

基于改进 ErcNet 的农技咨询分类:吉林省信息平台数据实证

于合龙¹ 赵丹¹ 毕春光¹ 赵明² 王莫寒^{1,2}

(1. 吉林农业大学信息技术学院, 长春 130118; 2. 吉林省中农阳光数据有限公司, 长春 130000)

摘要: 针对农业技术咨询非规范短文本语义稀疏性和特征表征不足导致的分类性能受限问题, 依据吉林省农业信息服务平台构建真实场景下的中文农技短文本数据集(平均长度少于 30 字), 提出一种基于深层语义重构与双驱动特征增强的融合优化模型(ErcNet)。区别于传统针对标准农业文本的单一结构改进方法, 在农技全领域实现双重突破; 通过预训练语言模型的后 3 层编码器的固定加权融合策略, 构建深度语义表示补全机制, 有效解决农民自发咨询文本的语义碎片化问题; 设计多尺度卷积与 ECA 注意力协同优化模块, 在特征提取阶段建立“语义密度增强-判别边界锐化”双驱动架构, 显著提升非规范短文本的特征辨识度。最后提出全局-局部特征融合机制, 进一步补全语义提取。实验结果表明, 模型在自建数据集上精确率(96.82%)、召回率(96.96%)和 F1 值(96.88%)均优于 ERNIE、TextCNN 等模型。在 THUCNews 数据集跨领域测试准确率达 91.70%, 验证了本方法泛化能力。

关键词: 农业文本; 咨询问句分类; 多尺度卷积; 通道注意力机制; 预训练模型

中图分类号: S24; TP39

文献标识码: A

文章编号: 1000-1298(2026)06-0311-09

OSID:



Agricultural Technical Consultation Classification Using Improved ErcNet: an Empirical Study Based on Jilin Provincial Information Platform Data

YU Helong¹ ZHAO Dan¹ BI Chunguang¹ ZHAO Ming² WANG Mohan^{1,2}

(1. College of Information Technology, Jilin Agricultural University, Changchun 130118, China

2. Jilin Zhongnong Sunshine Data Co., Ltd., Changchun 130000, China)

Abstract: Aiming to address the limited classification performance of non-canonical short texts for agricultural technology consultation, which stemmed from semantic sparsity and insufficient feature representation. Based on the Jilin Provincial Agricultural Information Service Platform, it constructed a dataset of Chinese agricultural technology short texts under real scenarios (average length < 30 characters) and proposed a fusion optimization model (ErcNet) based on deep semantic reconstruction and dual-driven feature enhancement. Differentiated from traditional methods that only improved single structures for standard agricultural texts, this work achieved dual breakthroughs in the entire agricultural technology field: firstly, it adopted a fixed weighted fusion strategy for the last three encoder layers of pre-trained language models, built a deep semantic representation completion mechanism, and this mechanism effectively resolved semantic fragmentation in spontaneous questions from farmers; secondly, it designed a coordinated optimization module combining multi-scale convolution and efficient channel attention (ECA), established a “semantic density enhancement – discriminative boundary sharpening” dual-driven architecture during feature extraction, and this architecture significantly improved the feature discriminability of non-canonical short texts. Finally, it proposed a global – local feature fusion mechanism, which further complemented semantic extraction. Experimental results showed that on the self-constructed dataset, the model outperformed ERNIE, TextCNN, and other models, with precision at 96.82%, recall at 96.96%, and F1 score at 96.88%; in cross-domain testing on the THUCNews dataset, it achieved 91.70% accuracy, which verified the method’s generalization ability.

Key words: agricultural text; consultation question classification; multi-scale convolution; channel attention mechanism; pre-trained model

收稿日期: 2025-04-17 修回日期: 2025-10-18

基金项目: 吉林省科技发展计划重点研发项目(20220202032NC)和吉林农业大学-中农阳光数字农业新质生产力研发项目(ZNYG-ZGS-2024129)

作者简介: 于合龙(1974—),男,教授,博士,主要从事智慧农业和光学农业等研究,E-mail: yuhelong@jlau.edu.cn

通信作者: 毕春光(1977—),女,教授,博士,主要从事数据库原理和智慧农业等研究,E-mail: chunguangB@jlau.edu.cn

0 引言

随着信息化技术飞速发展,线上智能问答成为解决农业技术问题的必然趋势,而咨询问句分类作为农业问答系统的首要环节,其准确性至关重要。传统基于规则和模板匹配的方法依赖人工提取规则,存在灵活性差、人力成本高、泛化能力不足等缺陷。相比之下,机器学习方法虽在效率等方面有优势,但传统机器识别方法如支持向量机^[1-4]、朴素贝叶斯^[5-7]等,因特征提取能力有限,处理复杂农业咨询问句时性能较低。

近年来,深层自学习技术因能挖掘句子语义与句法特征,在农业短文本分类领域应用广泛^[8]。主流技术包括卷积神经网络(CNN)^[9]、循环神经网络(RNN)及各类预训练模型^[10-11]。GUO等^[12]提出双向编码器递归卷积神经网络用于农业专家系统短文本分类;冯帅等^[13]提出的RIC-Net模型可精准分类不同样本量、复杂度的水稻知识数据。郑丽敏等^[14]提出BERT-LEAM模型,开展食品安全文本分类研究;DONG等^[15]提出融合语义与情感信息优化的EXBMA分类模型,其生鲜农产品评论情感分类性能优于现有模型。文献[16-18]针对农业新闻进行分类,均取得优异结果。但上述研究均聚焦陈述性、说明性信息,与农民口语化农业咨询问句差异大,模型适配性与分类精准度不足。大多对于农业问句分类的研究^[19-24]只针对特定作物或特定问题,对更广泛农业技术咨询短文本的覆盖度不够,缺乏对整个农业技术咨询场景全面、通用的分类方案。金宁等^[25]提出了BiGRU_MulCNN模型对农业问句进行分类,却忽略了词间语义动态变化与农业领域知识特殊性,影响复杂语义问句分类性能。

现有研究在农业技术咨询短文本分类中,尚未解决特征稀疏引发的类别区分难题,且多仅调整模型结构,忽视深层语义原始特征。为此,本文依据吉林省信息平台数据,自主构建吉林省农技知识咨询问句短文本数据集,并提出一种基于深层语义重构

