抽取与价格补贴、关税调整及区域流通限制相关的法规文本，与上游预测和调度信息结合，在对话接口中以“根据最新出口补贴政策，到港价可提升 5%，建议优先将 30% 货量分配给区域 A，并调整合同条款”的形式向决策者报告。通过三类 Agent 在同一对话流中的无缝协作，实现从价格洞察到物流执行再到政策解读的端到端供应链优化。

- **价格预测 Agent:** 通过对历史价格序列、区域供需和宏观经济指标进行多模态分析，利用诸如 Temporal Fusion Transformer 的时间序列模型，输出未来各地块农产品的价格走向  $\hat{P}_{t+1:t+H}$ ，为后续调度和采购决策提供量化的价格预期。
- **物流调度 Agent:** 收到价格预测后，整合仓储成本、运输网络拓扑与车辆调度约束，构建并求解混合整数线性规划模型，输出最优的货物分配矩阵  $x_{ij}^*$ ，明确各路线和车辆的调度方案，确保产地到市场的运输资源在成本与时效间达到最优平衡。
- **政策解析 Agent:** 持续调用并检索政府政策数据库，利用检索增强生成（RAG）技术提取最新的价格补贴、关税或流通限制法规文本，将这些政策要点与价格预测和物流调度结果结合，以自然语言形式（例如“根据最新出口补贴，可将 30% 货量优先分配至区域 A”）实时向决策者汇报，确保供应链方案符合政策合规要求。

在展示田间管理的多智能体协作实践后，我们进一步将视角延伸至农业产业链的中后端。供应链与市场决策环节同样面临着价格波动、物流约束和政策变化等多重复杂因素的交织影响。如表 8.2 所示，这种融合时序预测、运筹优化与政策语义解析的智能体协作范式，不仅实现了供应链端到端的成本控制，更在市场风险应对中展现出动态适应性。

## 8.2 农产品供应链中的多智能体设置

智能体	核心功能	输入参数	处理逻辑	输出/决策
价格预测 Agent	农产品价格时	historical_prices (历史价格) market_demand (市场需求)	1. 加载 Temporal Fusion Transformer 模型 2. 多模态特征融合：价格+需求+宏	发布价格预测： {预测曲线, 波动风险}

	序 预 测	macro_index ( 宏观 指标 )	观指标 3. 输出未来 H 步价格序列 $\widehat{P}_{t+1:t+H}$	
物流调度 Agent	运 输 路 径 优 化	warehouse_capacity ( 仓储容量 ) transport_cost ( 运输成本 ) supply_volume ( 供 应量 )	<b>求解 MILP 模型 :</b> $\min \sum_{i,j} (c_{ij}x_{ij} + h_{jL_j})$ 约束 : $\sum_j x_{ij} = S_i$ $\sum_j x_{ij} \leq C_j$	发布物流方 案 : { 路线分配, 车 辆调度 }
政策解析 Agent	政 策 文 本 语 义 抽 取	policy_keywords ( 政策关键词 )	1. RAG 检索政府数据库 2. 提取补贴/关税/限制条款 3. <b>IF</b> 检测到出口补贴 <b>THEN</b> 生成优先分配区域建议	发布政策摘 要 : { 补贴幅度, 区 域限制 }
协 调 Agent	多 目 标 优 化 决 策	订阅三大主题数据	<b>决策规则 :</b> 1. 价格预测 → 制定销售定价策略 2. 物流方案 → 优化运输成本 3. 政策摘要 → 调整区域分配权重	生成供应链 指令 : { 定价策略, 物 流调整, 政策响 应 }

### 8.4.3 跨行业融合

在未来的跨行业融合与超大型多 Agent 平台构想中, 各类专业 Agent 将通过统一的事件驱动总线 (Event-Driven Bus) 和开放标准语义协议 (Semantic Interoperability Protocol, SIP) 实现无缝对接与动态扩展。平台核心由一个全局 Agent 目录 (Global Agent Registry) 和语义中间件 (Semantic Middleware) 构成, 前者维护 Agent 元数据 (功能、依赖、版本), 后者负责将不同领域 (如农业、金融、气象、物流、安全监管) Agent 的本体 (Ontology) 进行自动对齐与映射, 以便实时实现跨域知识共享。整个架构在逻辑层面可抽象为一个图数据库  $\mathcal{P} = (V, E)$ , 其中节点  $V$  代表不同领域的 Agent 集合, 边  $E$  则由 SIP 定义的“能力调用”或“数据依赖”语义关系构成; 当某一农业 Agent 需要外部信用或保险产品支持时, 它可通过查询子图  $v_i, v_j \subset V$  并触发相应 Agent 间的跨域调用, 从而快速获得金融风险模型输出并将其纳入农事决策。

在平台性能和可靠性层面, 可定义服务质量指标 QoS 为 Agent 响应时间、可用率与互操作成功率的加权组合

$$QoS = w_r \overline{RT}^{-1} + w_a AR + w_i IR,$$

其中  $\overline{RT}$  为平均响应时间， $AR$  为可用率（Availability Ratio）， $IR$  为互操作成功率（Interoperability Ratio）， $w_r + w_a + w_i = 1$ 。通过对这一指标的持续监控与自动扩容策略（Auto-Scaling Policies）结合，平台能够在 Agent 数量和调用频次激增的情境下，保持稳定高效的跨域协同。此外，基于智能合约（Smart Contract）和区块链账本的不可篡改特性，可为关键农业交易、补贴申领和溯源数据等场景提供去中心化安全保障。这种超大型多 Agent LLM 平台将打破行业边界，依托开放生态与可扩展架构，实现农业与金融、供应链、环境监测、政策监管等多个领域的深度协同，为未来智慧农业生态系统提供一个可持续、高度可靠且具备自主进化能力的基础设施。

- **全局注册 Agent:** 维护所有 Agent 的元数据，包括功能描述、依赖关系和版本信息；在新 Agent 上线或现有 Agent 更新时负责登记、校验并通知其他 Agent 获取最新能力。
- **语义中间件 Agent:** 对接并自动对齐不同领域的本体（Ontology），在跨域调用时将农业、金融、物流等领域的语义数据映射到统一表示，确保多行业 Agent 间的知识共享无歧义。
- **跨域服务 Agent:** 在农业 Agent 需要外部信用、保险或金融风险评估支持时，从全局知识图谱中检索合适的金融或保险模型，调用其 API 并将结构化结果反馈给农事决策 Agent，用于补充风险管理与资金安排。
- **QoS 监控 Agent:** 持续采集各 Agent 的响应时延、可用率和互操作成功率，计算综合服务质量（QoS）指标，并在指标下降或调用激增时触发自动扩容、限流或容错切换策略，以保障平台的稳定与高效。
- **智能合约 Agent:** 将关键农业交易、补贴申请和溯源数据转换为区块链上的智能合约，生成不可篡改的交易凭证并自动执行合约条款，为跨域协作提供安全可审计的保障。

当农业智能决策从田间管理延伸至供应链优化，其价值边界已突破传统农业范畴。在数字化生态深度融合的今天，农业系统与金融、环境、监管等领域的协同成为智慧农业进化的关键方向。本节展示的多 Agent 跨行业融合架构，正是通过全局注册、语义对齐和智能合约三大核心机制，构建起“农业+”的开放生态系统。如表 8.3 所示，语义中间件 Agent 破解领域本体差异，QoS 监控 Agent 保障系统鲁棒性，智能合约 Agent 实现可信交易——这种多维协同范式不仅为农业注入跨域智慧，更重塑了产业边界融合的技术路径。

表 8.3 农业+的开放生态系统

智能体	核心功能	输入参数	处理逻辑	输出/服务
全局注册	跨域 Agent 元	agent_id (智能体 ID)	1. 维护全局目录 $\mathcal{D}$ 2. IF 新 Agent 注册 THEN	提供 Agent 发现服务：

<b>Agent</b>	数据管理	<code>agent_metadata</code> (元数据)	$\mathcal{D} \leftarrow \mathcal{D} \cup \{(id, meta)\}$ 3. 支持语义查询	{匹配 Agent 列表}
<b>语义中间件 Agent</b>	多领域本体对齐	<code>ontology_A</code> (农业本体) <code>ontology_F</code> (金融本体)	1. 计算概念相似度 $\text{sim}(c_i^A, c_j^F)$ 2. <b>IF</b> $\text{sim} > \tau$ <b>THEN</b> 建立映射 $c_i^A \rightarrow c_j^F$ 3. 生成跨域本体图 $\mathcal{G}_{\{AF\}}$	发布本体映射： {跨域语义转换规则}
<b>跨域服务 Agent</b>	需求-能力匹配	<code>query</code> (农业需求) <code>domain</code> (目标领域)	1. 向量化需求 $\mathbf{q} = \text{Encoder}(\text{query})$ 2. 检索 $\mathbf{v}^* = \arg\max_{\mathbf{v} \in \mathcal{V}} \text{sim}(\mathbf{q}, \mathbf{v})$ 3. 触发目标领域 API 调用	返回跨域服务结果： {金融风控评估}
<b>QoS 监控 Agent</b>	系统性能保障	<code>response_time</code> (响应时间) <code>availability</code> (可用率) <code>interop_rate</code> (互操作率)	计算综合指标： $\text{QoS} = w_r \cdot \text{RT}^{-1} + w_a \cdot \text{AR} + w_i \cdot \text{IR}$ <b>IF</b> $\text{QoS} < \theta$ <b>THEN</b> 触发自动扩容	发布系统健康报告： {QoS 指标, 扩容建议}
<b>智能合约 Agent</b>	链上可信执行	<code>contract_terms</code> (合约条款) <code>trigger_conditions</code> (触发条件)	1. 部署合约至区块链 2. <b>WHEN</b> 环境监测数据达标 <b>DO</b> 自动发放补贴 3. 生成不可篡改凭证 $\text{Hash}(tx)$	执行合约： {交易凭证, 执行日志}

整个多 Agent 架构在农业智能决策中实现了从田间作业到供应链管理再到跨行业协作的全流程覆盖。各专业 Agent 根据自身领域知识在同一对话流中无缝交换信息并完成任务分解，种植 Agent、气象 Agent 和病害 Agent 在地块管理环节紧密配合以优化播种、灌溉和防治方案；价格预测 Agent、物流调度 Agent 与政策解析 Agent 则在供应链层面动态响应市场与政策变化，实现从产地到市场的高效协同；面向未来的超大型平台通过开放语义协议将农业 Agent 与其他行业 Agent 融为一体，使得农业生态系统能在金融、环境监测和监管等领域获得实时支持。这一系列案例展示了 LLM-Agent 在提升决策精度、缩短响应时延和增强系统弹性方面的显著优势，也为下一代智慧农业系统的构建提供了可操作的技术路径。

尽管这些实践已初步证明多 Agent 协同的可行性，仍有一些关键问题亟待深入研究。Agent 之间共享的语义标准需要进一步完善以避免数据歧义和工具调用失

败；系统对话协议虽能支持高并发交互却缺少统一的可验证安全策略；跨 Agent 的决策透明度和可解释性仍然不足，难以满足监管和审计的需求；在实际部署中，Agent 的生命周期管理与版本演进会带来新一轮兼容性挑战。未来工作可聚焦于构建基于形式化验证的 Agent 契约框架、开发自适应语义对齐算法、以及研究 Agent 自治与人为监督的平衡机制，以确保多 Agent LLM 系统在规模化应用中既保持灵活性，又具备高可靠性与可维护性。

## 第 7 章参考文献

- [1] Yoav Shoham and Kevin Leyton-Brown. *Multiagent systems: Algorithmic, gametheoretic, and logical foundations*. Cambridge University Press, 2008.
- [2] John Nash. Equilibrium Points in N-Person Games. *Proceedings of the National Academy of Sciences of the United States of America*. 1950. doi: 10.1073/pnas.36.1.48.
- [3] Patrick Lewis et al. “Retrieval-augmented generation for knowledge-intensive nlp tasks”. In: *Advances in neural information processing systems 33* (2020), pp. 9459–9474. CHAPTER
- [4] Harrison Chase. LangChain. Oct. 2022. url: <https://github.com/langchainai/langchain>.
- [5] Significant Gravitas. AutoGPT. url: <https://github.com/Significant-Gravitas/AutoGPT>.
- [6] Sirui Hong et al. “MetaGPT: Meta Programming for A Multi-Agent Collaborative Framework”. In: *The Twelfth International Conference on Learning Representations*. 2024. url: <https://openreview.net/forum?id=VtmBAGCN7o>.
- [7] Peter Stone and Manuela Veloso. “Multiagent systems: A survey from a machine learning perspective”. In: *Autonomous Robots 8* (2000), pp. 345–383.
- [8] Jason Wei et al. “Chain-of-thought prompting elicits reasoning in large language models”. In: *Advances in neural information processing systems 35* (2022), pp. 24824–24837.
- [10] Lijun Sun et al. “Multi-agent coordination across diverse applications: A survey”. In: *arXiv preprint arXiv:2502.14743* (2025).
- [11] Yury Malkov and Dmitry Yashunin. “Efficient and Robust Approximate Nearest Neighbor Search using Hierarchical Navigable Small World Graphs”. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol. 42. 4. 2020, pp. 824–836.

- [12] Eric Prud'hommeaux and Andy Seaborne. SPARQL Query Language for RDF. W3C Recommendation, 15 January 2008. W3C. 2008.
- [13] Peter Cramton, Yoav Shoham, and Richard Steinberg, eds. Combinatorial Auctions. MIT Press, 2006.
- [14] Hervé Jégou et al. "Faiss: Similarity search and clustering of dense vectors library". In: *Astrophysics Source Code Library* (2022), ascl-2210.
- [15] H.L. Boogaard et al. "WOFOST Control Centre 2.1: User's Guide for the WOFOST Control Centre 2.1 and the Crop Growth Simulation Model WOFOST 7.1.7". In: (2014).
- [16] James W Jones et al. "The DSSAT cropping system model". In: *European journal of agronomy* 18.3-4 (2003), pp. 235–265.

## 9. 农业智能化平台与大模型集成

农业智能化平台已从简单的信息展示进化为承载智慧决策的核心中枢。遥感影像、土壤传感、作物生长模型、市场动态等多源数据交织在一起，形成一张面向生产全流程的数字网络。传统平台多以静态查询和基本监测为主，往往难以实时处理海量异构数据，也无法针对复杂场景给出个性化、可操作的建议。此时，大模型的出现赋予平台“感知—推理—生成”三重能力，将原本分裂的信息体系整合为一体。

在农田一角，无人机高空拍摄的作物长势图像正被实时传输到云端，几分钟后，平台自动生成长势分析报告；在粮仓里，传感器不断回传粮温与湿度数据，系统利用气候预测模型与存储最佳实践知识为管理者提出具体的通风与通风时机建议；在市场交易大厅，大模型结合历史价格曲线、宏观经济指标和政策公告，智能推演出未来几周的供需趋势，并向种植户发布合理的销售时机和渠道建议。上述场景中，如果没有一个能够同时理解图像、时序与文本的智能中枢，农事管理和市场决策往往只能依赖人工经验或各自为政的单一系统。大模型在平台中的集成，正好填补了这一空缺。

平台不再仅仅是数据的收集者，而成为一个面向农业生产、管理与销售的智能引擎。它通过自然语言交互接口，使农户和技术人员可以像与专家对话一般提出问题，并即时获得专业、个性化的解决方案。系统内部的大型预训练模型不仅能够梳理海量科研文献和政策文件，还能与作物生长模型、土壤养分预测模块等专业工具协同运作，实现从“文本检索—图像诊断—时序预测—方案生成”这一完整链路的自动化。这样一来，无论是面对土壤养分失衡的田块，还是出现初期病害的作物，抑或是产销对接所需的精准价格预测，平台都能快速给出符合当地实际、可落地执行的建议，大幅提升决策的科学性与时效性。

更重要的是，集成大模型使平台具备“自我进化”的能力。通过对用户反馈和生产数据的持续学习，系统能够不断优化模型表现：每一次作物诊断后的防治成效、每一次灌溉或施肥方案的执行结果、每一次市场价格预测的准确与否，都成为平台迭代更新的关键环节。知识库由此得以扩充，模型的推理路径也更加符合当地环境与作业习惯。用户与平台的交互越频繁、场景越多样化，平台的智能化程度就会越高，建议内容也会越贴合实际需求，从而真正实现“人人皆可享受数字化农业专家服务”的理想。

在治理与发展策略层面，集成大模型的农业智能化平台为决策部门提供了全新的视角。政策制定者可以基于平台汇总的多源数据和模型预测结果，评估补贴政策的执行效果、监测市场风险和粮食安全态势；科研机构能够借助平台生成的知识图谱与研究报告，快速开展新品种筛选与实验设计；农业企业则可以依托平台提供的智能供应链分析，实现生产、仓储、物流的全链条优化。大模型不再局限于回答个体用户的问题，而是成为各类主体进行协同治理和联合创新的基础设施。

