曹佩荣,张思佳,李政霖,等.RoBFM:双向焦点增强机制的水产病害防治因果关系抽取[J].华中农业大学学报,2026,45(3):161-172.
DOI:10.13300/j.cnki.hnlkxb.2026.03.014

RoBFM:双向焦点增强机制的水产病害防治因果关系抽取

曹佩荣[1],张思佳[1,2],李政霖[1],安宗诗[1],张佳琪[1]

1.大连海洋大学信息工程学院/大连市智慧渔业重点实验室/大连海洋大学设施渔业教育部重点实验室,大连 116023; 2.辽宁省海洋信息技术重点实验室,大连 116023

摘要 为提升水产疾病防治中复杂与多层次因果关系抽取的准确性,引入一种双向焦点增强机制(bidirectional focus enhancement mechanism,BFM),提出RoBFM模型(RoBERTa-wwm-ext-large bidirectional focus enhancement mechanism)。该模型结合预训练语言模型RoBERTa-wwm-ext-large生成高质量词嵌入,并利用双向长短时记忆网络(bi-directional long short-term memory,BiLSTM)增强长距离依赖性建模。RoBFM的核心是通过BFM机制的前后向权重分配,强制解耦并聚焦因果语义角色。为全面评估模型性能,在公开数据集DuIE和自建的领域专用数据集DLOU-CRE上开展了基线对比试验与消融实验。试验结果显示,该模型在公开数据集DuIE和自建的领域专用数据集DLOU-CRE上的F_1值等指标均优于现有模型。尤其在DLOU-CRE数据集上,F_1值达到了68.23%。结果表明,该方法用于水产病害防治因果关系抽取中具有更好的效果。

关键词 因果关系抽取; 双向焦点增强机制; RoBFM; 水产病害防治

中图分类号 TP391.1; S941 **文献标识码** A **文章编号** 1000-2421(2026)03-0161-12

水产养殖业的快速集约化发展正面临日益严峻的病害挑战。以对虾白斑综合征、罗非鱼链球菌病为代表的流行性疫病频发,导致养殖群体的大规模死亡,不仅直接冲击生产效率与水产品质量,造成巨额经济损失,更对区域性水产供应链的稳定性构成了严重威胁。在此背景下,如何从海量数据中实现对水产病害因果链的精准、高效自动抽取与解析,已成为推动智慧渔业发展、实现精细化病害防控的迫切需求[1-3]。

因果关系抽取作为信息抽取领域的核心任务,其技术范式经历了从规则匹配、传统机器学习向深度学习演进的历程。早期研究主要聚焦于显性语言特征的挖掘,试图通过构建严密的语言学规则来捕捉因果逻辑。例如,Khoo等[4]通过归纳因果线索词构建模式库,从新闻语料中识别显性因果;Girju等[5]引入句法约束机制进行校验。尽管此类“硬编码”策略在规范文本中表现尚可,但在面对水产领域非结构化、跨模态的复杂文本时,因缺乏泛化能力而显得捉襟见肘。为缓解规则方法的僵化问题,统计机器学习被引入该领域,并逐渐形成了“流水线”式的处理范式。Girju等[6]和Luo等[7]分别从约束触发词优化和大规模语料库因果强度度量入手,提升了抽取的自动化水平。然而,这种分阶段处理模式割裂了实体与关系的内在联系,且受限于特征工程的完备性,传统机器学习模型在应对隐性、模糊或长距离因果依赖时,往往难以突破泛化瓶颈。

随着深度学习技术的兴起,凭借深度神经网络在特征自动抽取方面的显著优势,因果关系抽取研究正式迈入了深度语义理解的新阶段。CNN与RNN等架构被广泛应用于捕捉文本深层特征,有效应对了表述的隐含性与模糊性挑战。De Silva等[8]率先利用卷积神经网络对文本进行局部特征编码,以识别常识性因果逻辑;Li等[9]进一步提出面向知识的CNN架构,通过融合外部词汇知识库的先验信息来增强分类性能。与此同时,Dasgupta等[10]则利用长短期记忆网络在序列建模上的优势,从语言学视角深入解析了因果关系的表达能力。近年来,BERT[11]、RoBERTa[12]等预训练语言模型的出现带来了里程碑式进展,有效缓解了长文本处理和大规模数据依赖的问题。