与双驱动特征增强的融合优化模型(ErcNet),用于问答系统中的农技咨询问句分类。设计预训练语言模型的最后3层编码器的固定加权融合策略,构建深度语义表示补全机制。通过多尺度卷积与ECA注意力协同优化模块,在特征提取阶段建立“语义密度强化-判别边界锐化”双驱动架构。提出全局-局部特征融合机制,进一步补全问句多维度语义提取。以解决农业技术咨询非规范短文本语义稀疏性、特征表征不足导致的分类性能受限问题。

1 材料与方法

1.1 数据来源与预处理

1.1.1 数据来源

利用Python语言在吉林省信息平台爬取2015年4月—2018年11月农技人员的咨询问句,其中包括咨询ID、咨询时间、咨询问题、回复ID、回复时间、回复内容,数据量共25107条。

1.1.2 数据预处理

对原始数据采用正则表达式匹配规则进行处理,删除冗余信息并过滤无效内容,仅保留咨询问题文本,且统一转换为UTF-8纯文本格式。农业咨询问句分类数据集示例如表1所示,该数据集涵盖种植管理、品种选择、水肥管理、植物保护等7个类别,文本长度集中在10~30字。咨询问句短文本分类任务为单标签多类别分类,在数据集构建阶段,通过人工标注为每条提问赋予类别标签。由于数据来源于真实农事从业者的提问,从业者对植物病害等植物保护类问题及涉及民生的市场行情问题的关注度显著高于农机设备类问题,导致数据集存在类别不平衡现象。为此,采用简易数据增强(Easy data augmentation,EDA)文本增强技术对样本量较少的农机管理类数据进行处理,包括同义词替换、随机插入、随机交换及随机删除等操作。最终数据集包含13199条数据,数据量差异最大的2个类别比例为4:1,整体呈轻微的不平衡,各类别具体分布如图1所示。

表1 农技咨询问句分类数据集示例

Tab.1 Example of categorized data sets for agronomic advisory questionnaire

问句类别	问句示例	类别标签	数量	标签ID
种植管理类	茄子苗从移苗到定植需要多长时间?	Planting mode	2 250	1
品种选择类	哪个玉米品种高抗虫不掉棒产量高?	Variety selection	1 137	2
水肥管理类	葡萄底肥用15-5-20硝硫基肥,还用什麼肥追比较好?	Water and fertilizer	1 883	3
植物保护类	茄子花底部叶片变黄是什么原因造成的?怎样防治?	Plant protection	3 239	4
市场行情类	今年大豆的价格怎么样?	Market quotation	2 032	5
政策补贴类	今年松原市扶余地区种植的马铃薯有没有专项补贴?	Policy subsidy	1 841	6
农机管理类	联合收割机的轮胎尺寸和类型对田地的影响是什么?	Agricultural machinery	817	7

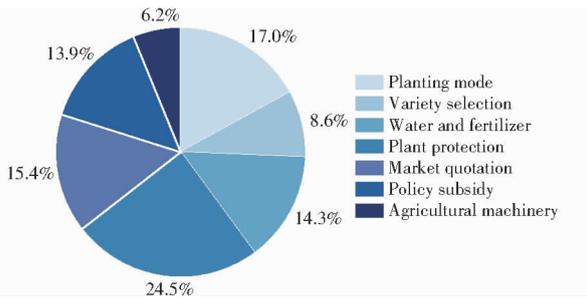


图 1 问句类别分布

Fig.1 Distribution of question categories

同时,为了验证模型性能,选取 THUCNews 新闻数据集的子集作为基准测试集。子集包含 2×10^5 条规范化的新闻标题,文本长度控制在 20 ~ 30 个字符之间,包含财经、房产、股票、教育等 10 个类别,每个类别平均包含 2×10^4 条样本。其中训练集 1.8×10^5 条、验证集 1×10^4 条、测试集 1×10^4 条。

1.2 模型构建

提出基于深度学习的农技知识问句短文本分类混合模型 ErcNet,包含 ERNIE、多尺度卷积及 ECA 注意力机制^[26]等模块(结构见图 2)。首先,将预训练语言模型 ERNIE^[27]得到的农技咨询问句嵌入信息传输到编码层,并将其最后 3 层编码层输出结果进行加权融合,传给含有不同尺度卷积核的卷积层进行局部特征提取。在多尺度卷积神经网络里包含 ECA 注意力机制层、卷积层、最大池化层、激活函数层。为了避免特征提取不全面,将输出的局部语义特征向量与编码层输出的包含全局语义信息的 [CLS] 位置向量融合作为特征提取层。通过全连接层连接至 Softmax 层,对融合后的多维度特征进行归一化,完成分类。