本章将围绕“大模型驱动的核心服务”“多模态信息检索与知识挖掘”“个性化农业建议”“与专业工具及 IoT 系统的无缝集成”“数据闭环驱动的自我进化”“推广与信

任建设”几个层面展开，深入揭示大模型如何改变平台的服务架构和价值输出，以及在构建技术生态与培育用户社区方面所需的理念与方法。章节布局既覆盖平台能力的构建，也关注用户采纳的路径，力图为农业数字化转型提供可操作的技术框架与实践指南。通过本章的学习，读者将对农业智能化平台与大语言模型深度集成的全貌有清晰认识，并掌握以大模型为核心驱动，构建智慧农业服务系统的关键思路与工程方法。

## 9.1 以大模型为驱动的农业智能化平台核心服务

当前，许多知名的农业在线平台，通过整合农业问答、农情热点测报、农产品收售等信息，已经得到了广泛应用。但这种基于人进行交互的平台也具有一定的局限性，尤其是在及时回复用户问题的及时性、跨领域问题回复等问题上具有一定的局限。而大模型的出现，标志着生成式人工智能迈向重要一步，凭借其卓越的自然语言处理和知识整合能力，能够将平台从传统的信息展示和简单交互，提升到具备深度理解、智能分析和个性化响应的新高度。以大模型为驱动的核心服务将成为农业智能化平台的标配，深刻改变农业知识的获取与应用方式。

大模型的集成应用正在深刻变革农业智能化平台的核心服务，尤其在信息获取的智能化、数据解读的多维化以及用户交互的自然化方面，展现出巨大的潜力。这些模型不仅提升了平台处理和理解农业数据的能力，还催生了更具个性化和情境感知能力的服务模式。

平台名称	主要功能/重点	关键 AI 组件/技术	目标用户	主要数据来源
AWS 农业文档数字化方案	智能文档数字化，将手写/扫描文档转为可搜索格式，集成至下游系统	MLLM (如 Claude 3), Amazon Bedrock	农业企业	手写笔记、扫描文档、图像
MA3 (多模态农业智能体架构)	甘蔗病害分析 (分类、检测、VQA)	MLLM, BERT (工具选择), CLIP-ViT (视觉)	农民、农业专家	甘蔗病害图像、文本查询
Farmonaut Jeevn AI	个性化农场咨询 (营 养、土壤 pH、病虫害、灌溉、产量)	AI, 卫星影像分 析	农民	卫星数据、 天气、土 壤、本地农 场信息
Agmatix	数字农艺平台 (田间 数据收集、试验管 理、作物营养优化、 再生农业)	AI, 生成式 AI (AXIOM 技术), 开放数据	农民、农 艺师、零 售商、研 究人员	田间数据、 试验数据
GROWERS	连接农民、农艺师、 零售商的数字服务平	数据驱动推荐	农民、农 艺师、零	客户数据、 产品数据、

平台名称	主要功能/重点	关键 AI 组件/技术	目标用户	主要数据来源
	台 (销售管理、投入品采购、数据分析、营销)		售商、制造商	精准农业数据
BytePlus ModelArk	PaaS 平台, 用于 LLM 部署和应用 (如产量预测与 ERP 集成、供应链优化)	LLM (如 DeepSeek)	企业 (包括农业领域)	历史作物数据、天气、卫星影像 (用于产量预测)

表 9-1: 部分农业智能化平台及服务

### 9.1.1 智能农业问答系统

在传统农业信息平台中, 知识获取通常通过关键字搜索、问题知识库或简单规则问答系统实现。这类系统往往只能检索到与查询词匹配的文档或预定义答案, 缺乏对自然语言提问的深度理解, 也无法根据用户背景提供量身定制的解答。例如, 过去农民遇到种植难题时, 可能需要翻阅技术手册或在门户网站输入关键词检索, 而检索结果需要用户自行阅读理解, 交互成本较高。此外, 传统系统对新出现的问题或语言表述多样的提问往往表现不佳, 容易出现检索不到有效答案或答案不精确的情况。这些局限使得农业技术知识的获取在时效性和易用性上受到限制。

大模型的引入, 推动了农业推广等传统服务从传统的基于关键词搜索或结构化数据库查询的模式, 向更自然的对话式交互的转变, 重塑了知识问答功能。大模型能够以对话形式理解农民或技术人员提出的自然语言问题, 并直接给出综合整理后的答案, 而不只是提供已经被回答过的固定知识。此外, 引入大模型可以将复杂的科研知识转化为农民听得懂的通俗语言, 提供针对性的建议, 不仅能回答“一般性的问题”, 还能结合用户提供的背景 (如作物种类、区域气候) 给出个性化的解答, 真正模拟了人类专家与提问者交流的过程, 大大降低了用户获取信息的门槛。例如, AgroLLM 系统利用大模型的自然语言理解和上下文感知能力, 有效地解答农民提出的各类农业问题, 农民、农艺师和研究人员等用户可以用日常语言提出复杂问题, 并获得与语境高度相关的答案。

相较于一般开放域聊天模型容易产生不正确的“幻觉” (hallucination) 回答, 因此常使用检索增强生成 (RAG) 框架, 通过将大模型的生成能力与来自经过验证的、特定领域知识库的信息检索相结合, 确保咨询建议的科学性和可靠性。该框架通过将大模型与领域知识库相结合, 避免生成不准确或虚构信息的问题的同时, 还能确保其输出是基于最新的科研文献、最佳实践以及本地化数据。例如, AgroLLM 利用 RAG 框架和一个包含 7000 份研究论文和书籍的专业农业知识库, 将回答锚定

在权威信息源上，从中检索信息，再生成答案，实现了高达 97% 的准确率。这种将检索与生成相结合的方法，可以弥补大模型训练语料过时或知识不足的弱点，使模型能够基于最新的科研和实践数据作答，极大减少了错误信息的产生。RAG 技术需要一个可信的外部专业知识源，而这反过来也推动了对高质量农业数据进行收集、整理和管理的新需求，带来新的产业变革。

此外，大模型的出现也为实现多语言交互提供可能。农业生产遍布全球，不同地区的用户语言各异。大模型的强大翻译能力和多语言理解能力，可以打破语言障碍，使农业知识服务惠及更广泛的人群。新一代的农业智能平台，不仅会促进跨地区的农业生产模式交流，甚至可以促进跨国的农业技能交流及培训，真正的化解语言门槛，促进世界农业的全面发展。

### 9.1.2 智能化信息检索与知识挖掘

随着农业信息化水平的不断提升，农业领域已积累起大量结构化与非结构化数据资源，如科研文献、市场动态、气象记录、土壤数据、病虫害发生规律及农产品价格波动等。这些数据蕴含着巨大的知识潜力，但因其种类繁多、格式多样、结构不一，如何从中高效、精准地提取有价值信息，成为农业智能化进程中亟待解决的核心挑战。多模态大语言模型（Multimodal Large Language Models, MLLMs）的兴起，为这一问题提供了突破口。

传统农业智能平台多依赖结构化数据和文本数据进行分析，难以覆盖图像、音视频、扫描件等非结构化信息，不同数据源之间缺乏有效关联，导致信息孤岛现象严重。而 MLLMs 天然具备处理图像、文本、语音等多模态数据的能力，使其成为农业多源数据整合的重要工具。以 AWS 推出的综合人工智能服务架构为例，其集成了多种多模态模型，可将手写笔记、扫描文档、照片、图示等转化为可编辑、可搜索的数字格式，从而释放此前未被系统利用的视觉数据价值。类似地，MA3[4] 通过 MLLMs 执行图像识别任务，例如甘蔗病害分类，进一步验证了多模态模型在农业应用中的可行性与有效性。

在实际农业生产中，纸质手写记录依然广泛存在，尤其是在田间观察、病害跟踪等环节中。这些记录往往包含高度实时、经验丰富的一手资料，却因其非结构化形式难以纳入数字分析体系。MLLMs 通过图像理解与文本生成能力，能够自动识别并提取手写内容，将其数字化为结构化文本，使这些原本“沉默”的信息得以被系统处理、搜索和分析。这不仅丰富了农业数据来源，也降低了传统农业从业者进入数字化管理系统的门槛。

多模态大模型真正的价值不仅在于单一模态的处理能力，而在于其整合多模态信息以实现综合分析的能力。这种融合体现在多个层面，如在作物监测方面，通过将卫星遥感影像、无人机航拍图像、土壤传感器数据与数字化手写田间记录相结合，系统可对作物长势、病虫害状况及土壤环境进行多维度分析。当遥感数据显示某区域植被指数异常下降时，系统会自动调取该区域的历史田间记录、土壤数据和气象信息，通过多模态分析快速定位问题原因，可能是病害爆发、营养缺失或灌溉不当。在精准施肥领域，多模态大模型能够整合土壤检测报告的图像、化验数据的

文本记录、作物长势的视觉信息以及农户的经验记录，生成个性化的施肥方案。系统不仅考虑土壤的化学成分，还会分析作物的视觉表现、历史施肥效果和农户的操作习惯，确保方案的科学性和可操作性。这种多源数据融合形成的信息闭环，不仅能提升诊断的准确性，还为资源调度、农艺优化提供了更科学的决策依据。

在多模态大模型的支持下，农业决策支持系统正逐步从基于静态数据分析的模式，向动态、情境感知型系统演进。例如，一张显示作物异常的图像，结合其对应时间段的气象数据、地块的土壤湿度历史、过往病害记录等多模态信息，可构建起丰富的上下文语境，从而实现更精准的问题诊断与响应策略生成。这种跨模态、上下文驱动的能力，使平台在应对复杂农业场景时具备更强的适应性与鲁棒性。

### 9.1.3 基于大模型的个性化农业建议

农业生产中，针对具体情境提供建议和决策支持传统上依赖人工顾问或固定规则的专家系统。例如，农户可能通过线下咨询农业推广人员获得针对其土壤、气候条件的种植建议，或使用根据通用情景设计的决策支持工具（如施肥方案推荐软件）。然而，这些传统方式要么受限于专家资源的可及性，要么缺乏对个体农场数据的深度利用，难以及时、大规模地为每个农场定制最佳方案。基于规则的系统通常只能覆盖预想的几种情况，对于复杂多变的生产环境难以灵活应对。

而大模型的出现，为农业决策支持带来了“数字农艺师”式的全新体验。平台可以综合考虑农户的具体信息（农作物种类、土壤检测结果、气象预报、历史产量等）并给出量身定制的建议。用户可以用自然语言直接询问诸如“在当前土壤肥力和未来 10 天天气条件下，我应该如何调整施肥和灌溉？”等问题，大模型能够理解问题背景并结合其掌握的农业知识进行推理，给出详细的决策建议。这种能力远超以往静态工具的范围，体现为对每个农场“因地制宜”的智能指导。有研究表明，大模型在全球多地的农学资格考试中取得了高分成绩，显示出对农业专业知识的深刻掌握，具备担任农业顾问助手的潜力。这意味着大模型可以胜任提供专业农技指导的角色，为农民和农业学生提供建议和反馈。在印度，已经出现了像“KissanGPT”这样的数字农艺助手，允许文化水平有限的农民通过语音与大模型交互，以获得贴合本地语言和农业实践的定制建议，预示着大模型驱动的系统能够将专家知识普惠化，打破语言和教育障碍，将个性化农业指导推广到更广泛的用户群体。

Farmonaut 公司的 Jeevn AI 系统也通过处理卫星影像、天气预报、土壤条件和历史作物数据，为农民提供个性化、多语言的农事洞察。

要实现真正精细的个性化，大模型需要结合农场的实时数据和在地知识。一方面，平台可以通过 API 将本地传感器和物联网设备的数据馈送给大模型，例如土壤湿度、病虫害监测、作物生长状态等，从而使模型基于最新状况提供决策支持。另一方面，引入区域性知识库（如本地栽培手册、气候和市场信息）对大模型进行检索增强或微调，可以使其建议更贴近本地实践。例如，ExtensionBot 利用检索增强确保回答与当地农业条件相符；微软研究亦指出，可以通过专门语料微调或引入检索两种途径来增强 LLM 的本地化能力，并比较了微调与 RAG 在农业任务中的

效果差异。通过这些手段，LLM 生成的建议能够反映区域差异，如因地制宜的品种选择、病害防治方案以及符合当地法规的操作守则。

相较于原有依赖人工或固定模型的决策支持，大模型带来的增量能力在于其能够理解自然语言描述的复杂情境，并泛化已有知识为具体场景服务，这使每个农场都能获得类似专家亲临指导的体验。而原有系统的升级体现为，通过融合大模型，这些平台得以利用更多元的数据来源并自动适应变化的条件，摆脱了预设规则的局限。类似的个性化智能建议在医疗领域已初现端倪，例如临床决策支持开始借助大模型参考患者个案数据提供针对性诊疗建议；在金融领域，大模型被用于分析投资者的资产状况和风险偏好以定制理财方案。这些跨领域的尝试印证了一个共同趋势：面向个体的智能决策支持正因为大模型的加入而变得更加灵活和强大。对于农业来说，这意味着未来的智能平台能够以更低的门槛将先进的农艺知识精准传递给终端用户，辅助他们做出更明智的生产决策。

## 9.2 大模型作为“智能中枢”：与专业农业工具和模型的协同

虽然大模型在通用知识方面表现出色，但在许多非常专业的农业应用场景中，仍需要与各种高度专业化的工具和更小型、更高效的 AI 模型协同工作，才能实现最佳效果。经过多年的演变，许多专业农业工具和服务已经得到了充分发展，但在整合全局的农业种植过程及用户交互上问题较多。因此，让大模型在其中扮演“智能中枢”或“协调者”的角色，实现信息流的整合、任务的分配以及结果的解读，以应对更复杂、多步骤的农业生产与管理挑战，是未来农业智能平台发展的新范式。

在这一新范式下，大模型在农业智能化平台中的作用正从单纯的分析工具向更高级的智能协调者或“指挥家”演变。它们不仅自身具备强大的数据处理和理解能力，还能有效地组织和调用平台内其他的专业化 AI 模型和软件工具，形成协同效应，从而为现代农业生产提供更加智能化和系统化的解决方案。

### 9.2.1 智能化工具选择与 workflow 自动化

LLMs 作为智能编排核心，能够理解用户的高级目标或复杂情境，并据此选择和调用最合适 的专业 AI 模型或工具。例如，面对作物病害的初步迹象，LLM 可以判断是需要调用图像识别模型进行病害初步鉴定，还是需要检索知识库获取可能的病害类型及其防治方法，亦或是结合历史数据和环境参数调用一个预测模型来评估病害扩散风险。多模态农业智能体架构 (MA3) 的设计理念中，便可预见到 LLM 在任务路由、工具选择（如病害分类、病斑检测或视觉问答模型）方面发挥核心作用。工具学习的概念也强调了大模型依据用户指令协调工具调用的能力。这种基于用户意图和系统状态进行高级决策的能力，取代了以往需要开发者手动串联逻辑模块的僵化方式。

大语言模型为农业调度与规划提供了一种新型解决方案，能够理解人类用自然语言描述的目标和约束，从而生成可执行的计划。通过链式思维 (Chain-of-Thought) 等推理技术，LLM 在处理复杂决策时可以分解问题、逐步推演，使其具有一定的规划能力。例如，研究者曾为 LLM 设计提示，让其根据天气预报、土壤

湿度和作物类型生成详细的播种计划。具体而言，提示可以是：“给定未来 10 天天气预报数据、当前土壤湿度水平和作物类型，请生成优化产量的详细播种日程。”LLM 接收到此类输入后，能够综合考虑天气窗口和农艺要求，给出合理的播种与田间管理时间表。与预置算法相比，LLM 生成的方案具有更灵活的知识调度基础，因为模型可以调用广泛的背景知识和经验，例如雨天不宜施肥、某作物需要在霜冻前定植等隐含规则都会在生成中体现出来。

此外，大模型能够动态编排涉及多个 API 调用的复杂 workflows。它们可以管理对平台内部或外部不同服务接口的调用顺序，处理数据格式转换，并以灵活的方式组织操作序列。这类似于 LangChain 或 AutoGen 等框架所实现的功能，即允许大模型与各种工具和 API 进行交互，并具备一定的记忆和规划能力。例如，大模型代理可以利用自然语言理解能力来选择和链接 API，以完成特定任务，如农资采购的询价与下单，或农机设备的调度与状态跟踪。大模型甚至可以将用户的自然语言意图解析为 SQL 查询，直接与数据库进行交互。

基于 LLM 的编排代表了从预编程 workflow 到动态、智能任务执行的转变。传统平台依赖硬编码逻辑来定义 workflow，这意味着每当引入新工具或流程发生变化时，都需要进行代码更新。大模型作为编排器，能够理解一个高级目标（例如，“评估 X 地块的冰雹灾情并推荐恢复措施”）。随后，大模型可以动态地选择调用卫星图像分析工具、作物损害评估模型，并查询知识库以获取恢复方案，将这些步骤智能地串联起来。这种基于意图的适应性，为农业智能化平台带来了前所未有的灵活性和智能水平。