收稿日期: 2025-06-30
基金项目:辽宁省重点研发计划项目(2023JH26/10200015)
曹佩荣,E-mail:caopeirong08@163.com
通信作者: 张思佳,E-mail:zhangsijia@dlou.edu.cn

尽管现有技术取得了长足进步，但在处理水产病害防治这类垂直领域的复杂文本时，仍面临深层挑战：一方面，领域适应性不足。现有预训练模型主要依赖上下文捕获词汇共现及句法结构，缺乏对因果逻辑的专门建模与优化，导致其在抽取实体间的动态交互及多层级因果链条时表现欠佳[13-14]。另一方面，隐性推理能力匮乏。尤其在缺乏显性触发词的语境中，模型对隐含因果的敏锐度较低[15]。例如，在“水温突降导致鱼体肾功能下降，从而诱发细菌感染”这类包含多层级、链式触发的复杂语义中，现有模型的逻辑推理与长距离依赖捕捉能力均显不足。

针对上述痛点，本研究提出了一种融合双向焦点增强机制的RoBFM模型。该模型旨在打破技术瓶颈，将海量、非结构化的专业病害文献转化为机器可理解的结构化因果知识。这些结构化知识是构建水产病害知识图谱和智能诊断专家系统的底层基石。通过本模型，系统能够自动梳理出“环境因子-病理反应-疾病暴发”的完整演化逻辑，从而为基层养殖户提供即时的病情预警与科学的防治决策支持。

1 材料与方法

1.1 因果关系数据集构建

为支持水产养殖病害防治领域的因果关系抽取，本研究构建了一个高质量的领域专用数据集，命名为DLOU-CRE。其构建流程如下：

1）数据收集与预处理。数据集的文本内容主要来源于权威水产学术期刊、行业技术报告及领域专家提供的文献资料，确保所采集文献与水产养殖疾病防治问题高度相关。在获取原始文本后，进行了严格的预处理，对原始文本进行语义单元切分，清洗特殊字符、格式错误及不规范内容，确保数据统一规范。

2）因果实体定义与BIO标注规则。因果实体分析与标注是DLOU-CRE数据集构建的核心环节。深入分析了水产动物病害防治领域的因果关系要素，并对原因实体和结果实体进行了细致的定义。采用BIO标注规则（B-Begin，I-Inside，O-Outside）对因果实体进行精确标注：原因实体标记为‘B-C’/‘I-C’，结果实体标记为‘B-E’/‘I-E’，无关词汇标记为‘O’。表1展示了一个具体的标注示例，清晰地说明了如何根据BIO规则对因果实体进行标记。

表1 标注样例

Table 1 Annotation example

原文文本 Original text	标注标签 Label
由于 Duo to	O
水温 Water temperature	B-C
急剧下降 Sharp decline	I-C
，	O
鱼类 Fish	B-E
免疫力 Immunity	I-E
下降 Decline	I-E
。	O

3）数据集统计与特性及典型样本分析。本研究构建的DLOU-CRE数据集共包含3 682条经过专家校验的标注样本。为确保数据集能够真实映射水产养殖中“环境-病原-宿主”的三元互作机制，本研究遵循“产业痛点导向”原则，对样本进行了严格的类型学分层与分布控制。统计结果（表2）表明，数据集在病害类型、环境诱因及管理干预3个维度上均保持了与实际流行病学特征的高度同构。

表2 DLOU-CRE数据集样本类型分布统计

Table 2 Distribution statistics of sample types in the DLOU-CRE dataset

样本类别 Sample category	典型实体 Typical entity	样本数量 Sample size	占比/% Proportion
传染性病原类	白斑综合征病毒（WSSV）、链球菌、气单胞菌、草鱼呼肠孤病毒等	1 561	42.4
环境因子类	氨氮（NH_3-N）、亚硝酸盐、溶解氧、pH值、水温骤变等	1 248	33.9
养殖管理决策类	投饵率、放养密度、换水、增氧机启停、微生物制剂投放等	873	23.7