为了解决数据轻微不平衡问题,借助模型自适

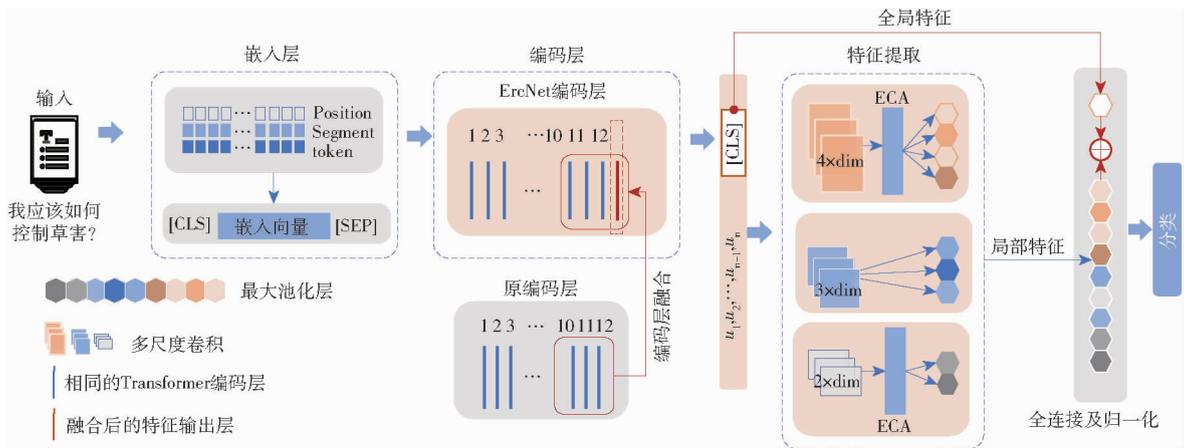


图 2 ErcNet 模型结构图

Fig.2 General framework of ErcNet

应权重方法来提升权重收敛性。设计类别感知自适应权重机制以优化模型训练:首先基于“反频率加权法”计算初始权重 $\omega_{i,0}$,初步平衡类别分布,即

$$\omega_{i,0} = N_{total} / (CN_i) \quad (1)$$

式中 N_{total} ——总样本

C ——类别数

N_i ——第 i 类样本数

每轮根据各类别损失与全局平均损失的比值调整权重(高损失类别权重增大,反之减小),设权重为 0.5 ~ 3.0 并通过指数移动平均平滑变化,保障收敛稳定。该策略与 ErcNet 的“深层语义重构 + 双驱动特征增强”架构协同,在模型捕捉少数类细粒度语义的基础上,通过动态权重分配确保少数类样本获得充足梯度更新,以优化不平衡数据分类效果。

1.2.1 嵌入层与编码层

引入 ERNIE 模型的嵌入层与编码层,其架构继承 BERT 的 Transformer 编码器,核心差异在于采用多层次知识掩码预训练策略——通过 token、短语、

实体三级掩码实现文本语义深度理解,掩码策略如图 3 所示。

句子	吉	林	适	合	种	什	么	品	种	玉	米
Basic-Level Masking	吉	林	适	合	种	什	么	品	种	玉	米
Phrase-Level Masking	吉	林	适	合	种	什	么	品	种	玉	米
Entity-Level Masking	吉	林	适	合	种	什	么	品	种	玉	米

图 3 ErcNet 掩码策略

Fig.3 Masking strategy of ErcNet

通过内部词法分析工具,在 CJK Unicode 字符周围添加空格实现字符级初步分隔,再结合 WordPiece 算法完成子词切分,同时识别词与实体,形成多粒度单元。切分后,文本单元被转换为 token 序列,生成记录边界的 seg_labels(0 表示词首,1 表示非词首,-1 为占位符)。基于这些标记,模型分阶段对 token、phrase、entity 级 span 实施随机掩码:随机选择 15% 的单元,其中 80% 替换为 [MASK], 10% 替换为其他词,10% 保持不变,以学习内部关联与实体边界。该机制可捕捉词汇-短语语义关联,提

升语义理解能力,精准把握领域术语语义特征,规避传统词向量的歧义问题(如在“玉米行情”中明确“行”读“háng”表示“市场行情”),进而优化分类效果并强化语义相似性捕捉。句子输入后,嵌入层在句首添加[CLS]标记用作分类,并在句子的末尾添加标记[SEP]。这些句子由标记嵌入、段嵌入和位置嵌入组成,三者求和后作为编码层输入。

编码层主体由12个结构相同的Transformer编码器层堆叠构成,各层通过残差连接与LayerNorm实现特征的稳定传递。每层编码器包含多头自注意力层与前馈神经网络层(FFN)2个核心组件:在多头自注意力层中,输入特征矩阵被并行投影至12个注意力头,每个头通过Query、Key、Value矩阵(维度均为[序列长度,64])的交互计算token间的关联权重,通过缩放点积注意力实现特征聚合,多头输出经拼接与线性变换后保持768维度。

值得注意的是,在经嵌入层采用的短语级与实体级掩码策略(如对“小麦锈病”进行整体掩码)后,可辅助自注意力机制捕捉“秸秆还田”“病虫害防治”等农技领域术语组合的语义关联,降低分词粒度对专业语义建模的干扰。自注意力层的输出经残差连接和LayerNorm处理后送入前馈神经网络,通过2层线性变换与GeLU激活函数引入非线性特征映射,其中第1层将768维特征扩展至3072维,第2层还原至768维,这一过程增强了模型对复杂农业语义关系的拟合能力。经FFN处理的特征再次经残差连接与LayerNorm处理,作为当前层输出传递至下一层。

在本文模型编码层堆叠结构中,各层输入均来自相邻上一层输出。编码层数据传输中易出现层间信息损耗,为减少损耗并拓宽语义捕捉范围,将编码层(编码层的结构见图4)最后一层输出与前2层输出进行类似残差方式的加权融合,以此作为新的输出层,即

$$H(x) = F(x) + G(x) + R(x) \quad (2)$$

式中 x ——输入

$F(x)$ ——第10层变换后的输出

$G(x)$ ——第11层变换后的输出

$R(x)$ ——第12层变换后的输出

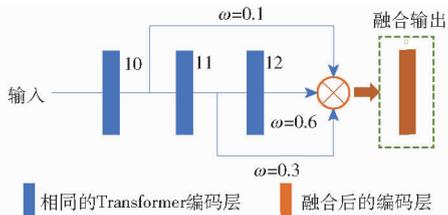


图4 EcrNet模型编码层

Fig.4 EcrNet's coding layer structure

该操作在实现输入-输出映射的同时填补信息缺失,助力网络学习恒等语义映射,完成编码层计算。最终输出的语义文本向量作为编码层词向量表示,输入多尺度CNN通道进行特征提取。

1.2.2 多尺度卷积集成ECA的协同优化模块

在特征提取部分,构建基于二维语义矩阵的多尺度特征抽取架构。将编码层输出的词向量序列构建为纵向时序维度-横向语义维度的二维表征空间,记为 $X \in \mathbf{R}^{L \times d}$,其中 L 为序列长度, d 为词向量维度。并行采用窗口尺度为 $h \in \{2, 3, 4\}$ 的多尺度卷积,卷积核尺寸为 $h \times d$,其沿纵向时序维度滑动,覆盖相邻 h 个词的时序关系。同时在横向语义维度上完整覆盖词向量的语义特征,从而通过不同尺度窗口捕获不同范围的词语关联信息,以获取时序层面的差异特征。单个尺度的卷积操作表示为

$$C_h = f(W_h X_{i:i+h-1} + b_h) \quad (3)$$

式中 W_h ——尺度为 h 的卷积核

$X_{i:i+h-1}$ ——第 i 个长度为 h 的滑动窗口

f ——ReLU 激活函数

b_h ——偏置项

每个卷积核都有其焦点,为了能学习到不同的信息,设置256个卷积核,即 $256 \times \text{filter}$ 。每个尺度为 h 的卷积操作输出特征映射为 $\mathbf{R}^{256 \times (L-h+1)}$ (256个特征图,长度为 $L-h+1$),分别捕获相邻2~4个词汇的层次化语义特征,如农业术语搭配、农事短语等。为解决不同尺度特征图长度差异,对每个特征图采用全局最大池化得到256维向量;将3个尺度的池化结果深度拼接为768维特征向量,实现语义的多粒度融合,有效缓解农机咨询问句因语义稀疏性导致的特征表征不足问题。