这种编排能力极大地增强了农业智能化平台的模块化和可扩展性。如果大模型能够通过 API 描述或自然语言指令学习如何使用新的专业工具或数据源，那么将这些新组件集成到平台中就会变得更加容易。开发者可以更专注于创建具有清晰 API 接口或功能描述的工具，供大模型编排器理解和调用，大模型在此过程中扮演了通用适配器的角色。这有望加速农业科技的创新步伐，因为新的功能模块（如一种新型传感器数据分析工具）可以更便捷地接入平台并被 LLM 利用，而无需对核心编排逻辑进行大规模改造。这类似于一个“应用商店”模式，其中大模型担当操作系统的角色。

大模型任务编排也必然要求为专业的农业模型和 API 开发更强大、更规范的“工具使用”协议和清晰的文档，使其更“LLM 友好”。为了让大模型能够有效地选择和使用一个工具，它需要理解该工具的功能、输入要求以及输出格式。这就推动了对工具及其功能进行标准化描述的需求，可能通过 OpenAPI 规范或 LLMs 能够解析的自然语言描述来实现。这意味着一个协同进化的过程：随着大模型编排变得越来越普遍，专业农业 AI 组件的设计和文档化方式也将随之调整，以更容易被 LLM 代理发现和使用。

当大模型给出调度方案后，平台可以进一步结合优化算法对方案进行量化评估和调整。例如，针对灌溉计划，可以用传统优化模型计算出最优用水量 and 时间，再由 LLM 将其融入自然语言建议中，从而结合了规则优化与语言解释的优点。另一

方面，调度方案的执行结果也为系统提供了宝贵的反馈数据。例如，如果 LLM 建议的田间管理计划实施后效果不理想，系统可以记录这些案例，并在后续通过微调或规则更新来避免重复类似失误。这种反馈机制与强化学习方法相辅相成，有助于模型逐渐学会更精确地遵循农艺最佳实践进行规划。总的来看，LLM 赋能的智能调度将原本孤立的多个决策环节融合为一体：模型理解决策意图，调用外部数据求解，输出可解释方案，再通过反馈不断完善。其新增能力在于自动将海量实时数据纳入考虑并生成人性化的计划建议，而原有调度功能则因此变得更加智能高效，实现了由人工经验驱动向数据与知识共同驱动的升级。

当前，在物流和制造领域，类似的智能排产也开始采用 LLM 技术，将生产要求转化为可执行计划。机器人和自动驾驶系统中，研究者尝试利用具备规划推理能力的大模型，让机器能根据高层指令自主安排行动序列。这些探索表明，大模型在复杂系统的调度控制上展现出通用智能的雏形。同样在农业领域，大模型通过与农机、自主设备的联动，有望实现农事活动的自动协调。例如，将来模型可以根据农田状况自动协调无人机喷洒农药和无人拖拉机耕作的时序，使各环节紧密配合、效率最优。虽然目前这些应用多处于实验阶段，但 LLM 驱动的智能调度为未来农业全流程自动化管理提供了一个令人憧憬的方向。

### 9.2.2 与物联网 (IoT) 及农场管理系统 (FMS) 的无缝集成

LLMs 可以作为农场中庞大的物联网设备网络与中央农场管理系统 (Farm Management Systems, FMS) 或企业资源规划 (Enterprise Resource Planning, ERP) 系统之间的智能中介，促进数据的流畅交换和深度利用。

在解读复杂传感器数据方面，大模型的能力远超简单的阈值警报。它们能够分析来自多个传感器的时序数据模式，理解与传感器部署相关的自然语言注释，并结合农场整体运营的背景，对传感器数据所指示的含义给出更细致、更智能的解读。尽管目前关于 LLMs 直接解读物联网数据并服务于 FMS 的验证尚不充分，但从 LLMs 处理多样化数据、执行数据分析以及与其他系统集成 的能力来看，这一潜力是显而易见的。文献中也提及了 LLMs 与物联网系统结合使用的可能性，例如 Farmonaut 便计划将其平台与物联网设备集成。

LLMs 还能促进智能数据流向 FMS/ERP 并生成可操作的洞察。它们可以将来自各种来源（包括物联网和由 LLM 编排的工具）的原始或半结构化数据，转换为适合 FMS/ERP 系统使用的结构化格式。同时，LLMs 可以生成自然语言的摘要、报告或警报，这些信息对于农场管理者而言是直接可操作的，或者可以触发 FMS/ERP 系统内的自动化流程。例如，AWS 的参考架构便能将处理后的信息（来自手写笔记、图像等）发送到下游的客户关系管理 (CRM)、FMS、农场管理信息系统 (FMIS) 等系统。BytePlus ModelArk 平台也支持将 AI 驱动的产量预测结果与 ERP 系统集成。LLMs 在自动化报告生成方面的能力也得到了广泛认可。

LLMs 能够将原始的物联网数据转化为内容丰富、上下文相关的叙述性信息或结构化洞察，供 FMS 消化和利用，这标志着从简单的数据记录向智能事件解读的转变。物联网传感器产生连续的数据流。传统的 FMS 可能仅接收原始的温度或湿

度读数。然而，一个集成了 LLM 的系统则可以分析一系列读数，将其与天气预报（LLM 可以访问的另一数据源）相关联，并生成如下警报：“B 区土壤湿度在 48 小时内下降 20%，期间无降雨且预报高温；建议启动 Beta 灌溉周期。如不及时处理，预计对产量造成 5% 的影响。”这种经过丰富和情境化的信息，对 FMS 而言远比原始数据点更有价值，代表了平台利用传感器数据方式的显著扩展。

通过 LLMs 促进的集成，可以实现更全面和主动的农场管理。当 LLMs 能够有效地处理多样化的数据（如手写笔记、图像、物联网数据）并智能地将其或其解读结果传递给 FMS 时，FMS 就成为了一个功能更强大的中央枢纽。FMS 内部的决策（如资源分配、作业调度）可以基于更丰富、更实时、经过智能筛选的数据集来制定。这使得农场管理从被动响应向主动预防和优化转变。

LLMs 的自然语言处理能力可以为 FMS/ERP 系统创建一个全新的、更直观的交互层，允许管理人员使用对话式命令来查询复杂的运营数据或启动相关操作。FMS/ERP 系统通常具有复杂的用户界面。而 LLMs 在自然语言交互方面表现出色。通过将 LLM 作为前端或交互层集成，农场管理者可以用自然语言向其 FMS 提问，例如：“上一季玉米与大豆的平均每公顷肥料成本分别是多少？”或“安排明天上午对所有番茄地块进行无人机病虫害侦察。”LLM 会将这些自然语言指令转化为 FMS 能够理解的查询或命令。这为用户与这些后端系统交互和利用其功能提供了一种全新的方式。

### 9.2.3 LLM 与专业工具、小模型、知识图谱的协同集成

大模型的强大功能在很多情况下并非孤立发挥作用，而是通过与各种专业工具和模型的配合，实现“1+1>2”的效果。在农业智能平台架构中，越来越多地采用模块化的设计，让 LLM 与检索系统、知识图谱、专用模型和外部 API 协同工作，形成一个有机整体，以克服单一模型的局限。

正如前文所述，将 LLM 与领域数据库集成的 RAG 策略，可以让模型实时获取知识。除了文档检索，知识图谱 (Knowledge Graph) 作为结构化知识的表达方式，也可以与 LLM 结合，提供精确的事实校验和关系推理支持。例如，有研究将客户服务历史数据构建为知识图谱供 LLM 检索，从而保留了问题与解决方案之间的结构联系，提升了回答准确率。在农业领域，类似的方法可将作物病虫害知识、品种特性等构建为图谱，LLM 在回答时查询相关节点，确保建议符合科学逻辑和事实依据。这种 LLM+知识图谱的结合能够减少模型产生不一致或不真实内容的概率，并使推理过程更加透明。

LLM 还可以充当“大脑中枢”，调用其它专门模型或算法完成特定任务。例如，图像识别模型可以用于处理农业中的视觉任务，然后将结果交由 LLM 解释和决策。在咖啡植物疾病诊断的研究中，Kumar 等将 YOLOv8 视觉检测模型识别出的病斑结果提供给 LLM，利用 RAG 机制让大模型结合上下文进行病害诊断和防治建议。这种多模型流水线整合了深度学习视觉能力与 LLM 的语言推理能力，实现了精确又智能的诊断系统，既克服了 LLM 孤立应用时可能出现的幻觉问题，又提供了动态的识别-推理方案。再比如 PlantCareN 系统采用深度卷积神经网络识别植物叶

部病害，同时由知识库和推理模块提供防治建议，实现视觉和知识驱动的双模推荐。在更复杂的基因育种领域，大模型也可以通过工具接口调用生物信息算法：例如 ShizishanGPT 在回答作物遗传问题时，能够自动调用外部的作物表型预测或基因分析程序来计算结果，然后将这些精确计算融入对用户的答案中。这种代理 (Agent) 式架构极大扩展了 LLM 的功能边界，使其既能处理开放的语言问题，又能借助专用模型完成精细计算和预测。

得益于 LLM 的工具使用能力，农业智能平台还可以实现高度自动化的调度决策。通过“函数调用”等机制，LLM 能够访问外部数据和服务，在生成计划时获取实时信息。例如，农场管理者可以问：“今天是否需要灌溉我的田地？”LLM 会自动调用天气 API 和土壤传感器数据，综合分析当前土壤湿度、未来降雨预报等因素，再给出结论性建议。同样地，对于“预计我的作物产量是多少？”这样的提问，模型可以调取历史产量记录和卫星影像 NDVI 指数进行估计。这一过程中，LLM 相当于扮演了一个调度中枢：将来自卫星、传感器和农场管理系统的多源数据加以整合，转化为直观的行动方案。例如，模型可能根据当前土壤墒情和天气预报建议立即灌溉，或者提示“两周后施加一次额外肥料以提高作物产量”。LLM 将复杂数据转化为简明可行的指令，使得即便缺乏专业知识的用户也能获得高质量的调度建议。

模块化、多组件协同的设计大大提升了农业智能平台的性能和可靠性。一方面，各组件各司其职：LLM 负责通用语言理解与生成，检索模块确保信息新鲜度和准确性，知识图谱保证逻辑一致性，专业模型提供特定领域的精准输出。这样的分工协作弥补了单一 LLM 的短板。实践证明，融合多源知识的 LLM 系统在回答准确性和细节丰富度上明显优于单纯依赖 LLM 的方案。例如，上述 ShizishanGPT 通过包含搜索引擎、知识图谱、RAG 检索和农业专用模型等五大模块，显著提升了回答的专业性和完备性，在 100 道农业问答测试中输出的答案更准确翔实，相比未集成外部工具的 LLM 表现出明显优势。另一方面，这种架构具有良好的扩展性和可维护性：平台可以根据需要灵活增加新的工具（如连接气象预测 API、经济模型等），LLM 通过调用它们即可获得新能力，而无需从头训练。此外，当某一模块需要更新（例如知识库扩充或更换更先进的子模型）时，可以局部替换而不影响整体系统，其余部分仍保持稳定。这种插件化的设计思想，类似于工业控制中的“主控单元+功能组件”模式，使农业智能系统能够持续演进，集成最新技术成果。

当然，多模块协同也带来一些挑战。例如，不同组件的接口规范和数据格式需要严格定义，LLM 调用工具时必须精确描述任务并正确解析返回结果，这对提示工程和代理控制提出了要求。此外，系统整体的响应速度取决于各模块的效率，过多的模块串联可能增加延迟，因此需要优化调用流程。最后，多来源信息融合时若出现冲突，平台需要制定优先级或决策规则（如以知识图谱事实为准等）来协调。这些挑战正在通过不断的实践得到经验积累，随着框架如 LangChain 等的发展，LLM 与外部工具的集成变得越来越成熟规范。总的来说，LLM 与专业工具、小模型和知识图谱的协同，为农业智能平台带来了前所未有的多样化能力，奠定了一个可以不断拓展的创新基础。

## 9.3 大模型数据驱动的人工智能平台学习适应

基于大模型的农业智能化平台并非一成不变的静态实体，其具备通过学习不断提升性能的潜力。特别是通过针对农业领域的反馈机制和持续的数据驱动优化，大语言模型（LLMs）能够逐步适应特定需求，提供更精准、更可靠的服务。农业智能化平台的核心竞争力不仅在于其集成的先进模型和工具，更在于其能否构建一个有效的数据闭环，通过持续的数据积累、高质量的反馈以及智能化的分析，驱动 AI 模型不断学习和进化，从而提供越来越精准、越来越智能的服务。大模型作为平台的重要组成部分，其性能的提升同样高度依赖于这一数据闭环。

### 9.3.1 通过领域特定反馈增强大模型性能

尽管大模型在许多任务上表现出色，但它们并非完美无缺，尤其是在专业性强、对准确性要求极高的农业领域，可能会产生事实性错误、不符合本地实际情况的建议，或者未能充分理解用户特定情境下的需求。因此，引入人工反馈，特别是农业领域专家的反馈，对于校准模型行为、提升输出质量至关重要。这就需要引入基于人类反馈的强化学习（RLHF），以农业领域专家和用户的反馈为核心，持续优化模型表现。

具体而言，RLHF 通过以下流程实现：首先构建农业领域偏好数据集，专家对模型生成的建议进行评分，以此训练奖励模型（RM），让其学习专家评价标准（如准确性、实用性、安全性）；接着，利用 RM 作为强化学习算法（如 PPO）的奖励函数，引导模型参数调整，使模型输出更贴近农业实际。

此外，用户（如农民）反馈对模型的个性化调整同样关键。他们的实际应用效果、反馈评价等信息，可帮助模型掌握农场具体情况与用户习惯，推动模型在建议表达方式、实操便利性方面的精细优化，形成持续学习闭环。在实际的模型服务中，模型可以在下一轮迭代中将积累下来的用户反馈，用于下一轮的 RLHF 过程中，做到真正对接用户的需求。

这种持续反馈与领域特定训练机制，进一步保证了模型对环境变化和用户需求的快速适应性。以 AgroLLM 为代表的农业模型系统通常已内置此类机制，通过动态优化不断提升模型表现。此外，RLHF 强调农业专家与 AI 开发者的跨学科紧密合作。这种合作模式催生了新的职业角色，强化农业专家在模型开发、评估与持续优化中的关键作用，确保建议科学可靠。

通过持续的 RLHF 循环，农业领域的大模型逐步发展出精准、情境感知，甚至具备前瞻性的建议能力，不仅解决用户当前提出的问题，还能主动预测潜在需求和风险，从而在农业咨询服务中提供比传统静态知识检索系统更为灵活和深入的支持。

### 9.3.2 生成合成数据以增强模型鲁棒性

LLMs 不仅可以直接提供服务，还可以作为一种辅助工具，通过生成合成数据来训练或提升农业智能化平台内其他 AI 模型的鲁棒性。例如，在植物病害检测等计算机视觉任务中，获取大量且多样化的真实标记图像往往成本高昂且耗时。

LLMs 在数据增强方面的应用，为解决这一问题提供了新的途径。它们可以生成多样化的文本描述，这些描述可以与图像数据配对，丰富训练样本的元信息。更进一步，大模型有潜力辅助生成合成图像数据，通过指令精细化的知道文生图模型生成逼真图片，用以扩充有限的训练数据集。这种方法有助于改善其他专业模型（如病害识别模型）的泛化能力和整体性能，尤其是在真实数据稀缺或存在类别不平衡的场景下。LLMs 通过整合和自动化跨模态合成，提供了比传统方法更复杂、更具上下文感知能力的合成数据生成方式，从而能够有效解决类别不平衡问题并增强数据集的多样性。

LLMs 在此扮演了一个关键的支持性角色：它们不仅是直接面向用户的服务提供者，还能通过解决数据稀疏性问题，为平台内其他 AI 组件的性能提升做出贡献。训练稳健的专业 AI 模型（例如用于罕见病害检测的模型）通常需要大规模、多样化的数据集。在农业领域，收集和标注此类数据的成本可能非常高昂。LLMs 凭借其强大的生成能力，可以创建现有数据的合成变体，或生成看似合理的新数据点（无论是文本描述还是指导图像合成）。LLMs 的这种“元功能”有助于改善平台内整个 AI 工具生态系统的健康度，而不仅仅是基于 LLM 自身的服务。

这种生成合成数据的能力，有望加速针对特定细分农业问题或数据资源匮乏地区的 AI 解决方案的开发和部署。许多农业挑战具有高度的地域性，或者影响的是一些不常见的作物品种，这导致了相关训练数据的缺乏。如果 LLMs 能够有效地增强这些稀疏数据集，就能降低为这些服务不足的领域开发 AI 工具的门槛。这可能促使 AI 技术在农业领域的惠益得到更广泛和更公平的分配。

### 9.3.3 大模型引导的数据闭环构建与平台自我进化

大模型的引入不仅为农业平台带来了即时的智能功能升级，更打开了系统自我演化的新路径。传统的软件功能往往是固定的算法，一旦部署，性能取决于预先提供的数据和规则。而基于大模型的智能平台则可以在“使用中学习”，通过构建数据闭环，不断优化自身的知识和策略。