具体而言，传染性病原类样本占比最大（42.4%），涵盖了对虾白斑综合征（WSSV）、罗非鱼链球菌病等高致死率病害，重点强化模型对显性病理特征的捕捉能力；理化环境因子类样本占比达到33.9%，高密度覆盖了氨氮、溶氧及温度突变等关键胁迫指标，旨在训练模型识别“水质恶化”引发的隐性致病逻辑；养殖管理决策类样本收录了23.7%，聚焦于投喂策略、密度调控等人工干预措施。这种数据分布策略不仅涵盖了从苗种标粗到成鱼养成的全生命周期场景，更在特征层面完整保留了“环境因子恶化（因）→免疫力下降（机理）→继发感染（果）”的链式语义结构，从而有效提升了模型在复杂生产语

境下的可信度与泛化潜力。

从数据分布特征来看，DLOU-CRE展现出高信息密度的特质。一方面，非背景类标签的有效占比高达38.4%。这一比例高于通用稀疏文本数据集，该语料库剔除了无关冗余信息；另一方面，从因果逻辑分布来看，数据集涵盖显性因果约27%，隐性因果约73%。为了直观解析文本的复杂性，表3展示了2类样本的语言学特征对比。

表3　显性与隐性因果关系样本对比

Table 3　Comparison of explicit and implicit causal relationship samples

关系类型 Relationship types	文本示例 Text examples	特征分析 Feature analysis
显性因果	溶氧量过低导致鱼类窒息死亡	含触发词“导致”传统模型易于抽取
隐性因果	养殖密度过大，水体富营养化严重	无触发词。前后分句呈“环境因子-环境结果”逻辑，依赖深层语义进行判断
隐性因果	投喂变质饲料，草鱼肠壁充血发炎	无触发词。通过知识判断“摄食”与“病变”的内在联系，是抽取的难点

4)数据与代码开源声明。为增强本研究试验结果的可复现性与透明度，并填补该领域公开资源的空白，本研究构建的DLOU-CRE数据集样本及核心模型代码已在GitHub平台开源*。

1.2　RoBFM模型抽取框架

RoBFM模型的整体架构如图1所示。该模型通过多层次信息处理与BFM模块，旨在克服传统方法在处理隐性及复杂因果关系上的不足，实现水产病害防治文本中因果关系的精准抽取。其核心工作流程包括：RoBERTa生成初始词嵌入、BiLSTM增强上下文建模、BFM动态加权聚焦以及分类器输出最终结果。

1)RoBERTa嵌入层。模型首先利用RoBERTa-wwm-ext-large预训练语言模型对输入文本进行编码。RoBERTa采用全词掩蔽(whole word masking，WWM)策略[16]，相比BERT能生成更准确的词级嵌入，并有效捕获中文文本的词边界信息和丰富的上下文语义。这一步骤的目标是为后续的因果关系抽取任务提供高质量的初始特征表示。

2)BiLSTM上下文编码层。在获得RoBERTa生成的词级嵌入后，模型进一步通过BiLSTM对语义信息进行增强建模。RoBERTa虽然提供了强大的全局上下文表征，但在捕获序列的局部依赖和精确的长距离依赖方面仍存在一定局限。BiLSTM通过前向和后向2个方向的隐状态传递，能够有效捕捉句子中的长距离依赖关系，同时保留局部上下文信息。具体公式如(1)～(4)所示。

$$\overrightarrow{h_t}=\mathrm{LSTM}\left(x_t,\overrightarrow{h}_{t-1}\right) \tag{1}$$

$$\overleftarrow{h_t}=\mathrm{LSTM}\left(x_t,\overleftarrow{h}_{t+1}\right) \tag{2}$$

$$h_t=\left[\overrightarrow{h_t};\overleftarrow{h_t}\right] \tag{3}$$

$$H=\left[h_1,\cdots,h_n\right] \tag{4}$$

这种结合充分利用了RoBERTa的深层语义编码能力与BiLSTM的序列建模优势，两者互补增强，为模型处理水产养殖病害文本中复杂的因果关系提供了鲁棒性更强的上下文信息。