在模型特征提取的过程中,每条数据中具有决定性作用的部分作为该数据的类别特征。针对农技咨询短文本中关键特征分布位置不固定的特性,同时使模型能够更加快速且准确捕获到关键特征,提出多尺度卷积融合动态通道注意力的特征提取方法,实现特征空间的自适应聚焦。针对不同尺度卷积结果,分别引入具有动态卷积核的ECA-Net模块,其核尺寸 k 通过非线性函数实现通道维度 C 的自适应映射,突破传统固定尺度卷积对特征范围的约束,即

$$k = \psi(C) = \left\lfloor \frac{\text{lb}C}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{ood}} \quad (4)$$

式中 k ——卷积核尺寸

C ——通道数

$\lfloor \cdot \rfloor_{\text{ood}}$ ——取最近奇数

γ 、 b ——用于改变通道数和卷积核尺寸的比例系数

随后,对各尺度特征图通过全局平均池化生成通道统计量,再用核尺寸动态计算的一维卷积实现跨通道交互,生成通道注意力权重。该轻量级操作可强化判别性特征,将各尺度经注意力增强的特征图拼接,形成最终特征表示。这种设计使模型能够根据输入文本的语义密度自主调节局部感受野,有效捕获农技咨询文本中的关键特征。通过改进 ECA-Net 注意力机制,增强了模型对通道信息的处理能力和对特征的表达能力。在强化高频判别特征的同时抑制可能存在的方言噪声干扰,形成面向非规范短文本的梯度敏感型特征提取范式。

最终完成 ErcNet 模型的特征提取,形成“语义密度强化-判别边界锐化”双驱动架构,多尺度卷积和 ECA 注意力机制二者的协同作用使模型形成“特征表征能力增强-分类决策质量提升”的闭环优化:基于多尺度卷积的语义强化部分提升特征空间的信息完备性,为边界锐化提供高质量输入;而 ECA 部分通过注意力聚焦过滤冗余信息,反向指导语义强化过程的特征优化方向。

1.2.3 全局-局部特征融合

向量数据经含注意力机制的多尺度卷积后,会通过激活函数剔除冗余特征,但此过程会引发网络稀疏性问题。为解决这一问题,在卷积层后添加最大池化层,既能缩小参数矩阵规模,又能精准提取各卷积核的核心特征向量。此外,文本输入模型时,开头会插入[CLS]标记、结尾插入[SEP]标记。经编码器深度加工后,编码层输出序列中[CLS]标记对应的768维向量,会被提取为农技咨询问句的语义表征,该向量蕴含“病害防治”、“种植技术”等全局主题信息。为了更大范围地捕获句子表示并提取特征信息不完整,将包含全局特征信息的[CLS]再次利用,与池化层输出的局部特征表示相结合,得到最终的特征表示结果。最后通过全连接的方式将特征表示连接到 Softmax 函数进行分类,输出预测标签并实现农技问句短文本分类。

1.3 实验环境与评价指标

农技知识问句短文本分类模型是由深度学习框架 PyTorch 构建的,实验配置如表 2 所示,模型参数设置如表 3 所示。

1.4 评价指标

采用分类准确率、精确率、召回率、损失值以及 F1 值作为分类模型评价指标。

表 2 实验配置

Tab.2 Experimental environment

类别	配置
Computer hardware	CPU: Intel(R) Xeon(R)
	Gold 5218R CPU @ 2.10 GHz
	GPU: NVIDIA GeForce RTX 2080 Ti
	OS: Windows 10 professional version
Computer software	CUDA 12.2
	Python 3.7
	Pytorch 1.12.0
	Transformers 4.30.2
	Numpy 1.21.6

表 3 参数设置

Tab.3 Parameters setting

参数	数值
最大序列长度	32
批次大小	32
训练轮数	4
学习率	2×10^{-5}
优化器	Adam

2 结果与讨论

2.1 ErcNet 模型参数

选用多分类交叉熵作为损失函数,同时引入早停机制,当连续训练 1000 轮次损失值不再下降时,停止训练。参数优化是影响模型分类性能的关键。由于 ERNIE 后 3 层改进涉及高层特征与底层编码的协同调优,训练过程采用全参数微调模式,既保留预训练模型的通用语言知识,又能使特征表达适配农技咨询问句的术语分布。为提升 ErcNet 预测效果,在固定其他参数的前提下,还针对卷积核尺寸、训练轮次及学习率等参数开展了寻优实验。

为确定 ErcNet 模型的最优参数,对卷积核尺寸与学习率开展对比实验。由图 5 可知,采用 2、3、4 3 种尺寸的卷积核时模型性能最优,准确率达 96.81% 且损失值最低。由图 6 可知,当学习率为 2×10^{-5} 时,模型性能最优,避免了因过小导致训练慢、过大陷入局部最优的问题。训练轮次影响损失下降与收敛情况,过多会增加计算量和内存占用量并降低速度。经 3 次重复实验,训练 2 次时性能快速提升,3 次逐渐稳定收敛,后续训练无明显增益;为避免未充分收敛、保证效果并降低成本,最终设为 4 次。综上,模型核心参数为卷积核尺寸 2、3、4,学习率 2×10^{-5} ,迭代次数 4。