构建强大的农业大模型和智能化平台，首先需要海量、多样、高质量的农业数据。数据积累策略应注重多源数据采集，包括用户交互数据、物联网传感器数据、农事记录数据、遥感与地理空间数据、专家知识与经验数据、公开数据集与文献数据以及市场与供应链数据。同时，数据治理与遵循 FAIR 原则（可发现性 Findable、可访问性 Accessible、互操作性 Interoperable 和可重用性 Reusable）至关重要，涵盖元数据管理、数据标准化、数据质量控制以及数据安全与隐私保护。有效的多源数据积累和严格的数据治理，是构建高性能农业 LLM 和智能化平台的基石。例如，Agmatix 等农业数据平台致力于将多样化的农学数据转化为可操作的洞

见，而 GROWERS 等平台则通过连接客户与产品，积累了大量与可持续农业实践相关的数据。

用户互动驱动的改进是数据闭环的关键环节。每一次用户与 LLM 的平台互动（如一次提问和得到的回答）都蕴含着改进的契机。用户的提问反映了现实生产中关心的问题，LLM 给出的回答及其后续效果可以作为新的数据积累下来。例如，农民咨询病虫害防治建议后，实际采取措施的结果（是否成功遏制病害）可以反馈回系统。当答案不理想时，专家可以标记纠正，平台据此更新知识库或调整模型输出策略。这种循环使得系统能够逐渐弥补自身知识盲区、纠正错误倾向。AgroLLM 等实践案例已强调通过持续反馈来提升回答质量的重要性。研究者通过引入用户评价和交互记录，不断微调模型或更新检索内容，使系统的回答愈发准确贴近用户需求。在实际应用中，这种反馈可通过显式评价（如用户对答案的满意度打分）或隐式信号（如用户是否采纳建议）获得，从而形成自动化的数据回流。

除了专家直接提供的显式反馈外，普通用户在平台上的自然行为也蕴含着大量有价值的隐式反馈信号。这些信号数据量大、获取成本低，对于模型的持续优化同样重要。通过分析用户查询模式、工具使用频率与路径、内容浏览时长与交互行为、建议采纳情况的间接推断以及 A/B 测试等，可以帮助平台理解用户的信息需求痛点和认知习惯，从而优化 LLM 对用户意图的理解能力，并指导平台功能的迭代和 UI/UX 的优化。Google PAIR 团队的研究强调，利用隐式反馈时，需要确保反馈信号与模型改进目标的一致性，向用户清晰传达其数据如何被使用，并允许用户选择退出隐式反馈的收集。

知识库的滚动扩充是平台自我进化的另一体现。有了 LLM 这样灵活的接口，农业知识库的更新也可以部分实现自动化。平台可以记录下 LLM 无法回答或回答不充分的问题，作为新知识需求的线索，由专家或数据工程师据此补充相应内容。另一方面，LLM 本身也可用于生成候选知识。例如，它可以根据已有文献总结新的问答对，待专家审核后加入知识库，丰富系统储备。社区参与也是闭环的一环：推广机构和科研人员可以持续向平台提交新的农业技术资料来扩充知识库。例如，美国 ExtensionBot 项目鼓励各州推广组织提交新的出版物，以增强其知识基础。随着时间推移，平台的知识库将日趋完备，LLM 通过检索将这些新增知识融会贯通地运用到回答中，避免了知识滞后的问题。

随着闭环机制的运行，农业智能平台将呈现出“自我成长”的能力。从早期版本的泛泛而谈开始，逐步积累数据后，回答的广度和深度都将扩大。例如，一个病虫害诊断平台，最初也许只涵盖常见病害，通过用户不断提问和专家补充，如今可能扩展到处理数百种作物病害及综合防治方案。系统性能也会因反馈优化而逐步提升，表现为回答准确率提高、用户满意度上升等可量化指标。更理想的设想是，平台甚至可以根据所收集的数据预测未来需求，提前学习相关知识。例如，如果大量用户开始询问某种新出现的虫害，平台可提示专家团队关注并添加该虫害的防治知识，从而前瞻性地更新系统。这样的进化能力将使农业智能平台始终紧跟农业生产实践的最新动态，不断提高决策支持的价值。对于政府和研发部门而言，这种“活的系统”意味着科技服务农业的模式从静态供给转变为动态共创——用户、专家与

AI 共同塑造和提升平台，使之越来越契合实际需求。通过构建这样一个从数据积累、多重反馈到知识持续更新的闭环系统，农业智能化平台及其 LLM 才能真正成为一个能够自我进化、永葆活力的“学习型”智能体，为农业生产者提供最可靠、最前沿的智慧支持。

## 9.4 促进新型农业平台的推广应用

尽管农业智能化平台与大模型的集成为农业发展描绘了光明前景，但技术的成功最终取决于用户的广泛接受和有效使用。农业用户的特殊性，如年龄结构、受教育程度、生产习惯、对新技术的敏感度等，使得提升 AI 接受度成为一项系统性工程，需要从用户体验、信任建立、技能培训、障碍克服和社区营造等多个层面综合施策。

### 9.4.1 以用户为中心的设计

平台的设计必须始终围绕农业用户的实际需求和习惯展开，而非单纯追求技术的先进性。在符合农业用户习惯的 UI/UX 设计方面，界面应力求简洁明了，避免信息过载和复杂操作，功能导航需清晰，常用功能宜置于显眼位置。为农民设计的应用，其数据可视化应做到“一目了然”，如图表直观展示土壤湿度、作物长势、病虫害预警等级等。平台应提供简单易懂的新用户引导和操作提示，降低学习门槛，对复杂的农机设备控制或数据分析功能尽可能简化操作流程。考虑到许多农民在田间地头通过手机等移动设备获取信息和操作，平台应优先支持移动端访问，并采用响应式设计，确保在不同屏幕尺寸上均有良好显示效果。针对农村地区网络信号不稳定或覆盖不全的问题，平台应尽可能提供核心功能的离线使用能力，如预下载的农技知识库、病虫害图谱、常用计算工具等。同时，平台应允许用户根据作物类型、关注重点、常用功能等对界面或信息展示进行一定程度的个性化定制。

多语言支持与文化适应性也至关重要。农业生产具有显著的地域特征，不同地区农民的语言、文化背景、认知习惯各不相同。平台应提供多种语言版本，确保翻译的准确性和地道性，内容呈现和交互方式亦应考虑到当地文化习俗和农民接受程度。如通过 AI 驱动的咨询服务，以多种地方语言通过移动应用向农民提供信息，取得了良好效果。此外，包容性设计要求关注不同年龄段、不同受教育水平、不同数字素养用户的需求，对老年用户或数字技能较弱的用户可提供更大字体、更简化流程、语音交互等辅助功能。

### 9.4.2 建立信任机制

信任是用户采纳 AI 技术的前提。由于 AI 决策过程的“黑箱”特性及可能存在的错误或偏见，农业用户对 AI 平台提供的建议往往持谨慎态度，建立信任需要长期努力。首先，透明度与可解释性 (Explainable AI, XAI) 是关键[21]。当平台给出农事建议或诊断结果时，应尽可能解释其判断依据和推理过程，例如，建议施用某种农药时，说明基于何种症状识别、参考了哪些防治指南、考虑了哪些环境因素等。利

用 SHAP、LIME 等 XAI 技术，可以将复杂模型的决策过程以相对简单的方式呈现给用户，增强其对 AI 决策的理解和信任。

其次，数据隐私与安全保障至关重要。农民的农场数据、个人信息、生产记录等是其宝贵资产，平台必须明确数据所有权归属（通常应归用户所有），制定严格的数据采集、存储、使用和共享规范，采用先进加密技术和安全防护措施，确保用户数据不被泄露、滥用或用于未经授权的目的。公开透明的数据使用政策和用户隐私协议是必要的。

再者，平台输出的知识和建议必须提供可靠且经过验证的信息，以科学依据和实践验证为基础。对于 LLM 生成的内容，尤其是涉及生产决策的关键信息，应尽可能经过农业专家审核或与权威知识库交叉验证，避免因错误信息导致生产损失。在推广初期，可从已被验证行之有效的 AI 应用场景入手，逐步积累成功案例，以事实证明 AI 的价值。同时，对于一些具有不确定性或潜在风险的建议（如极端天气应对、新型病虫害防治），平台应进行充分的风险提示，并明确 AI 建议的辅助性质，最终决策权仍在用户。应有明确的服务条款界定平台与用户在信息使用和决策后果方面的责任。最后，人类监督与纠错机制不可或缺。建立有效的人工反馈和专家审核机制，不仅能提升模型质量，也是向用户传递“平台对结果负责并持续改进”信号的重要方式，有助于建立信任。Codewave 等强调，人类监督对于缓解模型偏见和不完整性至关重要。

### 9.4.3 培训与技能提升

即使平台设计得再友好、技术再可靠，用户若缺乏必要的数字技能和 AI 认知，也难以有效利用。因此，针对性的培训和技能提升计划不可或缺。这需要提供多层次、多形式的培训资源。例如，面向数字素养较低的农民，提供智能手机使用、APP 操作、信息检索等基础数字技能培训；针对平台具体功能，提供在线教程、视频演示、操作手册、常见问题解答 (FAQ) 等平台操作培训。同时，应向农民普及 AI 在农业中的应用价值、基本原理（以通俗易懂的方式）、成功案例等 AI 理念与应用培训，消除其神秘感和疑虑。组织线下培训班、田间学校、现场演示会等实地演示与研讨会，让农民亲身体验 AI 平台的应用效果，并与专家、其他用户进行交流也是有效途径。此外，建立畅通的技术支持渠道，如电话、在线客服、本地服务站，及时解答用户疑问，提供专家咨询与个性化指导，也十分重要。

推广数字农业理念，提升农民数字素养是另一关键环节。可以借鉴联合国粮农组织 (FAO) 的“农民田间学校 (Farmer Field Schools, FFS)”模式，并将其升级为 FFS 2.0，即融入数字工具和技能培训[24]，通过参与式学习和经验分享，帮助农民提升在数字时代的生产经营能力。伊利诺伊大学 ACES Online 等机构已开始提供数字农业、农业 AI/ML 相关的证书或学位课程，培养高层次农业科技人才。同时，需要关注“最后一公里”的知识传递，与农业技术推广体系、合作社、农业企业等合作，利用其现有网络和服务渠道，将 AI 平台的培训和服务延伸到农村基层。

#### 9.4.4 克服采纳障碍

农业用户在采纳 AI 平台时可能面临多种实际障碍，需要针对性地解决。首先是成本效益问题。平台需要通过试点示范、案例分析、成本效益计算工具等，向农民清晰、具体地展示使用 AI 平台可能带来的经济效益，如提高产量、降低化肥农药投入、节省人工、减少灾害损失等，即清晰展示投资回报（ROI）。针对不同规模和类型的用户，提供灵活的订阅服务、按需付费、免费增值等多种多样化的付费模式，以降低初始使用门槛。对于高成本硬件设备，如大型智能农机、物联网传感器网络，可以探索合作社共享、租赁服务等共享机制，并积极争取政府对农业智能化应用和农民培训的财政补贴与政策支持。Folio3 和 Number Analytics 等分析指出，高昂的前期成本和不明朗的投资回报是主要障碍，需要政府激励和共享投资模式。

其次，技术复杂性与易用性也是障碍之一，需要持续优化平台设计，使其更易于理解和操作，提供“交钥匙”式解决方案或一站式服务，减少用户自行配置和维护的麻烦。网络连接性问题同样需要关注。应大力发展离线功能、边缘计算解决方案等推广适应性技术。在网络基础设施薄弱地区，可考虑利用卫星互联网、低功耗广域网（LPWAN, 如 LoRa, NB-IoT）、无线 Ad-hoc 网络或 Mesh 网络等技术改善连接性，即探索替代性网络方案。TerraConnect 等项目致力于通过数字市场和连接解决方案弥合这一差距。

此外，传统观念与习惯的挑战也不容忽视，应尊重农民长期积累的经验和智慧，将 AI 定位为辅助决策工具而非完全替代，通过渐进式推广、让农民小范围试用并看到实际效果，逐步改变其观念。最后，政策与基础设施支持是克服障碍的重要保障，需呼吁政府加大对农村数字基础设施投入，制定支持农业智能化的中长期发展规划和行业标准，营造良好政策环境。FarmingFirst 等组织强调了统一政府政策和农村数字基建投资的重要性。

#### 9.4.5 社区建设与知识共享

营造一个活跃的、互助的农业 AI 用户社区，对于提升用户粘性、促进知识传播和加速技术采纳具有重要意义。可以通过多种途径实现这一目标。例如，利用微信群、QQ 群、农业论坛等农民常用的社交媒体和在线社群，建立官方或用户自发组织的交流群，方便用户分享使用经验、提问求助、交流农技知识。研究表明，社交媒体在农民间学习、获取专家建议和实时咨询方面发挥着重要作用。在 AI 平台内部设置用户论坛、问答区、经验分享板块等，鼓励用户生成内容（UGC），也是有效的平台内建交流功能。

定期组织线上线下活动，如在线研讨会、专家直播答疑、线下用户交流会、优秀用户评选等，可以增强用户参与感和归属感。内容形式也应多样化，利用图文、短视频、直播、播客等多种形式向用户传递农业 AI 知识和平台使用技巧，特别是视觉化内容，有助于简化复杂概念。最终，将平台打造为连接农民、农业专

家、农资供应商、农产品采购商、科研机构等多方资源的桥梁，促进信息互通和产业协作，从而实现更广泛的知识共享和社区繁荣。

## 9.5 开拓未来创新：大语言模型驱动的前沿能力展望

随着 LLM 技术的不断成熟和演进，其在农业智能化平台中的应用正展现出更广阔的前景。除了对现有核心服务的增强外，LLMs 还有望在农业数字孪生、全价值链优化以及加速科研创新等前沿领域催生一系列突破性的新功能。农业智能化平台与大语言模型的集成尚处于发展的初期阶段，但其展现出的巨大潜力预示着未来农业生产方式和管理模式的深刻变革。

### 9.5.1 超个性化农业决策支持

当前的个性化农业建议主要基于农场宏观数据和作物普适性知识。未来，随着基因组学等多组学技术在农业中的应用普及，以及传感器技术的进一步微型化和精准化，农业智能化平台将能够获取到关于特定作物品种、甚至单株作物、特定牲畜个体的更深层次、更动态的生理生化信息。LLMs 可以作为解读这些复杂多组学数据与海量环境数据的强大工具，通过将特定品种的基因特性、实时生理状态与精细的环境数据相结合，LLM 驱动的决策支持系统有望实现“一物一策”甚至“一时一策”的超个性化管理。例如，针对特定基因型作物精准调控水肥供应，为种公畜或高产奶牛定制精细的饲喂方案 and 健康管理计划，或预测特定品种在特定环境下对新型病害的易感性并提前采取预防措施。这种超个性化决策支持将最大限度地发掘动植物的生产潜能，提高资源利用效率，并减少不必要的农药化肥投入。

### 9.5.2 农业生产全流程自动化与智能化

目前，农业自动化主要集中在某些单点环节。LLMs 的加入，特别是与机器人技术、计算机视觉、强化学习等技术的深度融合，有望推动农业生产向全流程、高度自主的智能化方向发展。未来的智慧农场可能拥有多种类型的自主作业机器人，LLM 可以作为农场的“超级大脑”，动态规划和调度这些异构机器人的作业任务，并实现它们之间的协同工作。例如，LLM 可以分析遥感影像和气象预报，判断最佳的植保窗口期，然后调度无人机和地面喷药机器人协同完成精准施药作业。农业环境复杂多变，LLM 赋予了农业机器人更强的环境理解和自主决策能力，例如采摘机器人在 LLM 的指导下，不仅能识别果实的成熟度，还能理解复杂的指令，甚至能在遇到意外情况时与人类管理员进行自然语言交互。Lumenalta 等公司展望了利用 LLM 和机器学习进行作物识别、杂草管理和病虫害检测，这为全流程自动化奠定了基础。

### 9.5.3 智能化农业数字孪生与大模型的深度融合

农业数字孪生是指物理农场或农业系统的动态虚拟副本，它能够整合实时数据与计算模型，实现对物理实体的持续监测、模拟、预测和优化，从而有效连接物理世界与数字世界。LLMs 的集成有望显著提升农业数字孪生的交互性、分析能力和应用价值。在增强交互与模拟方面，大模型可以为复杂数字孪生模型提供自然语言

交互界面。用户可以通过自然语言查询数字孪生的状态、设置模拟场景参数，并以更直观的方式理解模拟结果。例如，LLMs 在系统模拟、实验设计和策略生成方面展现的潜力，可以直接应用于数字孪生环境。一个基于 LLM 的智能体模拟引擎和自然语言交互的社会数字孪生系统概念，也完全可以适配到农业领域，允许用户通过自然语言引导和影响模拟过程，实时共同创建和测试干预策略。

在提升预测能力与优化决策方面，大模型可以辅助分析来自数字孪生的大量数据，识别复杂模式，预测未来状态（如作物生长趋势、病害传播路径），并提出最优的干预措施建议。LLMs 甚至被视为强大的“世界模拟器”，能够增强数字孪生在描述性建模（理解当前状态）、预测性建模（预见未来趋势）和指令性建模（指导最佳行动）各个阶段的能力。一个统一的“描述-预测-指令”框架已经被提出来，用以整合 LLM 增强的数字孪生建模技术。