3)BFM模块。针对水产病害因果逻辑呈现典型的“环境-生理-病理”长链条特征，BFM模块提出了一种双向显式因果建模策略。该机制通过引入独立的前向与后向权重矩阵，分别强制聚焦“环境诱因”与“病理结果”，在特征层面实现了语义角色的显式解耦。这一设计将文本中隐性的深层关联转化为显式的注意力焦点，有效解决了水产文本在无触发词语境下的特征稀疏与背景噪声干扰问题。其计算流程形式化如下。设BiLSTM输出的隐藏状态序列为H。前向焦点机制通过参数矩阵W_f和偏置b_f计算注意力权重α_t并聚合生成前向上下文c_f，如公式(5)～(6)所示。同理，后向焦点机制通过参数W_b，b_b生成后向上下文c_b，如公式(7)～(8)所示。最后，将拼接两者得到增强语义表示V。如公式(9)所示。

$$\alpha_t=\mathrm{softmax}\left(W_f h_t+b_f\right) \tag{5}$$

$$c_f=\sum_{t=1}^{n}\alpha_t h_t \tag{6}$$

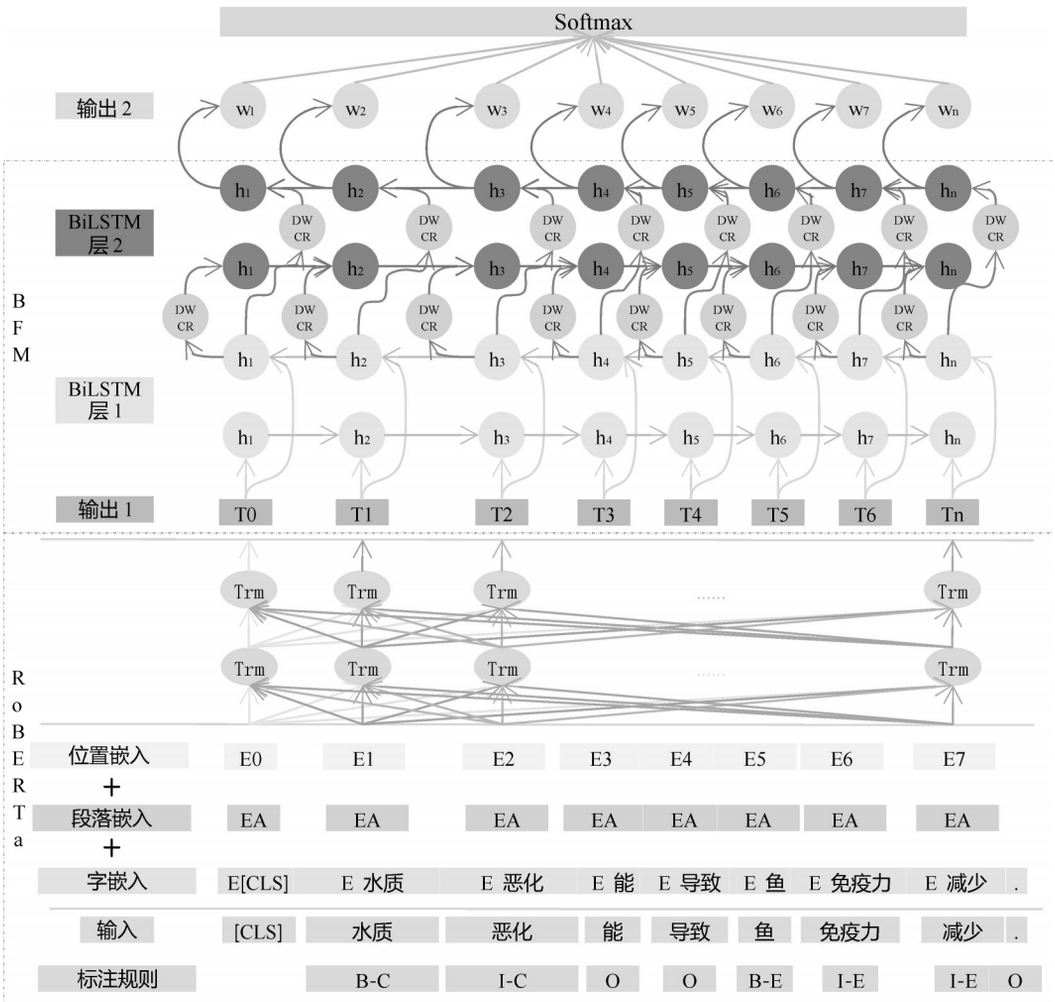
$$\beta_t=\mathrm{softmax}\left(W_b h_t+b_b\right) \tag{7}$$