2.2 消融实验分析

为深入探究 ErcNet 模型中局部模块对于分类效果所产生的作用,在确保参数一致且实验环境完全相同条件下,设计消融实验,结果如表 4 所示。

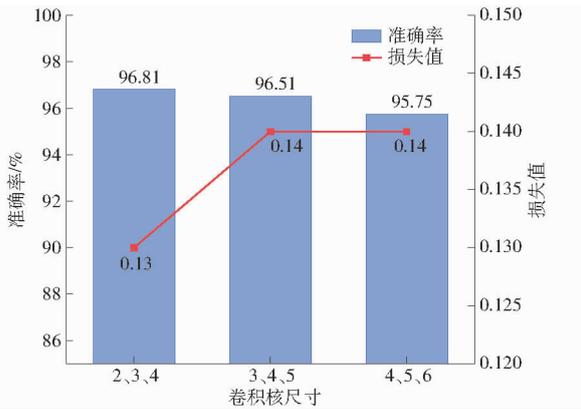


图5 不同卷积核测试结果对比

Fig. 5 Comparison of results under different learning rates

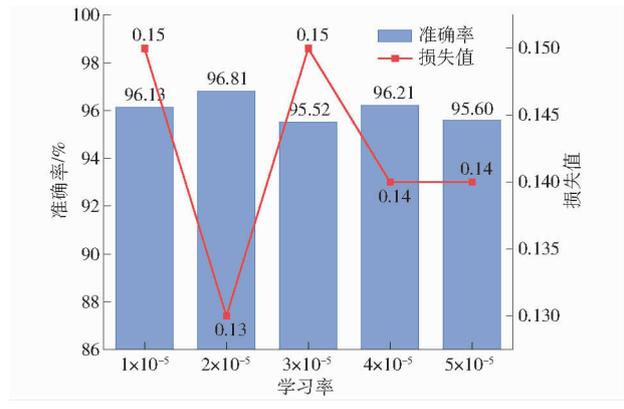


图6 不同学习率测试结果对比

Fig. 6 Comparison of results under different convolution kernels

表4 消融实验结果对比

Tab. 4 Comparison of results of ablation experiments

模型	精确率/%	召回率/%	F1 值/%	损失值	准确率/%
ERNIE	94.79	95.65	95.19	0.19	95.37
A (ERNIE + CNN)	96.11	95.67	95.86	0.15	95.83
B (ERNIE + CNN + ECA)	96.07	96.06	96.06	0.15	95.98
C (ERNIE + CNN + CLS)	95.76	95.97	95.85	0.15	95.83
D (ERNIE + CNN + ECA + CLS)	96.30	96.64	96.45	0.14	96.21
ErcNet	96.82	96.96	96.88	0.13	96.81

模型 A 在 ERNIE 基础上引入多尺度卷积模块,分类性能较 ERNIE 显著提升,表明 CNN 提取的局部特征可有效拓宽感受野、挖掘更丰富的语义信息,对模型性能具有正向增益;进一步在多尺度卷积中融入 ECA 注意力机制(模型 B),实验结果显示该机制能通过对关键字赋予差异化权重,精准捕捉各通道重要特征,优化特征筛选效果;模型 C 单独结合 [CLS] 标记后指标无明显改善,但模型 D 将 ECA 与 [CLS] 协同使用时性能显著提升,其核心原因在于 ECA 注意力机制通过多层感知机 (MLP) 增强关键语义信息权重,强化单个特征词学习,而 [CLS] 标记作为原始语义嵌入后的句表示,可捕捉输入序列全局语义信息,补全 ECA 加权后的序列语义连接,二者形成协同作用以提升分类性能;ErcNet 通过 ERNIE 编码层特征融合,进一步增强对农技问句语义信息提取准确性,实现固定任务下精准分类,使模型性能达到最优。

通过测试集混淆矩阵(图 7)可直观对比消融实验各模型分类效果。相较于基线模型本文模型为最优结果,分类性能提升,品种选择类正确分类实例增加 6 个(约占该类总数 6%),其余类别误分类率均下降。仅种植管理类因关键词与其他类别重叠、语义模糊性较高,分类错误相对较多。消融实验结果表明,所引入的各改进模块均对模型性能有增益作

用,移除任一模块都会导致 ErcNet 分类准确率下降。

2.3 不同模型性能对比实验

使用农技问题数据集将所提模型与几种常见的多分类模型进行详细对比,表 5 为各模型在整体性能以及在单个类别中测试结果。

由表 5 可知,FastText 分类效果最差,因其采用词袋模型,忽略词语顺序与语法结构;TextCNN 性能优于 FastText、BiLSTM - Attention,体现了卷积神经网络理解文本语义有效性。同时,基于 Transformer 架构^[23]的模型各指标更优,因其能捕捉文本语义、句法与上下文信息以提升准确性;Llama3 - 8b 作为英文原生通用大模型,对中文农业领域专业词汇与语义理解不足,而 ErcNet 针对中文优化且适配垂直领域特征,故在中文农业问句分类任务上表现更优。

从单类别性能看,各模型对品种选择、农机管理类分类效果较差,对植物保护、市场行情、政策补贴类分类效果较好。这是因后 3 类样本量多,能提供更丰富信息且类别边界清晰。而前 2 类样本少,导致模型学习类别特征不足。但 ErcNet 模型在少样本类别中表现更优,尤其在样本最少的农机管理类上 F1 值达 98.04%,证明其在样本轻微不平衡任务中仍具备良好性能。