大模型的引入，通过以自然语言交互取代复杂的编程或专业化界面，有望普及尖端数字孪生技术的应用。数字孪生功能强大，但通常需要专业用户才能操作和解读其复杂输出。LLMs 可以充当一个直观的“前端”，允许农民或技术背景较弱的管理人员用通俗易懂的语言提出“假设性”问题，并获得易于理解的输出结果。这显著降低了采用和使用先进模拟工具的技术门槛。

大模型强的数字孪生系统，具有支撑大规模、高度主动和优化的农场管理的潜力，支持复杂的场景规划和风险缓解。通过将实时数据与大模型驱动的模拟和预测相结合，农场管理者可以在物理实施之前，虚拟地测试各种管理策略。例如，他们可以模拟在不同气候预测情景下，采用不同的种植密度、施肥方案或病虫害控制策略的效果，以确定最优路径。这使得农业决策从被动响应转变为真正具有战略性的、前瞻性的农场规划，代表了平台能力的重大扩展。Texas A&M 等机构的研究表明，结合传感器数据、无人机影像、AI 和大数据创建的数字孪生模型，可以用于优化种植与收获计划、灌溉和资源分配。

#### 9.5.4 优化农业价值链与智慧供应链

大模型的贡献并不仅限于农场内部的生产环节，它们还有潜力优化更广泛的农业价值链，对从投入品供应到最终消费的各个环节产生积极影响。农业供应链环节多、链条长、信息不对称、易受自然和市场风险影响。在先进产量预测与动态供应链管理方面，其能够分析更广泛的数据阵列，包括新闻报道、市场分析报告、异常天气事件等非结构化文本信息，从而提高产量预测的准确性。更精准的产量预测，继而支持更动态、更高效的供应链调整，包括物流、仓储和分销等环节的优化。此外，大模型能够增强农户、供应商、分销商和零售商之间的供应链沟通效率，提供实时的产品可获得性更新、交付状态预估以及市场需求预测。它们还有助于预测潜在的供应链中断，优化运输路线，并提升整体预测的准确性。SummaVerse 等分析指出，LLM 可以用于预测供应链中断，并通过分析销售数据、社交媒体和宏观经济指标来改善需求预测。

LLM 可以辅助的需求预测与生产计划，通过分析历史销售数据、市场趋势报告、消费者评论、社交媒体舆情、天气预报、宏观经济指标等多源异构数据，更准

确地预测不同农产品的市场需求波动，并向生产者提供更科学的种植/养殖结构调整建议和生产计划指导。在智能化库存管理与物流调度方面，LLM可以整合来自仓库管理系统(WMS)、运输管理系统(TMS)、物联网设备的实时数据，优化库存水平，规划最佳运输路径，动态调度物流资源，减少损耗，提高配送效率。LLM还可以增强农产品溯源与食品安全，帮助构建更易于用户查询和理解的农产品溯源系统，并辅助分析溯源数据，发现潜在的食品安全风险点。此外，LLM能促进产销精准对接，通过分析生产者的产品信息和采购商的需求信息，进行智能匹配，减少中间环节，提高农民议价能力。

LLMs正在催生一些新颖的应用场景。例如，“副产物流向匹配”(side-stream matching)利用LLMs分析科研文献和产业需求，为农业生产过程中产生的副产品或废弃物寻找有价值的再利用途径。另一个例子是基于农产品特性和个体健康数据，开发个性化的营养建议服务。LLMs还能辅助进行食谱开发，特别是在可持续或健康替代食品的创新方面。

LLMs正在将农业智能化平台的覆盖范围从传统的农场生产运营，扩展到并优化整个农业价值链，涵盖了从投入品采购到最终消费者互动的全过程。传统上，许多农业智能平台主要聚焦于生产环节。而LLMs凭借其处理多样化文本数据和促进复杂沟通的能力，正在催生供应链优化、副产物价值化乃至个性化营养链接等新功能。这代表了平台功能领域的显著扩张。LLM驱动的价值链优化，有望带来效率提升、浪费减少、食品安全改善，以及农业生产与市场 and 消费者需求的更好契合。更准确的产量预测可以减少供需错配，更高效的沟通则能简化物流环节，副产物流向匹配将废弃物转化为有价值的资源，而LLMs分析消费者反馈以保障食品安全则有助于提升质量控制水平。

### 9.5.5 加速农业研究与开发及知识图谱协同进化

大模型不仅服务于农业生产实践，其本身也可以作为农业科研人员的强大工具，加速农业科技的创新进程。在辅助实验设计、数据分析和知识发现方面，LLMs能够帮助研究人员高效处理海量的科学文献，从中提取关键信息、总结研究进展；它们可以辅助识别实验数据中的复杂模式，甚至启发新的研究假设；在科研论文撰写、基金项目申请等方面，LLMs也能提供有力的支持。例如，AI技术正在通过加速新型农业技术解决方案的发现，从而变革研发过程。LLMs通过处理复杂查询并生成与上下文相关的响应来协助研究，并且能够分析研究论文以进行副产物流向匹配等任务。

LLMs能够扮演“科研助手”的角色，在农业科学领域内加速创新步伐，而这些创新成果又将反哺农业智能化平台和农业实践的改进。农业研究产生大量的数据和文献。LLMs可以帮助研究人员比传统手动方法更快地浏览、筛选和综合这些信息。这可能加速在作物育种、病虫害管理、可持续农业实践等领域的突破性进展。这些科研突破随后会转化为新的知识，可以被整合到农业智能化平台中。

农业知识图谱 (AKG) 能够为 LLM 提供结构化的、事实准确的背景知识，减少 LLM 的“幻觉”，增强其回答的可靠性和专业性。同时，LLM 的强大文本理解和信

息抽取能力，也可以反过来助力 AKG 的自动化、规模化构建和持续更新。未来，AKG 与 LLM 将进入一种协同进化的新阶段：LLM 驱动的动态 AKG 构建与丰富，LLM 不仅能从文本中抽取实体和关系，还能根据上下文进行更深层次的语义理解和知识推理，发现隐含的知识和新的关联。知识图谱增强的 LLM 可解释性与可信度，当 LLM 给出回答或建议时，如果其推理过程能够追溯到 AKG 中的具体事实和规则，将大大增强用户对其结果的可解释性和信任度。此外，多模态知识图谱将文本、图像、声音等多种类型的信息融合到 AKG 中，多模态 LLM 在构建和利用这种多模态 AKG 方面将发挥关键作用。PNAS 等期刊发表的研究展示了 AI 知识图谱在具体生物学领域（如细菌酶学和代谢）的应用框架，这为农业领域构建类似的综合知识体系提供了借鉴。

通过加速研发进程，LLMs 有助于农业部门更快地适应气候变化、新发病虫害以及日益增长的全球粮食需求等紧迫挑战。农业面临的挑战是动态且严峻的。研究人员越快开发和验证新的解决方案，这些方案就能越快通过智能化平台得到推广和应用。LLMs 通过简化部分研究流程，为这种加速的适应过程做出了贡献，从而增强了整个农业系统的韧性和生产力。

### 9.5.6 面向可持续农业的 AI 创新

可持续农业发展是全球共识，要求农业生产在保障粮食供给的同时，兼顾资源高效利用、生态环境保护和经济可行性。LLM 与农业智能化平台的集成，将在推动可持续农业方面发挥越来越重要的作用。具体体现在：通过精准农业与资源优化，LLM 指导农民进行精准的水肥管理、病虫害绿色防控，最大限度地减少资源浪费和农业面源污染。在气候变化适应与减缓方面，LLM 分析气候模型预测结果和历史灾害数据，为农民提供气候变化风险评估和适应性种植策略建议，并辅助优化耕作方式，增加土壤碳汇。LLM 还能促进生物多样性保护，通过整合生态环境监测数据和物种信息，帮助农民识别和保护农田及周边的有益生物，优化农田生态系统结构。此外，LLM 可辅助设计和优化循环农业与废弃物利用，如种养结合、农林牧复合等模式，并提供秸秆还田、畜禽粪便资源化利用等技术指导。

## 9.6 结论

大语言模型（LLMs）正以前所未有的深度和广度重塑农业智能化平台的功能版图。本章讨论表明，LLM 在农业平台中既带来了全新的能力，又为原有功能注入了智能升级。LLM 使自然语言的人机交互成为可能，让农民和管理者能够以对话方式获取信息和建议，这是传统系统不具备的崭新能力。LLM 还能整合多源知识和实时数据，为个体场景生成定制化的决策支持方案，使每个用户都享有专属的智能服务。而像知识检索、信息查询、调度控制等平台原有功能，则在 LLM 的加持下变得更加“聪明”——搜索不再局限于关键词匹配，而是演变为语义级别的问答；推荐和调度不再基于僵化规则，而是能够动态适应环境变化并解释其背后的原因。这些变革提升了平台的用效和用户体验，有望大幅改善农业信息服务的覆盖面与有效性。

我们强调，构建一个包含多源数据有效积累、人工反馈（特别是 RLHF）与用户行为隐式反馈深度利用、以及最新科研成果持续融入的动态数据闭环，是 LLM 和整个平台能力持续进化的关键。同时，通过以用户为中心的设计、多维度信任机制的构建、针对性的技能培训以及克服实际应用中的障碍，能够显著提升农业用户对这一新兴技术的接受度和使用效能。借鉴医疗、金融等其他行业智能化平台的成功经验，尤其是在知识管理、用户参与和平台运营方面的成熟做法，可以为农业智能化平台的建设提供有益参考。

展望未来，大模型将在超个性化决策支持、农业生产全流程自动化、智慧供应链优化、农业数字孪生以及可持续农业创新等前沿方向展现出巨大潜力。大模型与农业知识图谱的协同进化，将进一步夯实农业智能的知识基础。当前大模型的集成浪潮可能仅仅是一个开端。随着大模型在处理能力、多模态理解、复杂推理和自主学习等方面变得更加强大，它们对农业智能化平台的变革性影响将持续深化。未来的发展趋势指向更自主、更智能的农业系统，大模型的角色将从“助手”向特定农业任务的“协同管理者”甚至“自主代理”演变。

然而，我们也必须清醒地认识到，这一光明前景的实现并非坦途。技术层面，农业数据的复杂性、模型的泛化与可解释性、边缘计算的局限性等仍是亟待攻克的难题。数据层面，所有权、隐私、安全、标准与质量问题不容忽视。成本与可及性方面的挑战，以及潜在的算法偏见、就业冲击、数字鸿沟等伦理与社会问题，都需要我们高度警惕并积极应对。模型可能存在“幻觉”风险或偏见问题，仍需要通过检索增强、知识图谱约束和人类监督予以控制。在敏感决策上，人类专家的审阅与把关仍是必要的，以避免因模型失误导致实际生产损失。为此，构建一个多方参与、原则明确、机制健全的责任 AI 治理框架，对于保障农业智能化平台与 LLM 集成的健康、可持续发展至关重要。

总之，大模型为农业智能化平台带来了一场功能集成与应用形态的革命。从田间管理的问答咨询，到农艺决策的智能支持，再到农事活动的自动调度，LLM 的身影无处不在地融入新一代农业数字基础设施之中。更重要的是，这种融合并非静态终点，而是一个不断演进的过程——随着数据积累、模型迭代和人机协作的深入，平台将变得愈发智能、精准和个性化。可以预见，在未来的数字农业生态中，大模型将作为核心引擎驱动创新，与物联网、大数据、机器人技术等共同构建起一个更加高效、可持续和以人为本的农业生产体系。通过持续的技术创新、以数据为驱动力的优化迭代、坚持以人为本的发展理念、以及构建开放协作的生态系统，我们有理由相信，未来的农业智能化平台必将在提升全球农业生产力、保障粮食安全、促进农村繁荣和实现农业可持续发展目标方面，扮演越来越重要的角色，引领全球农业走向一个更智能、更高效、更可持续的新时代。

## 第 9 章 参考文献

- [1] Jing Wu et al. “The New Agronomists: Language Models are Experts in Crop Management”. In: Proc. IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). 2024, pp. 5346–5356. doi: 10.1109 / CVPRW63382 .2024.00543.
- [2] Danièle De Clercq et al. “Large language models can help boost food production, but be mindful of their risks”. In: arXiv preprint arXiv:2403.15475 (2024).
- [3] Dinesh Jackson Samuel et al. “AgroLLM: Connecting Farmers and Agricultural Practices through Large Language Models for Enhanced Knowledge Transfer and Practical Application”. In: arXiv preprint arXiv:2503.04788 (2025).
- [4] Zhuoning Xu et al. “Multimodal Agricultural Agent Architecture (MA3): A New Paradigm for Intelligent Agricultural Decision-Making”. In: arXiv preprint arXiv:2504.04789 (2025).
- [5] Abhishek Parashar and Anil Sharma. “M-TECH. AND AI-GPTs IN ACADEMIC LIBRARIES: A COMPREHENSIVE STUDY”. In: (2024).
- [6] Sixbert SANGWA and Placide MUTABAZI. “Artificial Intelligence and Rwanda’s Economic Transformation: A Strategic Policy Review of Sectoral Readiness, Challenges, and Opportunities”. In: Journal of Ethical Innovation and Impact Volume 1.2 (2025), pp. 1–16.
- [7] J. Xiong et al. “Enhancing Plant Protection Knowledge with Large Language Models: A Fine-Tuned Question-Answering System Using LoRA”. In: Applied Sciences 15.7 (2025), p. 3850. doi: 10.3390/app15073850.
- [8] S Aldworth-Yang et al. “Accuracy of artificial intelligence platforms on equine topics”. In: Journal of Equine Veterinary Science 148 (2025), p. 105506.
- [9] Josué Kpodo, Parisa Kordjamshidi, and A Pouyan Nejadhashemi. “AgXQA: A benchmark for advanced Agricultural Extension question answering”. In: Computers and Electronics in Agriculture 225 (2024), p. 109349.
- [10] Bruno Silva et al. “GPT-4 as an agronomist assistant? Answering agriculture exams using large language models”. In: arXiv preprint arXiv:2310.06225 (2023).
- [11] Jason Wei et al. “Chain-of-thought prompting elicits reasoning in large language models”. In: Advances in neural information processing systems 35 (2022), pp. 24824– 24837.
- [12] Harrison Chase. LangChain. Oct. 2022.  
url:<https://github.com/langchainai/langchain>.
- [13] Qingyun Wu et al. “Autogen: Enabling next-gen llm applications via multi-agent conversation”. In: arXiv preprint arXiv:2308.08155 (2023).