$$c_b=\sum_{t=1}^{n}\beta_t h_t \tag{8}$$

$$V=\left[c_f;\,c_b\right] \tag{9}$$

4)分类器输出层。经过BFM加权后的语义表示V被输入到最终的分类器中。分类器采用全连接神经网络结构，负责根据焦点增强表征生成最终的因果关系抽取结果。接着，使用softmax函数对输出进行归一化，生成每个词的分类概率分布，从而为每个词分配最终的类别标签(B-C，I-C，B-E，I-E，O)，完成因果关系抽取任务。具体公式如(10)～(11)所示。

$$z_t=W_c V+b_c \tag{10}$$



图中B-C/I-C、B-E/I-E依次指原因与结果实体的起始与结束标注标签，O为其他标签。E、EA、E0～E*n*为字、段落与位置嵌入；Trm为Transformer模块；T0～T*n*为预训练特征。BFM层中h为隐藏状态；DW、CR分别指方向权重与因果角色特征；w1～w*n*为最终加权输出向量。In the figure, B-C/I-C and B-E/I-E denote the beginning and ending labels of the cause and effect entities respectively, and O represents other labels. E, EA, E0-E*n* are character, paragraph, and positional embeddings; Trm is the Transformer module; T0-T*n* are pre-trained features. In the BFM layer, h is the hidden state; DW and CR represent directional weights and causal role features respectively; w1-w*n* are the final weighted output vectors.

图1 模型构架

Fig. 1 Model architecture

$$P = \mathrm{softmax}(z_t) \tag{11}$$

式(10)中，W_c、b_c是学习参数。最终，根据概率分布为每个词分配类别标签，并拼接标签形成完整的因果关系表征，返回抽取出的因果关系实体。

1.3 试验设置与验证策略

1)试验环境与参数配置。试验基于Windows10(64 bit)操作系统，硬件环境采用英特尔Core i5-10400F @2.9GHz六核处理器、16 GB运行内存及NVIDIA GeForce RTX 4090图形处理器，以Python 3.8为编程语言，在PyCharm 2023.1开发环境下完成。模型的训练参数经过优化设置：最大序列长度max_sequence_length为512，训练轮次epochs为13，学习率learning_rate设置为2e-5。BiLSTM的单向隐层大小设置为1 024，Dropout比率设置为0.3用于BiLSTM输出后。BFM模块的内部迭代次数设置为16次。

2)验证策略与鲁棒性控制。为了最大限度地利用有限的标注数据，并客观评估模型在非平衡样本下的泛化性能，本研究采用了K折交叉验证(K-fold cross-validation)策略。该方法的核心逻辑在于将原始数据集随机划分为K个互斥的子集，每次迭代选取其中K-1个子集构建训练集，剩余的1个子集作为

验证集。经过K轮循环训练与评估后，取各项评价指标的平均值作为最终的模型性能得分。这种全量验证机制有效消除了因数据集单次随机划分而引入的偶然性偏差。具体而言，鉴于DLOU-CRE数据集具有样本量相对较小且实体密度高的特性，为严格抑制潜在的过拟合风险并验证模型的鲁棒性，本研究将K值设定为5，实施5折交叉验证试验流程，其具体划分逻辑如图2所示。