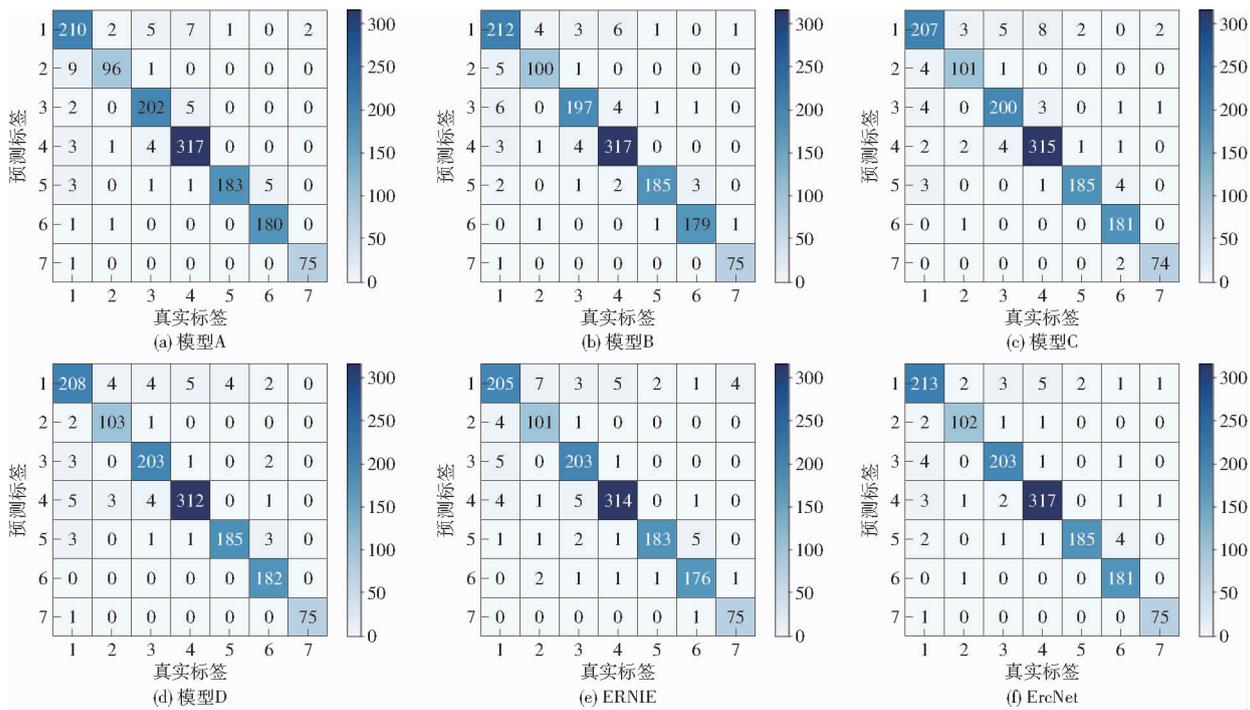


图7 消融实验混合矩阵

Fig. 7 Ablation experimental confusion matrix

表5 不同深度学习模型结果对比

Tab. 5 Comparison of experimental results of different deep learning models

模型	指标	农技咨询问句类别							宏观平 均值/%	加权平 均值/%	准确 率/%	损失值	参数量
		1	2	3	4	5	6	7					
FastText	精确率/%	66.09	77.66	89.23	82.22	74.19	90.91	99.00	82.90	81.24	80.12	0.84	1.52×10^8
	召回率/%	67.84	68.87	83.25	86.77	95.34	87.91	38.16	75.45	80.12			
	F1值/%	66.96	73.00	86.14	84.43	83.45	89.39	55.24	76.94	79.63			
BiLSTM - Attention	精确率/%	72.76	84.00	94.39	92.28	96.72	93.09	73.97	86.74	88.29	87.71	0.41	3.54×10^7
	召回率/%	89.43	59.43	88.52	92.00	91.71	96.15	71.05	84.04	87.71			
	F1值/%	80.24	69.61	91.36	92.14	94.15	94.59	72.48	84.94	87.65			
Transformer	精确率/%	82.77	86.14	95.52	95.81	92.96	87.06	91.18	88.12	90.85	90.67	0.35	2.36×10^7
	召回率/%	86.78	82.08	91.87	91.38	95.85	96.15	81.58	87.91	90.67			
	F1值/%	84.73	84.06	93.66	93.54	94.39	91.38	86.11	87.80	90.68			
TextCNN	精确率/%	70.99	94.81	93.56	92.57	96.20	92.51	90.38	90.15	89.59	88.47	0.45	3.32×10^7
	召回率/%	91.63	68.87	90.43	92.00	91.71	95.05	61.84	84.51	88.47			
	F1值/%	80.00	79.78	91.97	92.28	93.90	93.77	73.44	86.45	88.47			
TextRNN	精确率/%	88.11	86.11	90.05	95.65	97.80	93.44	81.33	90.36	91.88	91.81	0.29	3.47×10^7
	召回率/%	88.11	87.74	95.22	94.77	92.23	93.96	80.26	90.32	91.81			
	F1值	88.11	86.92	92.56	95.21	94.93	93.70	80.79	90.32	91.82			
BERT	精确率/%	82.80	94.19	94.34	96.55	95.41	95.63	90.28	92.47	92.99	92.79	0.28	1.02×10^8
	召回率/%	91.19	76.42	95.69	94.77	96.89	96.15	85.53	90.95	92.79			
	F1值/%	86.79	84.38	95.01	95.65	96.14	95.89	87.84	91.67	92.77			
BERT - BiLSTM	精确率/%	84.06	92.47	94.71	95.65	96.39	97.24	88.41	92.71	84.14	93.02	0.29	1.26×10^8
	召回率/%	92.95	81.13	94.26	94.77	96.89	96.70	80.26	91.00	93.02			
	F1值/%	88.28	86.43	94.48	95.21	96.64	96.97	84.14	91.74	93.01			
BERT - CNN	精确率/%	83.87	91.30	95.24	95.15	98.40	94.71	95.16	93.40	93.33	93.17	0.25	1.04×10^8
	召回率/%	91.63	79.25	95.69	96.62	95.34	95.34	95.34	90.64	93.17			
	F1值/%	95.34	84.85	95.47	95.88	96.84	96.50	85.51	91.80	93.12			
ERNIE	精确率/%	93.61	90.18	94.42	97.52	98.39	95.65	93.75	94.79	95.41	95.37	0.19	1.01×10^8
	召回率/%	90.31	95.28	97.13	96.62	94.82	96.70	98.68	95.65	95.37			
	F1值/%	91.93	92.66	95.75	97.06	96.57	96.17	96.15	95.19	95.37			
All - distilroberta	精确率/%	88.51	90.48	95.67	96.26	98.40	95.63	91.14	93.73	94.30	94.23	0.23	8.21×10^7
	召回率/%	91.63	89.62	95.22	95.08	95.34	96.15	94.74	93.97	94.23			
	F1值/%	90.04	90.05	95.44	95.67	96.84	95.89	92.90	93.83	94.25			
BGE - small - zh	精确率/%	91.48	93.14	95.69	96.33	96.84	96.26	92.50	94.61	94.98	94.92	0.18	9.14×10^7
	召回率/%	89.87	89.62	95.69	96.92	95.34	98.90	97.37	94.82	94.99			
	F1值/%	90.67	91.35	95.69	96.63	96.08	97.56	94.87	94.69	94.98			
Llama3 - 8b	精确率/%	63.32	75.32	66.11	69.03	62.39	69.57	62.34	66.87	66.81	66.69	1.41	1.09×10^8
	召回率/%	55.51	54.72	56.94	74.77	73.06	79.12	63.16	65.32	66.69			
	F1值/%	59.15	63.39	61.18	71.79	67.30	74.04	62.75	65.66	66.39			
ErcNet	精确率/%	94.67	96.23	96.67	98.93	98.93	96.28	97.40	96.82	96.82	96.81	0.13	1.03×10^8
	召回率/%	93.83	96.23	97.13	97.54	95.85	99.45	98.68	96.96	96.81			
	F1值/%	94.25	96.23	96.90	97.54	97.37	97.84	98.04	96.88	96.81			