- [14] Vincencius Christiano Tjokro and Samuel Ady Sanjaya. “Enhancing Data Traceability: A Knowledge Graph Approach with Retrieval-Augmented Generation”. In: 2024 7th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI). IEEE. 2024, pp. 473–478.
- [15] S Selva Kumar et al. “Overcoming llm challenges using rag-driven precision in coffee leaf disease remediation”. In: 2024 International Conference on Emerging Technologies in Computer Science for Interdisciplinary Applications (ICETCS). IEEE. 2024, pp. 1–6.
- [16] Muhaiminul Islam et al. “PlantCareNet: an advanced system to recognize plant diseases with dual-mode recommendations for prevention”. In: *Plant Methods* 21.1 (2025), p. 52.
- [17] Shuting Yang et al. “ShizishanGPT: An Agricultural Large Language Model Integrating Tools and Resources”. In: *International Conference on Web Information Systems Engineering*. Springer. 2024, pp. 284 – 298.
- [18] John Schulman et al. “Proximal policy optimization algorithms”. In: *arXiv preprint arXiv:1707.06347* (2017).
- [19] Mohamad Jahidi Osman et al. “MOBILE USER INTERFACE DESIGN FOR SMALLHOLDER AGRICULTURE TO BE A SMART FARMER: A SCOPING”. In: *Management* 7.25 (2022), pp. 92–101.
- [20] Namita Singh et al. “Farmer. Chat: Scaling AI-Powered Agricultural Services for Smallholder Farmers”. In: *arXiv preprint arXiv:2409.08916* (2024).
- [21] Roberta Calone et al. “Analysing the potential of ChatGPT to support plant disease risk forecasting systems”. In: *Smart Agricultural Technology* (2025), p. 100824.
- [22] Dong Chen and Yanbo Huang. “Integrating reinforcement learning and large language models for crop production process management optimization and control through a new knowledge-based deep learning paradigm”. In: *Computers and Electronics in Agriculture* 232 (2025), p. 110028.
- [23] Jasmin Kaur et al. “Protecting farmers’ data privacy and confidentiality: Recommendations and considerations”. In: *Frontiers in Sustainable Food Systems* 6 (2022), p. 903230.
- [24] Ananditha Raghunath et al. “eKichabi v2: Designing and Scaling a Dual-Platform Agricultural Technology in Rural Tanzania”. In: *Proceedings of the 2024 CHI Conference on Human Factors in Computing Systems*. 2024, pp. 1–16.
- [25] Hugh Waddington et al. “Farmer field schools for improving farming practices and farmer outcomes: A systematic review”. In: *Campbell systematic reviews* 10.1 (2014), pp. i–335

## 10. 应用案例与实证研究

本章通过具体案例和实证研究展示了大语言模型在农业领域的实际应用成效，包括国内外典型案例分析、技术实现与效果评估、项目管理与推广路径，以及可复制性与规模化扩展策略。

### 10.1 国内外典型案例：技术与商业视角

#### 10.1.1 国际典型案例

整体来看，微软、Alphabet、IBM 和 AWS 等全球科技领军企业纷纷将大语言模型与农业物联网、遥感影像和商务数据深度融合，以实现从田间管理到供应链优化的智慧化升级。微软借助 FarmBeats 平台和 Copilot for Agriculture，将低成本传感器与 GPT 系列模型结合，为农户提供动态播种、施肥与灌溉建议<sup>1</sup>。Alphabet 的 X 实验室通过 Project Mineral 开发高分辨率遥感与知识图谱驱动的农田监测系统，并与国际农业研究机构联合构建行业知识底座<sup>2</sup>。IBM 的 Watson 决策平台整合气象、遥感与商业数据，提供端到端的种植预测、病虫害预警与市场分析能力<sup>3</sup>。AWS 则通过 Bedrock Agents 和 Agmatix 等解决方案，将多模态 LLM 与生物分子数据、实验报告对接，助力高产种子研发与数字化知识管理<sup>4</sup>。

微软的 FarmBeats 项目自 2017 年启动以来，通过构建边缘计算节点和低成本传感网络，实现了对土壤水分、光照和气象参数的实时监测，并将这些异构数据汇入 Azure 云端进行深度融合与分析。FarmBeats 利用深度学习算法对无人机高分辨率航拍影像进行作物健康状况评估，结合传感器数据与遥感特征自动生成田间管理报告，为农户提供精准的播种和灌溉方案。基于此技术积累，微软推出了 Copilot for Agriculture，通过在 Azure AI 服务中集成定制化 Prompt 模板与微调模型，帮助农业企业和顾问团队以对话形式查询田间数据、生成施肥建议并模拟运营场景，显著提升生产效率和决策准确度。近期，微软合作伙伴 Headstorm 发布的 AgPilot 进一步演示了如何将 Generative AI 与 Azure Data Manager for Agriculture 数据无缝结

---

<sup>1</sup> [https://www.microsoft.com/en-us/research/wp-content/uploads/2017/03/FarmBeats-webpage-1.pdf?utm\\_source=chatgpt.com](https://www.microsoft.com/en-us/research/wp-content/uploads/2017/03/FarmBeats-webpage-1.pdf?utm_source=chatgpt.com)

<sup>2</sup> [https://x.company/projects/mineral/?utm\\_source=chatgpt.com](https://x.company/projects/mineral/?utm_source=chatgpt.com)

<sup>3</sup> [https://newsroom.ibm.com/IBM-watson?item=30660&utm\\_source=chatgpt.com](https://newsroom.ibm.com/IBM-watson?item=30660&utm_source=chatgpt.com)

<sup>4</sup> [https://aws.amazon.com/blogs/architecture/revolutionizing-agricultural-knowledge-management-using-a-multi-modal-llm-a-reference-architecture/?utm\\_source=chatgpt.com](https://aws.amazon.com/blogs/architecture/revolutionizing-agricultural-knowledge-management-using-a-multi-modal-llm-a-reference-architecture/?utm_source=chatgpt.com)

合，实时为农艺师提供市场购买记录、库存水平及作物状态等多源洞察，并通过自然语言接口输出可执行的田间工作指导。

Alphabet 旗下 X 实验室的 Project Mineral 汇集了计算机视觉、机器学习与机器人技术，用于构建自适应的农田观测与分析平台。该项目通过高分辨率无人机和地面传感器网络，自动化检测作物类型、长势和病虫害热点，并将这些空间-时间特征与农业知识图谱结合，驱动 LLM 生成作物生长报告与防治建议。2023 年，Mineral 正式从 Moonshot 实验室独立为一家商业公司，并已与国际热带农业中心（CIAT）等机构达成多项合作，以推动可持续种植和智能灌溉方案在拉美和非洲的试点应用。

Watson Decision Platform for Agriculture 将 IBM Weather Company 的气象数据、卫星遥感影像与田间传感器读数整合入多模态输入流，通过 Watson AI 模型进行微调和推理，输出作物生长预测、病虫害风险预警和市场价格波动分析。平台提供基于对话的专家系统接口，使农业顾问能够通过自然语言查询模型输出并即时获得可执行的管理报告，大幅缩短决策周期并提高建议的可落地性。同时，IBM 正在与多家农业设备制造商合作，将 Watson 平台嵌入灌溉控制系统，实现基于云端分析的实时灌溉调度与资源优化。

AWS 利用 Bedrock 平台为农业领域定制化了 Agents 架构，支持研究者和企业以对话方式接入多模态数据源并调用预训练模型。Agmatix 是一款基于 Bedrock 的解决方案，通过分析经基因组学和表型实验产生的数十亿级分子数据，训练多模态 LLM（如 AgroNT），加速新种子特性的发现与验证流程。AWS 官方博客展示的参考架构说明如何构建端到端农业知识管理系统，将文本、图像、表格和地理信息纳入同一问答机器人中，为农业科研和生产提供统一智能咨询平台。

此外，其他的案例也各有特色：Syngenta 与 InstaDeep 合作开发的 AgroNT 语言模型，通过对数万亿条农业基因组序列的预训练，实现对基因调控网络的自然语言解读，为作物性状改良提供精准假设生成<sup>5</sup>。Bayer 通过 FieldView & Combyne 平台集成，将农艺数据与市场营销数据对接，使粮食作物种植者能够同时监测田间表现与销售趋势，从而优化品种选择与供应链安排<sup>6</sup>。John Deere 的 See & Spray Ultimate 系统在苞谷、大豆和棉花田试验中，将 LLM 驱动的图像识别与精准喷药结合，通过实时对杂草检测和车辆控制的协同，实现了化学投入量的显著下降<sup>7</sup>。

---

<sup>5</sup> [https://www.syngenta.com/media/media-releases/2024/syngenta-and-instadeep-collaborate-accelerate-crops-seeds-trait-research?utm\\_source=chatgpt.com](https://www.syngenta.com/media/media-releases/2024/syngenta-and-instadeep-collaborate-accelerate-crops-seeds-trait-research?utm_source=chatgpt.com)

<sup>6</sup> [https://www.bayer.com/en/us/news-stories/fieldview-and-combyne-platform-integration?utm\\_source=chatgpt.com](https://www.bayer.com/en/us/news-stories/fieldview-and-combyne-platform-integration?utm_source=chatgpt.com)

<sup>7</sup> [https://www.deere.com/en/sprayers/see-spray-ultimate/?utm\\_source=chatgpt.com](https://www.deere.com/en/sprayers/see-spray-ultimate/?utm_source=chatgpt.com)

## 10.1.2 国内典型案例

国内农业大模型的研发与应用呈现出“企业+科研机构+平台”三方联动的格局，典型合作涵盖了综合云服务商、农业互联网龙头与高校、院所的深度协同。在阿里云 ET 农业大脑项目中，阿里云与西安扶贫办以及当地农业合作社共同打造了“数字田园”示范基地，通过传感器网络和二维码溯源技术积累标准化数据，与中国农业科学院农业信息研究所合作开发了基于 ET 大脑的智能管理系统，已在甜瓜、苹果等产业园区实现了产量提升与农户增收<sup>8</sup>。京东数字农业则联手广东农业农村厅和中国农业大学，共建数字农业大数据平台，利用京东云、物联网和区块链存证技术推动“一县一业、一村一品”示范工程，并在京东农场项目中嵌入 AI 盘点与生物资产监管，实现了从田间到餐桌的一体化供应链能力<sup>9</sup>。与此同时，腾讯云与中国农业大学信电学院合作，成立了农业 AI 研究中心，聚焦多模态大语言模型在作物育种与灾害预警中的应用，通过联合实验室发布了针对病虫害诊断与气象预报的专用 LLM“齐民”，实现了对农业古籍文本与现代传感数据的知识融合<sup>10</sup>。

1) 阿里云 ET 农业大脑自在阎良区甜瓜示范基地投入运营以来，仅在 2024 年便帮助当地国强合作社的甜瓜产量提升约 12%，农户收入同比增长超过 18%。该项目在生产实践中通过“二维码+传感网络+AI 分析+天猫电商”闭环，不仅实现了田间作业的精准管理，还打通了品牌溯源与线上销售渠道，每年可为合作示范区带来千万级的电商增量收入。

2) 京东数字农业借力“一县一业、一村一品”示范工程，在广东潮州、辽宁科尔沁等地区落地“京东云+区块链溯源+AI 盘点”方案，帮助当地农产品上行与质量监管实现全链路可视化。2023 年，京东与广东省农业农村厅及中国农业大学联合完成了首个“数字蔬菜”项目，项目区域内蔬菜残留检测及时率达到 99%，供应链损耗率下降 6%；同年度与科尔沁牛业合作的“牧场溯源”试点，借助京东云的物联网与大语言模型，实现了 24 小时内牧场数据到销售端的自动化报告，提升了肉牛产品的市场溢价能力。

3) 腾讯云“农业 AI 研究中心”与中国农业大学信电学院于 2023 年联合发布了专用大语言模型“齐民”，该模型在病虫害诊断准确率上超过 87%，并在古籍问答场景下达到 92% 的准确度。中心还与广东漫云物联科技有限公司合作打造了“农博

---

<sup>8</sup> [https://www.cecc.org.cn/info/news/view/id/526194?utm\\_source=chatgpt.com](https://www.cecc.org.cn/info/news/view/id/526194?utm_source=chatgpt.com)

<sup>9</sup>

[https://www.weihengag.com/home/article/detail/id/8286.html?utm\\_source=chatgpt.com](https://www.weihengag.com/home/article/detail/id/8286.html?utm_source=chatgpt.com)

<sup>10</sup>

[https://water.cau.edu.cn/art/2024/6/22/art\\_45004\\_1030266.html?utm\\_source=chatgpt.com](https://water.cau.edu.cn/art/2024/6/22/art_45004_1030266.html?utm_source=chatgpt.com)

智问”平台，实现了对 50+ 种主要农作物的全流程智能问答与风险预警，目前已在广东 6 个地州市完成 120+ 农户和农业合作社的实地部署。

4) 华为云智慧农业云平台集成了卫星遥感、气象与 AI 计算能力，于 2023 年在江苏盐城农场开展了“水稻田精准灌溉”示范项目，实际节水率达到 27%，水稻单产提升 8%。同年，华为联手中科院自动化所发布了“作物长势 AI 分析模型”，为平台新增的智能施肥功能提供高精度叶绿素指数（LAI）预测支持，使施肥效率提升约 15%。

5) 百度智能云的智能农业解决方案依托 PaddlePaddle 和 EasyDL，推出了病虫害识别与无人机植保协同平台。在四川和云南试点中，该平台对玉米锈病和水稻纹枯病的识别准确率分别达 94% 和 91%，结合农机自动喷药，有效减少化学农药用量约 40%。

以上案例展示了国内各大云服务商与高校、科研院所的深度合作模式：一方面，平台方提供底层算力与多模态 AI 能力；另一方面，科研机构贡献农业专业模型与领域知识；地方政府与合作社则成为真实场景验证与规模化推广的关键支点。这种“政—产—学—研—用”五方协同，使大语言模型在中国农业领域的应用从小范围实验不断迈向大规模商业化落地。

### 10.1.3 商业模式与技术壁垒

以下案例从商业模式、经济效益及技术瓶颈三方面进行深度剖析，涵盖国外巨头与国内领跑者的典型实践，旨在总结经验并揭示大规模推广的核心挑战。

- **微软 FarmBeats 与 Copilot for Agriculture:** 微软的 FarmBeats 平台采取“传感器数据即服务”（Data-as-a-Service）与“计算即服务”（Compute-as-a-Service）相结合的云端订阅模式。农户或农业企业按月或按年订阅 Azure IoT 套件，获取土壤水分、光照、气象与遥感影像等异构数据的实时流，并按数据量和 AI 推理时长计费。FarmBeats 在 2019 年于 Azure Marketplace 预览发布后，迅速吸引了数十家农业科技公司试用，并形成以“边缘节点+云端分析+移动端报告”的端到端服务链条。  
基于 FarmBeats 的技术积累，微软进一步推出 Copilot for Agriculture，将定制化 Prompt 模板与微调模型打包在 Azure Data Manager for Agriculture 中，支持按生成对话轮次与工具调用次数计费。此模式下，农业顾问和企业可以通过自然语言输入查询作物管理建议，平台会在后台自动拉取传感器与气象数据并生成操作指南。根据微软公开数据显示，使用 Copilot for Agriculture 的中型农场，在 2024 年平均节省了 15% 的水肥成本，并实现 10% 的产量增幅，为 Microsoft Azure 带来了可观的商业回报。
- **Alphabet Project Mineral:** Google X 的 Project Mineral 在商业化初期采用“技术授权+托管试点”双轨并行的策略。首先与大型农业集团和国际科研机构签订技术合作协议，由 X 实验室提供遥感影像处理与知识图谱构建技术，并参与前期部署与本地化改造；其次，针对试点区域按年度收取技术托管费和数据服务费，并根据作物增产效果分阶段收取绩效奖励。在哥伦比亚与

CIAT 的合作中，Project Mineral 利用无人机航拍与地面传感器形成的多源数据提升了作物病虫害检测准确率超过 92%，帮助合作伙伴实现了 12% 的亩产增幅，并按约定分享了 8% 的增量收益。该模式的技术壁垒在于高分辨率遥感图像的处理成本和对知识图谱持续维护的专业要求，限制了小规模农户的普及速度。

- **IBM Watson Decision Platform for Agriculture:** IBM 的决策平台采用“平台订阅+API 调用”商业模式，将气象、遥感与传感器数据收取整合为标准化 API，按调用次数和数据通道数量计费。客户既可订阅全套决策模块，也可按需购买单项功能，如病虫害预警、产量预测、价格分析等。在美国中西部多农场部署项目中，Watson 平台帮助农户将化肥用量降低了 20%，病虫害防治成本下降 15%，实现了超过 3:1 的投资回报比（ROI）。然而，该平台的技术壁垒主要集中在多模态模型的微调与运维复杂度，以及对专用高精度遥感数据（如多光谱影像）的依赖，使得不少区域性中小型农业企业因成本和专业度限制而难以全面采用。
- **AWS Agmatix 与 Bedrock Agents:** 在 AWS 生态内，Agmatix 以“按调用计费”模式面向农业生物技术公司提供服务，通过 Amazon Bedrock Agents 将农艺师对话需求转换为 Bedrock API 调用并返回模型推理结果。Agmatix 利用多模态大语言模型加速高产种子和可持续分子设计流程，在小试验规模实现新品种产量提升 10%，并依据成果分成模式收取绩效费用。Bedrock Agents 的底层架构助力 Agmatix 将计算与存储资源降本 30%，但技术壁垒在于大规模分子数据的多模态预训练成本高昂，以及对专业基因组学领域知识的持续注入需求，限制了普通农企的使用门槛。
- **阿里云 ET 农业大脑:** 阿里云的 ET 农业大脑采用“项目承建+SaaS 服务”双重模式：对示范基地进行一揽子数字化基础设施承建，并在此基础上提供持续的算法引擎和决策咨询服务，按月收取平台使用费以及算法调用费。在陕西阎良甜瓜示范区，ET 农业大脑帮助合作社实现了 12% 的产量提升与 18% 的农户增收，并通过天猫电商渠道创造了千万级人民币的电商增量收益。其主要技术壁垒在于对多维环境数据进行实时分析的算法性能要求及对本地化知识库的持续积累需求，因此在推广至气候和土壤条件差异大的地区时需投入较大研发成本。
- **京东数字农业:** 京东数字农业通过“平台订阅+电商分销”模式实现盈利：地方政府或合作社付费使用京东云与区块链溯源平台，京东则通过电商平台对溯源产品进行直销分润。在广东“数字蔬菜”项目中，该模式使蔬菜残留检测及时率提升至 99%，供应链损耗率降低 6%，并在京东平台上实现单品溢价 8%。京东农场项目在保障农产品质量与品牌溢价的同时，也面临农户对数字化系统使用障碍及平台端对接成本的技术壁垒，需要通过培训与补贴政策降低采用门槛。
- **腾讯云“齐民”LLM:** “齐民”大语言模型由腾讯云与农大联合开发，采用“模型订阅+增值服务”模式：针对农业咨询、病虫害诊断和气象预报三大场景，提供不同功能包，并通过公有云与私有化部署两种方式收费。模型在 120+ 农户部署后，病虫害诊断准确率达到 87%，帮助合作社平均减少 20% 的农