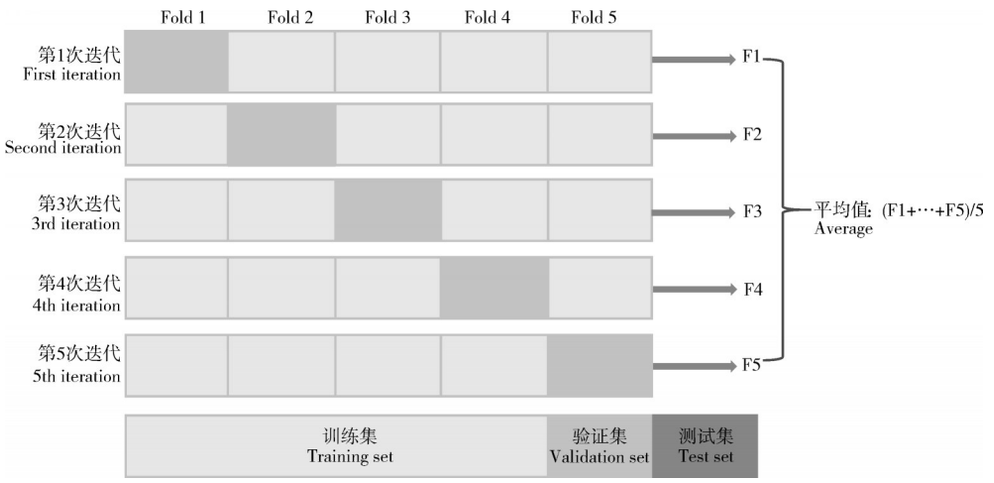


图2　5折交叉验证划分逻辑

Fig. 2　Logic of 5 fold cross-validation division

1.4　评估指标

为全面评估模型的性能，本研究采用了因果关系抽取任务中最常用的精确率(P)、召回率(R)和F_1值作为评价指标。这些指标将分别针对“原因”和“结果”2个核心标签的抽取性能进行计算，并最终综合验证模型的整体效果。尽管“O”标签在数据中占据较大比例，但其主要作为背景类，核心评估集中在因果实体类别的抽取上。具体的评价指标计算公式如(12)～(14)所示：

$$P=\frac{T_p}{T_p+F_p}\times 100\% \tag{12}$$

$$R=\frac{T_p}{T_p+F_N}\times 100\% \tag{13}$$

$$F_1=\frac{2\times P\times R}{P+R}\times 100\% \tag{14}$$

其中，T_p表示正确预测为因果关系正例的数量，F_p表示错误预测为因果关系正例的数量。F_N表示实际为因果关系正例但预测为负例的数量。F_1值作为精确率和召回率的调和均值，能够综合衡量模型的精确性和召回能力，为评估模型在“原因”和“结果”标签抽取方面的表现提供了全面且平衡的视角。

2　结果与分析

2.1　预训练模型选择与性能评估

为全面评估RoBFM模型的泛化能力与领域适应性，本研究构建了跨领域的对比实验框架，选取了通用领域权威数据集DuIE与自建的领域专用数据集DLOU-CRE作为试验对象。DuIE数据集作为百度发布的业界权威大规模中文关系抽取基准，数据集包含超过21万条句子，以及45万个三元组实例，广泛覆盖了金融、娱乐、百科等开放域场景。引入该数据集旨在验证模型在处理异构、复杂通用文本时的鲁棒性。然而，尽管DuIE具有显著的规模优势，但DuIE缺乏针对农业中水产病害防治领域特有的隐性因果逻辑，例如由“水质理化指标交互”诱发的隐性病害。这种信息知识的缺失，导致DuIE难以精准评估模型在垂直领域复杂语境下的实际效能。

针对上述不足，本研究引入了DLOU-CRE数据集。尽管其3 682条的样本规模小于通用数据集，但DLOU-CRE作为专为水产病害防治场景构建的语料库，具有极高的信息密度。该数据集不仅由领域专家深度参与标注，确保了专业实体边界的精确性；更关键的是，它高密度地覆盖了水产领域隐性因果关系及多因素链式反应模式。这种“小而精”的特质使得DLOU-CRE能够有效填补通用数据集在垂直知识上的空白，为激发预训练模型在任务中的推理潜能提供了高质量的数据支撑。

在DuIE数据集和DLOU-CRE数据集架构的基础上，为进一步验证RoBFM核心组件RoBERTa-wwm-ext-large的性能表现，本研究设计了系列对比试验，选取BERT、RoBERTa及BERT-wwm等主流

模型作为基线。试验结果详见表4，不同数据集的性能指标对比示于图3。结果显示：相较于通用数据集，DLOU-CRE能够显著提升模型对隐性病害机理的抽取精度，充分体现了高质量领域专用数据在解决特定科学问题时的关键价值。

表4 试验结果

Table 4 Test results %

数据集 Dataset	模型 Model	P	R	F_1
DuIE	BERT	66.20	61.27	63.64
	RoBERTa	63.45	67.15	65.25
	BERT-wwm	61.86	59.25	60.53
	RoBERTa-wwm-ext-large	66.29	63.10	64.66
DLOU-CRE	BERT	61.48	66.35	63.82
	RoBERTa	65.81	69.40	67.56
	BERT-wwm	63.17	63.85	63.51
	RoBERTa-wwm-ext-large	65.86	70.77	68.23