ErcNet 模型整体精确率、召回率和 F1 值分别达 96.82%、96.96% 和 96.88%，较 ERNIE 模型分别提升 2.03、1.31、1.69 个百分点。尽管参数量略有增加，但未显著提升模型复杂度，损失值降至 0.13，总体准确率达 96.81%，在对比实验中优于其他分类模型，性能表现卓越。

图 8 为 5 种模型在验证集测试准确率及损失值变化曲线。虽 ERNIE 模型在后期的准确率表现良好，但上升速度不如 ErcNet 模型快且平稳，同时精度低于 ErcNet 模型。ErcNet 模型在初期验证精度略低，但随着迭代次数增加，模型可高效地学习关键特征，以最快速度赶上其他对比模型，提升至较高的准确率并快速收敛，在迭代次数为 120 时基本保持平稳状态。从收敛速度、模型稳定性、准确率和损失值的综合对比来看，ErcNet 模型性能最好，测试效果最优。

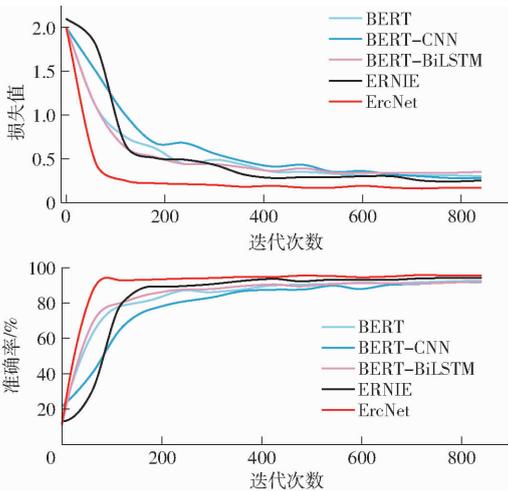


图 8 验证集准确率及损失值变化曲线

Fig. 8 Accuracy and loss curves on verification set

为了验证模型泛化能力，使用清华 NLP 组提供的 THUCNews 新闻公开数据集对模型进行测试，同时进行可视化分析，如图 9 所示，其中标签 1~10 分别表示 10 个类别，对比结果如表 6 所示。

3 结论

(1) 针对农业问答系统的农技咨询问句分类问

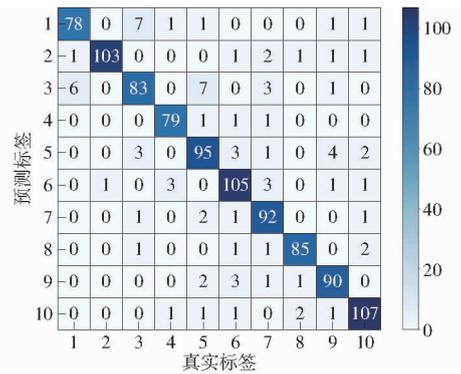


图 9 公共数据集混淆矩阵

Fig. 9 Confusion matrix on public dataset

表 6 在 THUCNews 公开数据集上测试结果

Tab. 6 Comparison results on THUCNews public dataset

模型	精确率/%	召回率/%	F1 值/%	损失值	准确率/%
FastText	82.91	82.42	82.55	0.59	82.30
TextCNN	84.61	84.44	84.44	0.53	84.30
TextRNN	79.52	78.84	78.95	0.66	78.70
BiLSTM - Attention	82.69	82.39	82.36	0.62	82.10
Transformer	88.12	87.91	87.80	0.44	87.91
BERT	83.40	83.45	83.18	0.6	83.20
BERT - CNN	82.45	82.77	82.41	0.59	82.50
BERT - BiLSTM	79.09	79.18	78.88	0.72	78.60
ERNIE	90.25	89.94	89.97	0.35	89.90
ErcNet	91.78	91.75	91.73	0.24	91.70

题，提出短文本分类模型 ErcNet，从深层语义表示重构与结构优化 2 方面进行增强：通过后 3 层编码固定加权融合补全深层语义，设计多尺度卷积集成注意力协同模块，构建“语义密度强化-判别边界锐化”双驱动机制，解决短文本语义稀疏与细粒度类别决策边界模糊问题。

(2) 基于吉林省农业信息服务平台构建真实数据集，验证结果显示 ErcNet 精确率、召回率、F1 值分别达 96.82%、96.96%、96.88%，优于现有模型；跨语料测试证实其短文本分类适用性与扩展性。该方法不仅有效解决农技问句语义稀疏导致的特征表征不足问题、提升分类精度，更为农业问答系统问句分类提供可行方案，也为农业大模型^[28]问答提供先验知识。

参 考 文 献

- [1] SHASTRY K A, SANJAY H A, DEEXITH G. Quadratic-radial-basis-function-kernel for classifying multi-class agricultural datasets with continuous attributes[J]. Applied Soft Computing, 2017, 58: 65 - 74.
- [2] 魏芳芳,段青玲,肖晓琰,等. 基于支持向量机的中文农业文本分类技术研究[J]. 农业机械学报,2015,46(增刊):174 - 179. WEI Fangfang, DUAN Qingling, XIAO Xiaoyan, et al. Classification technique of Chinese agricultural text information based on SVM[J]. Transactions of the Chinese Society for Agricultural Machinery,2015,46(Supp.):174 - 179. (in Chinese)
- [3] 卢鸿,邱云志,戴小路,等. 基于中心核对齐模糊 SVM 的中文农业文本分类[J]. 赣南师范大学学报,2021,42(6):57 - 61.
- [4] 李伟,汪延华,郑惠宁. 基于特征族群语义扩散核的半监督农业文本分类[J]. 赣南师范大学学报,2018,39(3):66 - 71.
- [5] 周云成,许童羽,邓寒冰. 基于 NB 和 CHI 值的农业文本分类方法[J]. 江苏农业科学,2018,46(17):219 - 223.