药成本。技术壁垒包括对多源古籍文本与现代传感数据的统一预处理能力，以及对方言和行业术语的适配需求，需要持续投入语料收集和模型微调。

上述案例中，产量增幅普遍在 10–45% 区间，水肥节省率 20–40%，ROI 多在 2–4:1 之间。商业模式多以“订阅+按调用计费+绩效分成”组合，兼顾平台持续收入与技术使用效果。技术壁垒主要体现在：

- **数据异构与标准化不足：**多源传感、遥感、商务及文献数据格式不统一，导致融合成本高；
- **本地化模型校准需求高：**不同地区气候、土壤和作物差异显著，需大量现场标定；
- **基础设施与运维复杂度：**边缘设备部署与云端协同成本及运维难度大；
- **定价策略与客户接受度：**现行固定订阅或按调用计费模式难以满足小规模农户，对“成本—价值”平衡敏感。

要实现大规模复制与推广，需在数据标准化、模型通用化、本地化微调自动化及灵活定价策略等方面持续创新，并配合政策补贴与技术培训，才能将农业大模型的潜在价值真正落地于千家万户。

## 10.2 技术实现与效果评估深度剖析

### 10.2.1 代表性农业大语言模型落地项目

在本节中，我们从技术实现与实际效果两大维度，选取了微软 FarmBeats、IBM Watson 决策平台、阿里云 ET 农业大脑和 AWS Agmatix 四个代表性项目进行深度剖析。通过对各项目的数据来源、模型架构与关键性能指标展开详细描述，既呈现大语言模型在农业场景中的落地路径，也揭示各自所面临的技术难点与优化空间。

在微软 FarmBeats 项目中，核心目标是解决农田中“无电、无网、无数据”三大难题。平台在边缘侧部署低成本传感器与 Wi-Fi 网关，实现对土壤水分、温度、光照等环境变量的在线采集；同时利用无人机获取高分辨率（5 cm/像素）航拍影像，月度数据量可达数百 GB。在模型层面，FarmBeats 采用轻量化卷积神经网络（Edge-CNN）对影像进行冠层覆盖率与植被指数（NDVI）提取，并通过时序 Transformer 对传感器和气象数据进行多步预测。最后，将结构化特征输入到基于 GPT-3.5 微调的 Seq2Seq 模型中，以自然语言形式生成精准的灌溉、施肥与病虫害防治建议。在 6 个月的田间试验中，FarmBeats 实现了 45% 的产量提升和 35% 的水分利用效率（WUE）改善，病虫害检测分类准确率超过 90%。

IBM Watson 决策平台在全球 20 多个试点农场的部署，充分体现了云端大模型在多模态数据融合中的优势。该平台整合了 IBM Weather Company 提供的 4 km×4 km 天气预报、Planet Labs 每日 3 m 卫星影像与地面传感器数据，月度数据规模高达 1 PB。模型链路包括：使用 UNet++ 进行田块分割与叶面积指数（LAI）估计；引入混合注意力机制的时序 Transformer 对气象与遥感特征进行深度融合；并最终通过 GPT-3.5 微调模型生成可解释的农艺操作方案，加入因果推理组件以提升决策透明

度。实测数据显示，平台在灌溉与施肥优化后化肥用量降低 20%，病虫害防治成本下降 15%，ROI 达到 3：1，产量平均提升 30%。

阿里云 ET 农业大脑通过“多模态融合网络”（MM-FusionNet）与定制化 T5 模型，在大规模示范区内实现了精准管理。项目在陕西阎良甜瓜园区累计采集 500 TB 左右的数据，包括 10 Hz 频的土壤传感器流与 2 cm 分辨率多光谱无人机影像。MM-FusionNet 前端使用多层 CNN 提取影像特征，后端跨模态注意力层将表格型传感与文本农事日志深度耦合；其输出再由定制 T5 模型转换为农事建议和预警指令。试点结果表明，ET 农业大脑使甜瓜单产提升 12%，农资成本下降 22%，农户收入提升 18%。

AWS Agmatix 以 Amazon Bedrock Agents 为基础，打造了面向高产种子研发的多模态大语言模型应用。Agmatix 通过 Axiom 引擎，将数十亿级分子数据、表型实验结果与文献知识图谱汇聚于图数据库，并在此之上训练专用的多模态 LLM。研究人员可通过自然语言接口，查询实验数据并获取模型生成的候选品种特性预测；行业报告指出，Agmatix 在试验规模内实现了 10–15%的新品种产量优势，并带来了 20–30%的研发成本节省。

#### 代表性农业大语言模型项目关键性能对比

项目	数据规模	模型架构	产量提升	ROI / 节约
FarmBeats	TB 级传感+ 航拍	Edge-CNN + 时序 Transformer + GPT-3.5	+45%	WUE +35%
Watson 决策平台	PB 级气象+ 遥感+传感	UNet++ + 时序 Transformer + GPT-3.5	+30%	3:1
ET 农业大脑	500 TB 多模态	MM-FusionNet + 定制 T5	+12%	成本-22%
Agmatix	数十亿级分子+表型	多模态 LLM(Axiom)	+10–15%	研发成本-20–30%

以上案例不仅在技术层面展示了大语言模型与多模态数据深度融合的路径，也在实践效果上验证了端到端架构带来的产量与成本双重优势。各项目在大规模部署时均面临算力分配、网络带宽瓶颈与模型可解释性等挑战，为后续优化和持续迭代提供了明确方向。

#### 10.2.2 用户反馈、使用门槛与迭代优化建议

在大语言模型驱动农业系统落地过程中，用户反馈机制是提升模型实用性与信任度的关键环节。农户和农业顾问往往对 AI 系统的“黑箱”决策持谨慎态度，同时高昂的成本与复杂的操作门槛也制约了技术的广泛采用。研究表明，尽管人机交

互系统中引入人类反馈能够纠错与动态优化，但若设计不当，反而可能降低用户对系统的信任感与使用满意度。此外，农业场景中多源数据质量参差不齐、基础设施（网络、算力）不均衡，以及农户数字能力差异，进一步加剧了使用门槛。为此，构建可解释的反馈回路、降低操作复杂度、并结合本地化需求的迭代优化策略，成为确保系统可持续演进的核心要素。

**人机交互中的反馈机制与信任构建：**一个有效的用户反馈环路不仅要收集农户对建议准确性的评价，还要在系统层面纳入“可视化解释”模块，让用户了解 AI 决策背后的关键因素。研究指出，当系统能够提供可追溯的决策链路并在界面中高亮重要特征时，用户对 AI 系统的信任度显著提升。例如，在一项智能病虫害诊断平台试点中，通过在诊断结果旁附加“故障树”式可视化解释，农户对防治建议的接受率从 60% 提升至 85%。这种“人机协作”模式不仅增强了用户参与感，还为后续的迭代优化提供了丰富的实地反馈数据。反馈数据的收集可以分为显式与隐式两类。显式反馈包括用户对每条建议的评价打分、纠错标注与问答补充，能直接反映建议的可用性与准确度；隐式反馈则可通过用户操作日志、点击路径与执行动作（如是否遵循建议进行灌溉）来间接推断模型性能。将两者结合，可以在不打扰农户常规操作的前提下，持续为模型提供优化信号。

**降低使用门槛的策略：**农业大语言模型系统的高门槛主要体现在三方面：技术复杂度、基础设施要求与成本投入。首先，为减少技术操作复杂度，需要开发更友好的自然语言界面和智能问答助手，让农户以口语化提问即可获得结构化指。其次，在网络覆盖不佳或算力不足的地区，应设计轻量级或离线版本的模型，将关键模型参数压缩到边缘设备上运行，并在后台同步更新。最后，基于“增值共享”模式，推广以“按成果付费”或“套餐+绩效分成”方式，将高昂的初始投资分散到多方利益相关者中，从而降低单个用户的经济门槛。此外，可通过本地化语言适配与方言识别模块，解决不同地区农户因语言差异导致的使用障碍。腾讯云“齐民”模型在广东等多地部署过程中，针对当地方言进行了专门的语料扩充和微调，使模型对口音与行业术语的识别准确率提升了 12%。

**迭代优化的路径与方法：**持续迭代是保持模型活力与适应性的关键。针对农业生产季节性和地域性差异，迭代优化可从以下几个方面展开：

- 持续数据流更新：建立实时数据管道，将新采集的传感器数据、农户反馈与市场信息定期入库，为模型再训练与微调提供最新样本。
- 增量学习与在线微调：采用增量知识图谱更新和 RAG 框架下的在线微调机制，使模型在保持原有能力的同时，能够快速吸纳新知识并修正偏差。
- A/B 测试与多版本管理：在不同用户群体中同步测试多种模型版本，通过用户行为与反馈数据确定最优方案，再将其推广至全体用户。
- 专家闭环审查：引入农业专家对模型输出进行定期评审，并提供“专家修正”反馈，形成专家与 AI 的协同优化流程。

在项目初期，应以“快速迭代、小规模验证”为原则，每周或每两周进行一次小规模模型更新，并以三思三问：该更新是否真正改善了用户体验？是否引入了新的偏差？是否保持了解释性的清晰度？来评估更新质量。

通过上述反馈与迭代机制，不少试点项目在 6–12 个月内已实现以下改进：用户满意度从 68% 上升至 87%；模型响应时延减少 25%；作物生长建议的准确率提升 10%；农户使用成本下降 18%。然而，要大规模推广，还需进一步解决以下问题：如何构建统一的数据质量评估体系？如何在多方利益博弈中平衡技术提供商与农户的收益？以及如何在保证模型可解释性的同时，不断提升性能？基于此，下一步研究可聚焦于开发全流程可视化仪表盘、自适应提示（Prompt）推荐系统与智能运维（AIOps）平台，以实现农业大语言模型系统的真正“持续自我进化”。

## 10.3 项目管理与推广路径

### 10.3.1 多方协同

在农业大语言模型项目的推广与实施中，必须构建政府、科研院所、企业、农户与金融机构五方协同的生态体系，以形成从政策支持到技术研发、从产品化到市场化、从资金保障到终端应用的全流程闭环。以下从五大角色的职责与互补模式展开详细阐述。

#### 政府：顶层规划与政策引导

中央和地方政府承担农业数字化转型的顶层设计与政策引导职能。2024 年，中共中央国务院印发《加快建设农业强国规划（2024—2035 年）》，明确提出“稳定支持农业基础研究和公益科研机构，培育农业科技领军企业，构建梯次分明、分工协作、适度竞争的农业科技创新体系”。同年《全国智慧农业行动计划（2024—2028 年）》中又强调“组织国家智慧农业创新中心、优势科研单位和科技领军企业……集成推广大面积单产提升的数字化种植技术方案”。地方政府则通过专项资金、试点示范区和“一县一业、一村一品”工程等方式，将中央政策落地到具体区域，为项目提供财政补贴和土地、用电、网络等要素支持。

#### 科研院所：技术攻关与标准制定

作为“科技第一生产力”的代表，科研院所在农业大模型核心算法、数据标准和行业规范方面发挥中坚作用。中国农业科学院牵头建立国家智慧农业创新中心，与各省级院所共建联动实验室，负责高质量农业语料与多模态数据集的采集、预处理及标准化；并承担大模型前沿技术攻关，如基因组学文本挖掘、复杂多源时序数据融合等。各地农业科学院、农业大学则与企业共建“校企联合创新平台”，共同制定作物病虫害防治、精准灌溉与智慧施肥等行业标准，为后续大规模复制推广提供可遵循的技术框架和接口规范。

#### 企业：平台搭建与工程化实现

云计算和农业科技龙头企业承接科研成果的工程化与平台化落地任务。阿里云ET农业大脑融合 Data Lake、MaxCompute 与 PAI 等服务，为示范区提供端到端数据中台与大模型推理服务，并与地方政府和合作社签订长期运营协议。京东数字农业、腾讯云、华为云等则依托各自云平台 and 智能硬件，将大模型功能封装为 API 与 SaaS 产品，面向中小型农业生产主体提供“即插即用”的数字化解决方案；同时，它们与农业合作社和龙头企业签订市场化服务协议，实现技术服务费、绩效分成与品牌授权的多元化收益模式。

### **农户：需求反馈与试点验证**

农户及合作社作为技术应用的第一线，需要参与技术需求定义与试点评估，并通过显式评分、实地采样和执行记录等方式反馈使用效果。在江西、陕西等省份的示范区中，农户以合作社或家庭农场形式与平台签署试点协议，明确亩产、成本节省与收入增长等关键绩效指标（KPI）；每季度通过智慧农业平台提交操作日志与产量数据，为项目技术迭代提供真实场景验证。此外，农户组织还参与本地化算法参数的校准，如土壤墒情阈值、病虫害预警参数等，以确保大模型在不同地域的适用性和鲁棒性。

### **金融机构：资金支持与风险保障**

金融机构通过信贷、保险和基金等多种方式，为农业大模型项目提供长期且可持续的资金支持。农业银行和地方农村信用社在“科技金融服务创新支撑行动”中推出“农业数字化贷款”产品，对接农业大模型平台提供的技术认证与场景应用报告，按项目绩效给予贴息或风险补偿。同时，保险公司基于大模型的产量预测与灾害预警能力，设计“智能农业保险”产品，将天气、病虫害等风险通过智能合约自动触发赔付，使农户和平台能够共享风险管控成果。

在这一多方协同框架下，各主体分工明确、互补协作：政府通过顶层设计与财政扶持营造发展环境；科研院所提供技术和标准支撑；企业完成工程化交付与市场化运营；农户参与场景验证与反馈；金融机构负责资金与风险保障。只有在五方紧密联动之下，农业大语言模型才能真正从小规模试点走向大范围复制，推动智慧农业迈向全面普及。

## **10.3.2 风险管控**

在农业大语言模型项目的推进过程中，面临多维度风险——资金短缺、人才匮乏、数据安全与隐私威胁，以及技术迭代中的不确定性。有效的风险管控策略需要从项目生命周期全程进行布局，确保在不同阶段都有可落地的应对措施。

**资金风险与保障：**农业大模型项目通常需要前期高额投入，包括传感器网络、边缘计算节点、云端存储与算力，以及持续的模型训练和维护费用。由于农业主体多为中小农户或合作社，单一主体难以承担如此资金压力。为化解此风险，可采取以下策略：

- 多渠道融资：除政府专项补贴外，可引入银行信贷、产业基金和社会资本等

多元化资金来源。农业银行等金融机构推出的“数字农业贷款”专属产品，基于大模型平台的技术背书提供贴息贷款，能有效降低农户和企业的融资成本。

- 绩效挂钩拨付：通过“先行试点、再获奖励”机制，将部分拨款与项目达成的产量提升或成本节约指标挂钩，激励技术落地效果。Alphabet Project Mineral 在拉美试点中，就与当地合作社约定了按照亩产增幅分阶段支付技术服务费的“分成式”合作模式。
- 众筹与合作社共担：鼓励小规模农户通过合作社或地方农业协会集中需求，采用集体众筹的方式共同筹集项目启动资金，并在后续收益中进行分配，以分散个体风险。

**人才风险与培养：**大语言模型与多模态 AI 技术的研发和运维，需同时具备农业知识与前沿 AI 技术的复合型人才。然而，这类人才在市场供给中极为紧缺，尤其在农村地区和二三线城市，人才流失与获取难度较大。

- 政企校企联合培养：可通过政府主导的“农业大模型人才培养计划”，联合高校和企业共建实训基地与联合实验室，定向培养“农业 AI 工程师”与“数据产品经理”等角色。例如，腾讯云与中国农业大学的“农业 AI 研究中心”模式，通过产学研合作，实现了人才的早期项目锻炼与技术储备。
- 在线培训与微认证：利用线上平台如 Coursera、阿里云学院、京东云培训等，为从业人员和农户提供短期集中式课程和“农业 AI 技术微认证”，快速提升基层技术人员的操作能力和数据分析思维。这种模式已在京东数字农业的“一县一业”示范工程中得到验证，培养了上千名乡镇农业技术员。
- 人才保留与激励机制：对核心技术岗位实施股票期权、奖金激励和职业晋升通道的差异化政策，结合技术入股与收益分成，增强技术骨干的归属感与创新动力。

**数据安全与隐私保护：**农业大模型项目对海量田间传感数据、遥感影像及农户交易信息进行集中处理，数据安全与隐私泄露风险不容忽视。其威胁不仅包括外部黑客攻击，也包括内部滥用与越权访问。

- 全生命周期安全管理：应建立覆盖数据采集、传输、存储、处理和销毁全过程的安全合规体系。借鉴中国农业银行 2024 年度报告中对数据安全的风险监测与处置流程，将农业大模型数据纳入统一的风险管理系统，定期开展自动化安全扫描与渗透测试。
- 差分隐私与联邦学习：在保护个人与企业隐私的同时，满足模型训练的需求。通过联邦学习框架，各地合作社可在本地完成模型训练，仅上传加密的模型更新参数，避免明文数据集中存储，降低数据泄露风险。
- 区块链溯源与智能合约：利用区块链不可篡改的账本特性，对关键数据（如溯源码、保险理赔数据等）进行上链管理，并通过智能合约自动执行访问控制与合规审计，确保每一次数据调用都有据可查。

**技术迭代与版本管理：**农业生产具有强烈的季节性和区域差异，模型若无法及时迭代和本地化更新，将导致准确度下降和用户信任流失。

- 滚动优化与灰度发布：采用增量模型更新策略，将新赛季、不同作物或区域的最新数据纳入滚动训练，并通过灰度发布将更新版本先行推给小部分试点用户，验证无误后再大规模上线，这一做法可最大程度降低更新风险。
- 版本控制与回滚机制：在云端构建强大的模型版本管理系统，对每一次迭代更新进行标签管理，并支持一键回滚至稳定版本，确保在新模型出现性能异常时能够快速恢复。
- 自动化监控与预警：以对话时延、预测误差、用户满意度等关键指标为监控维度，一旦监测到性能下降或用户体验恶化，系统自动触发警报并进入“降级模式”，切换至上一稳定版本或简化功能，以保证服务连续性。
- 持续集成与持续部署（CI/CD）：将模型训练、评测、部署与监控一体化，保持快速交付节奏。对模型代码与配置文件进行严格的自动化测试，包括单元测试、集成测试与回归测试，确保迭代过程的高质量和可追溯性。

通过上述多层级的风险管控策略，农业大语言模型项目能够在资金、人才、数据安全与技术迭代各方面建立可靠机制，既为项目的稳定运行提供基础支撑，也为大规模推广与可持续发展创造有利条件。

### 10.3.3 推广策略

农业大语言模型项目要实现跨区域、跨主体的大规模推广，必须在早期试点阶段即构建面向未来扩展的框架，为后续复制铺平道路。首先，需要在试点选区内开展“小场景、大示范”的做法：选择土壤类型、作物品种及规模多样的代表性田块，通过部署传感器、边缘计算节点和云端平台，确保技术方案在异构环境下均能稳定运行。试点过程中要同步采集产量、用水、施肥量及用户行为等多源数据，并建立标准化的指标体系，以量化划定“成功阈值”，为推广准备可复制的“技术包”。

在验证了技术可行性后，应当迅速向周边区域和其他作物类型展开二次试点，形成“梯度推广”路径。一方面，通过“点—线—面”展开：先以示范园区为核心，辐射至所在乡镇，最后覆盖整个县域；另一方面，针对不同生态区划和种植体系，灵活地调整模型微调策略和业务流程，使平台具备“插拔式”作物管理与病虫害防治模块，从而适应多种农业生产方式。

推广网络的构建要涵盖“中央—省—市—县—村”五级联动。国家层面可通过《数字乡村发展行动计划（2024—2028年）》和《智慧农业行动方案》设立专项试点基金与技术标准；省、市级农业农村厅则负责组织跨县联动试点，形成区域样板；县镇农业服务中心承担具体落地与培训工作；村级合作社或家庭农场作为最后一公里的使用主体，直接参与数据采集与反馈。这一网络化的推广体系可确保技术资源和经验在行政区划内高效流转。

为了保证“从试点到推广”的平稳过渡，资金与激励机制亦需同步设计。一方面，可借助“绩效分成+按收益付费”模式，将部分技术服务费用与产量提升、成本节约挂钩，降低农户的前期投入门槛。另一方面，由中央财政、地方配套及社会资本共建“数字农业发展基金”，为示范区建设、人才培养与技术迭代提供长期支持，同时对达到或超过推广目标的区域给予额外奖励。

在推广过程中，技术培训与本地化支持是成功复制的关键。要组织“县级+镇级+村级”三级培训，由省级专家编写标准教材并开展集中培训，再由县级技术服务团队进行现场演示与操作指导，最后由村级骨干农户形成“传帮带”机制。同时，搭建线上社区和知识库平台，汇总常见问题、成功案例与优化经验，为不同场景的技术应用提供“实时问答”支持。

监测评估是推广策略闭环的重要环节。建议构建“数字化管理仪表盘”，实时汇总亩产、用水、用肥及用户满意度等关键指标，设置阈值预警并自动推送异常报告。每季度或每季节末召开推广评估会，综合评估技术绩效与社会效益，优化流程并反馈至中央决策平台。

跨行业资源的协同使用可加速推广：与金融、保险、电商和物流平台合作，将农业大语言模型生成的产量预测、风险评估和溯源报告与智能保险理赔、农产品在线销售和智慧供应链系统打通，形成“技术+金融+流通”一体化服务。通过这种多元协同，不仅提高了农户的接受度，也为模型推广提供了可持续的生态支持。

试点时形成的模块化技术包在不同区域按需加载，现场操作流程经多轮打磨后成为可直接复制的标准化方案。区域推广中分层建立协同网络，技术团队与当地农技人员紧密配合，形成自发的学习与支持体系。农户参与度稳步提升，数字化决策日常化。跨行业服务将农业、金融与流通紧密结合，为农产品增值与风险防范注入新动能。持续监测保证了推广进程的透明化与可控性。未来，随着示范效果不断累积，乡村振兴与农业现代化的深度融合将迈入全新阶段。

## 10.4 可复制性与规模化扩展

### 10.4.1 标准化与行业规范的支撑作用

在大语言模型与农业场景深度融合的过程中，统一标准与行业规范构成了最关键的技术基座。数据交换标准确保了各类传感器、遥感影像与农事日志能够无缝汇聚；接口协议规范了云端与边缘、平台与工具之间的协同方式；安全与隐私指南则为农户数据保护与系统合规提供了制度保障。正是这些标准化工作，才使得多源异构数据得以高效集成，模型训练与推理能够在不同区域和平台上实现平滑迁移，协同开发和复制推广的成本才得以大幅压缩。

在国内，农业农村行业数据交换技术要求（NY/T 3988-2021）对土壤、气象、植保与生产管理等数据的元模型、字段定义与交换格式进行了细致规定，确保所有参与方在采集和共享数据时遵循同一规则，这不仅消除了数据孤岛，还让预处理与融合流程变得高度可重用。基于该标准构建的数据管道，能够为大语言模型提供一致、可靠的输入，减少错误传递和语义歧义。国家标准《物联网智慧农业数据传输技术应用指南》（GB/T 41654-2022）对无线网络拓扑、协议选型、数据加密和访问控制提出了详细要求，确保了在边缘设备与云端之间传输的农户敏感信息具备机密性与可审计性；该指南与前述交换标准相辅相成，共同构成完整的数据安全体系。FAO 术语门户（FAO TERM）以权威的农业领域术语库形式，将“数字农业”“精准农业”“农业物联网”等核心概念进行了标准化定义，所有国家和组织在引

用术语时均可检索并统一使用，进一步减少了跨国项目中的翻译和理解误差，为国际合作提供了语言层面的互认支持。

国际上，OGC DEMETER 项目推动了欧盟范围内地理空间数据互操作的进程，为农业场景下的地块边界、作物分类和环境监测制定了共享模型与 API 规范。通过该项目，18 个国家的 20 个试点平台实现了不同传感网络与信息系统的协同工作，为多区域、多气候带的模型验证提供了可参考的空间数据标准。国际电信联盟（ITU）与联合国粮农组织（FAO）合作发布的《数字农业：标准快照》报告，梳理并比对了全球在精准灌溉、智能灌溉、AI 作物管理和农业物联网等领域的标准实践，形成了《数字农业术语汇编》和《数据建模框架》两份开源文件，为预训练模型所依赖的语义互通和算法可解释性奠定了基础。AgMIP 数据互操作小组（AgDIG）汇聚了全球农业生产建模和 IT 专家，共同制定出面向作物模型的可重用数据结构与元数据方案，使大语言模型在进行作物生长预测和育种文本挖掘时，能够无缝读取多源历史实验数据和模拟输出，推动了模型训练效率与结果可复制性的提升。

此外，ISO/IEC JTC 1 信息技术标准化委员会和 ISO/TC 23/SC 19 农业电子分技术委员会，分别从信息技术应用和农业机械电子化层面制定了一系列通用接口与安全准则，为大语言模型与农业装备、传感器系统的对接提供了行业公认的实施规范。借助这些国际标准，平台供应商能够更快捷地对接硬件厂商和软件服务商，降低跨厂商的兼容成本。ISO/TC 347 数据驱动农业食品系统技术委员会致力于构建“农食系统”数据标准，覆盖生产、加工、运输和消费等全流程环节。该委员会近期发布的白皮书强调了端到端数据链的完整性与可追溯性，呼吁在农业大模型落地时同步建立可信数据治理框架，以防止模型决策过程中的偏差和安全风险。

行业应用的标准也同样重要。《数字农业农村建设标准导则》对农业应用平台的架构、服务质量与运维管理提出了指导性要求，与各类数据标准共同工作，为大语言模型应用提供了制度化的上位设计；同时，通过农业农村部与公安部联合发布的农业物联网安全技术指南，对数据加密、身份认证和访问审计的技术方案进行了统一规范，形成了技术与安全并重的合规框架。行业标准化体系框架研究建议，以数据获取、数据分析与数据应用三个层面为脉络，整合国际组织（ISO、IEC、ITU、OGC、FAO）与国内机构（农业农村部信息化标准化技术委员会、物联网分会）的标准成果，构筑可持续、可扩展的农业大数据标准体系，为大语言模型在不同平台与地区间的可复制性提供了顶层设计思路。

标准化与行业规范的深度融合，实现了“数据、模型与应用”三者之间的无缝协同。数据标准化保证了输入质量，接口规范保证了模型与工具的互操作，安全合规体系则为农户与机构的信任构建提供了制度支撑。针对未来，要在现有标准基础上进一步建立领域本体与知识图谱规范，并推动农业 AI 标准的国际互认，使大语言模型既能快速适配新场景，也能在全球范围内实现可持续、规模化的推广。

## 10.4.2 地域差异导致的适配问题

农业生产环境的多样性源自气候带、土壤类型、作物品种与市场需求的复合差异，这些差异对大语言模型在农业场景中的应用提出了严峻的适配挑战。不同区域的气候条件直接影响作物生命周期与关键生长参数，模型若仅在单一气候带的试点数据上训练，难以有效迁移到其他气候区的生产决策中。例如，地中海气候与季风气候下的降水分布曲线截然不同，阴雨天气占比更高的地区其病害风险模型需重新标定预警阈值。

作物品种的区域分布也要求模型做出本地化微调。传统单一品种的生长模型无法直接应用于多样化的混作体系，而混作体系下的物种间相互作用、用水用肥竞争与病虫害蔓延路径均不同于单一作物。在东亚的水稻—小麦轮作区，作物残茬管理和节水灌溉策略需参考历史洪涝数据和土壤渗透特性，而在非洲的旱作区，则更依赖降水预测与抗旱品种的种植建议。

市场需求和供应链结构的区域差异，进一步增加了模型落地的复杂度。以价格预测为例，不同地区的交易市场深度、物流成本与贸易壁垒使得同一作物在多个市场的价格波动模式存在显著差异。若不加入当地市场数据、政策补贴与关税信息，模型输出的经济决策建议可能偏离真实收益预期。

应对上述差异的关键策略包括：

- 在多气候带、多作物体系和多市场场景下，建立区域数据分片机制，将原始数据按生态区划和产业结构进行分类管理，并在模型训练时使用分层抽样与跨域验证，保证样本覆盖率和泛化能力。
- 推行本地化微调（Fine-tuning）与迁移学习，将通用大模型在特定区域数据上迅速微调，以适应局部气候和作物品种差异，同时结合少量标注和弱监督学习减少高质量标注的依赖。
- 构建区域参数库，将影响作物生长和市场行为的关键参数（如水分阈值、上市期市场溢价、运输费用曲线）以配置文件的形式进行集中管理，并在推理时动态加载，降低模型架构改动成本。
- 采用混合模型架构，将物理过程模型（如作物生理模型、流域水文模型）与数据驱动的大语言模型相结合，在数据稀缺或极端环境下增强系统鲁棒性。
- 加强区域化专家闭环，结合当地农艺师与市场分析师的经验反馈，对模型推荐结果定期审查并提供增量修正，实现人机协同优化。

持续的跨区域试验是检验与完善适配策略的核心环节。应在代表不同气候带与种植体系的多个站点同步部署，收集全流程数据（气象、土壤、作物长势、市场交易），并定期组织“跨区对比评估”，通过多源对照试验分析模型在不同区域的性能差异，及时调整数据管道与微调策略。数据质量的可追溯与对照设计也可为国际合作提供共享样本集和评测基准，推动技术输出与本地落地的双向融合。以此可在气候、作物与市场多重差异中构建灵活、可扩展的模型适配体系，确保大语言模型在全球范围内实现真正的可复制性与规模化扩展。

### 10.4.3 国际合作与技术输出潜力

在全球化背景下，农业现代化已成为各国共同追求的发展目标。大语言模型（LLM）技术的迅猛发展，为农业领域提供了前所未有的智能决策能力，其跨国应用与技术输出潜力巨大。通过与发达国家和发展中国家的多边合作，一方面可以吸纳全球最佳实践与技术标准，另一方面也能推动本国技术在国际市场的落地与产业化。

在国际合作层面，应秉持“互利共赢”的原则，开展多层次、多领域的协同创新。发达国家拥有成熟的智慧农业生态和强大的技术研发能力，其在农业遥感、物联网、大数据与 AI 结合方面积累了丰富的经验；发展中国家则拥有庞大的农业需求市场和多样化的生产场景。基于大语言模型的技术可以通过联合试点项目、联合研发中心和专业培训计划等方式，实现技术能力的双向流动。例如，中欧联合在撒哈拉以南非洲国家开展的“数字粮食安全”示范项目，通过在坦桑尼亚和肯尼亚部署具有本地化微调能力的作物模型，实现了对玉米和水稻种植全过程的智能监测与指导，为当地增产增收提供了有效支撑；同时，参与项目的中国技术团队借此机会深入了解非洲土壤类型、气候特点与种植习惯，不断优化大语言模型的多模态输入结构，为后续的全球部署打下基础。

技术输出过程中，标准化与本地化相辅相成。国际合作项目往往要求使用符合 FAO 与 ITU 等组织推荐的数据与接口标准，以便各参与国能够在统一规范框架下高效对接。与此同时，技术提供方必须针对接收国的生态和经济特点，开展本地化适配：包括将多语言 Prompt 和行业术语库本地化、将气象模型与区域气候模式结合、将作物品种信息与当地农艺体系对齐等。只有在标准化保证互操作性的前提下，实现深度本地化，才能保证大语言模型在不同国情与文化背景下的真实落地。

技术输出的另一重要途径是建立“国际农业 AI 联合实验室”。通过在目标国家或区域设立联合实验平台，由中方、高校科研机构与当地农业研究单位共同管理，开展长期技术交流、数据共享和人才培养。一方面，联合实验室可在当地采集高质量多模态农业数据，包括遥感影像、地面传感器读数和农户调查反馈，作为大语言模型持续优化的样本库；另一方面，可组织周期性技术研讨会和培训班，帮助当地政府官员、技术人员和农户快速掌握使用方法和维护要点，形成可复制的“人—机”协作模式。

从商业化视角看，农业大语言模型在国际市场上具备多样的盈利模式：可以通过“平台即服务”（PaaS）向合作伙伴提供云端计算与 API 调用接口，按数据调用量或模型推理时长计费；也可以以“软件即服务”（SaaS）形式将定制化应用打包出售，结合现场部署与运维一揽子解决方案；还可在重大国际农业工程项目中，通过政府间援助或出口信用保险，获得项目总包或分包合同，实现规模化落地。以东南亚某国为例，某中国智能农业企业与当地农业部签订框架协议，为全国产区提供“数字种植”平台，项目期内投资规模超过上亿美元，不仅大幅提升了当地粮食产量，也在区域内形成了示范效应。

国际技术输出还面临复杂的知识产权与法规合规挑战。不同国家在农业数据隐私、基因组数据保护、跨境数据流动及 AI 伦理方面的法律政策存在差异，技术提供方需提前进行合规评估与制度对接。构建透明的“技术许可+合规审计”机制，能够有效降低贸易摩擦与法律风险。与此同时，还应积极参与国际标准组织与行业联盟的工作，为全球农业 AI 相关标准建设贡献力量，推动数据模型、接口协议与安全规范的国际化统一，使得大语言模型技术在出口时具备更强的议价能力与市场认可度。

展望未来，随着区块链、数字孪生、元宇宙等前沿技术与大语言模型的深度融合，为国际合作与技术输出带来更多可能性。例如，可通过跨境区块链溯源系统，实现农产品“产—运—销”全链条的可追溯与智能合约支付；利用数字孪生技术，构建区域农业生态模拟平台，辅助国际合作伙伴进行大规模灾害应对与气候适应性研究；借助元宇宙平台，打造沉浸式的全球农业技术培训与交流空间，进一步降低跨文化沟通与技术推广的成本。

大语言模型在国际农业领域的合作与输出潜力巨大，但需要在标准化、本地化、合规化以及生态化等多方面持续发力。通过构建多边联合研发和人才培养体系，创新商业模式与合规机制，推动全球标准协调与数据互认，才能真正让先进的农业 AI 技术在不同国情下落地生根，为人类粮食安全和农业可持续发展贡献智慧力量。