- [6] 陈鹏,郭小燕.基于Adaboost与朴素贝叶斯的农业短文本信息分类[J].软件,2020,41(9):13-18.
CHEN Peng, GUO Xiaoyan. Agricultural short text information classification based on Adaboost and naive bayes[J]. Software, 2020,41(9):13-18. (in Chinese)
- [7] 于孝铂.基于文本分类算法的吉林省农业信息集应用研究[D].长春:吉林农业大学,2020.
YU Xiaobo. Application research of agricultural information set in jinlin province based on text classification algorithm[J]. Changchun: Jilin Agricultural University, 2020. (in Chinese)
- [8] ALSAMMAK I L H, ITWEE W H, MAHMOUD M A, et al. Text classification: a comprehensive survey from traditional approaches to deep learning methods[J]. Current and Future Trends on AI Applications, 2025,1: 247-267.
- [9] KIM Y. Convolutional neural networks for sentence classification[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, 2014: 1746-1751.
- [10] LI J, XU M, XIANG L, et al. Foundation models in smart agriculture: basics, opportunities, and challenges[J]. Computers and Electronics in Agriculture, 2024, 222: 109032.
- [11] ZHAO B, JIN W, DELSER J, et al. ChatAgri: exploring potentials of ChatGPT on cross-linguistic agricultural text classification[J]. Neurocomputing, 2023, 557: 126708.
- [12] GUO X, WANG J, GAO G, et al. Improving text classification in agricultural expert systems with a bidirectional encoder recurrent convolutional neural network[J]. Electronics, 2024, 13(20): 4054.
- [13] 冯帅,许童羽,周云成,等.基于深度卷积神经网络的水稻知识文本分类方法[J].农业机械学报,2021,52(3):257-264.
FENG Shuai, XU Tongyu, ZHOU Yuncheng, et al. Rice knowledge text classification based on deep convolution neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 257-264. (in Chinese)
- [14] 郑丽敏,乔振铎,田立军,等.基于BERT-LEAM模型的食品安全法规问题多标签分类[J].农业机械学报,2021,52(7):244-250,158.
ZHENG Limin, QIAO Zhenduo, TIAN Lijun, et al. Multi-label classification of food safety regulatory issues based on BERT-LEAM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 244-250, 158. (in Chinese)
- [15] DONG Y, ZHANG Y, WU G, et al. Sentiment classification method of fresh agricultural product reviews based on semantic and emotional optimisation[J]. International Journal of Intelligent Information and Database Systems, 2025, 17(1): 32-56.
- [16] XIAO Z Y, YANG S Q, DUAN X L, et al. E3W—a combined model based on greedySoup weighting strategy for chinese agricultural news classification[J]. Applied Sciences-Basel, 2022, 12(23): 12059.
- [17] WANG H, ZHANG S. Research on the application of improved BERT-DPCNN model in chinese news text classification[J]. Concurrency and Computation: Practice and Experience, 2025, 37(3): e8338.
- [18] 杨森淇,段旭良,肖展,等.基于ERNIE+DPCNN+BiGRU的农业新闻文本分类[J].计算机应用,2023,43(5):1-9.
YANG Senqi, DUAN Xuliang, XIAO Zhan, et al. Text classification of agricultural news based on ERNIE+DPCNN+BiGRU[J]. Journal of Computer Applications, 2023, 43(5): 1-9. (in Chinese)
- [19] YU H, LIU C, ZHANG L, et al. An intent classification method for questions in “Treatise on febrile diseases” based on TinyBERT-CNN fusion model[J]. Computers in Biology and Medicine, 2023, 162: 107075.
- [20] GUO X, WANG J, GAO G, et al. Efficient agricultural question classification with a BERT-Enhanced DPCNN model[J]. IEEE Access, 2024, 12: 109255-109268.
- [21] ZHANG T, WANG D. Classification of crop disease-pest questions based on BERT-BiGRU-CapsNet with attention pooling[J]. Frontiers in Plant Science, 2023, 14: 1300580.
- [22] 韦婷婷,葛晓月,熊俊涛.基于层级多标签的农业病虫害问句分类方法[J].农业机械学报,2024,55(1):263-269,435
WEI Tingting, GE Xiaoyue, XIONG Juntao. Hierarchical multi-label classification of agricultural pest and disease interrogative questions[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 263-269, 435. (in Chinese)
- [23] 王郝日钦,吴华瑞,冯帅,等.基于Attention_DenseCNN的水稻问答系统问句分类[J].农业机械学报,2021,52(7):237-243.
WANG Haoriqin, WU Huarui, FENG Shuai, et al. Classification technology of rice questions in question answer system based on Attention_DenseCNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 237-243. (in Chinese)
- [24] 朱波,黎魁,邱兰,等.基于SBERT-Attention-LDA与ML-LSTM特征融合的烟草问句意图识别方法[J].农业机械学报,2024,55(5):273-281.
ZHU Bo, LI Kui, QIU Lan, et al. Tobacco interrogative intent recognition based on SBERT-Attention-LDA and ML-LSTM feature fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 273-281. (in Chinese)
- [25] 金宁,赵春江,吴华瑞,等.基于BiGRU_MulCNN的农业问答问句分类技术研究[J].农业机械学报,2020,51(5):199-206.
JIN Ning, ZHAO Chunjiang, WU Huarui, et al. Classification technology of agricultural questions based on BiGRU_MulCNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5): 199-206. (in Chinese)
- [26] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534-11542.
- [27] SUN Y, WANG S, LI Y, et al. Ernie: enhanced representation through knowledge integration[J]. arXiv Preprint, arXiv:1904.09223, 2019.
- [28] 王耀君,徐国威,朱建军,等.农业领域大语言模型研究进展[J].农业机械学报,2025,56(9):240-256.
WANG Yaojun, XU Guowei, ZHU Jianjun, et al. Survey of research on large language models in agriculture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(9): 240-256. (in Chinese)