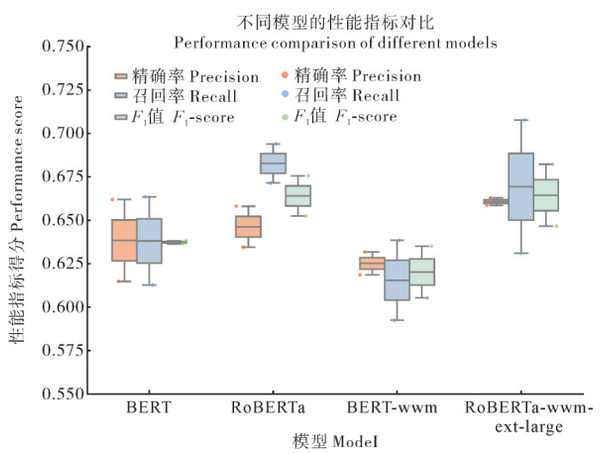


图3 不同模型的性能指标对比

Fig. 3 Performance comparison of different models

由表4与图3可见，尽管DLOU-CRE的样本量远小于DuIE，但所有模型在该数据集上的召回率(R)与F_1值均显著更高。这一现象符合预训练语言模型在垂直领域的普遍规律：数据质量与领域适配性在特定任务中起主导作用。DuIE数据集虽然规模巨大，但其来源异构、包含大量非因果噪声，导致模型在抽取特定逻辑关系时召回受限；相比之下，DLOU-CRE具有极高的信噪比与专家知识密度。RoBFM结合BFM机制，能够在此类高一致性数据上快速适应并收敛，从而在小样本条件下实现了比大规模通用数据集更高的性能表现。

具体而言，以BERT模型为例，它在DLOU-CRE上的召回率显著高于DuIE模型，带动了F_1值的整体上扬。这种性能增益在引入更强大的预训练基座，如RoBERTa及RoBERTa-wwm-ext-large后表现得尤为显著。数据统计显示，在RoBERTa-wwm-ext-large模型上，DLOU-CRE的召回率相较于DuIE提升了7.67百分点，最终推动F_1值达到68.23%（表4）。这一显著的性能跨越有力地证明了：在处理复杂因果关系抽取任务时，高质量的垂直领域数据能够更有效地激发大规模预训练模型的深层语义理解潜能。

综上所述，DLOU-CRE数据集的构建对于提升领域任务性能具有决定性作用。特别是当其与RoBERTa-wwm-ext-large结合时，能够形成“强模型＋强数据”的协同效应。这不仅验证了数据质量的重要性，也为本研究最终选择RoBERTa-wwm-ext-large作为RoBFM的基础架构提供了坚实的实证依据。

2.2 不同模型对比试验

为全面验证RoBFM模型的有效性，本研究在通用数据集DuIE和领域专用数据集DLOU-CRE上，与多种主流基线模型进行了系统性的性能比较。选取的基线模型涵盖了从传统序列标注到预训练语言模型再到大语言模型(LLMs)的代表性研究方法，具体如下：

1)-P模型(BiLSTM-CRF)[17]。其局限在于难以捕捉复杂或长距离的隐性因果关系，如链式关联，导致召回率较低。

2)-R模型(TF-ChineseERE)[18]。该模型在处理非结构化关系时建模能力较弱，并在面对中文复杂句式如倒装、省略时，精确率显著下降。

3)-BC模型(BERT-CRF)[19]。该模型过度依赖显性的因果触发词，在处理隐式因果关系时表现乏力。

4)-LC(BERT-BiLSTM-CRF)[20]。尽管增强了上下文建模，但其对因果特征的权重分配是静态的，缺乏动态关注机制，限制了对复杂场景的适应性。

5)RoBERTa和BERT模型。虽然具备出色的通用语义理解能力，但缺乏针对因果逻辑的优化，难以有效解析实体间的动态交互与多层级依赖，导致在隐性关系抽取上的精确率与召回率受限。

6)大语言模型(LLMs)。引入ChatGLM4-9B和Qwen2.5-7B作为对照，探究生成式范式在垂直领域信息抽取中的表现。

与上述基线模型相比，RoBFM引入BFM机制，

通过动态调整BiLSTM输出权重，实现了对因果关键特征的显式解耦与聚焦。得益于RoBERTa-wwm-ext-large的深层抽象表征与BFM的精准定位能力，RoBFM显著降低了模型对显性触发词如“导致”“因为”的依赖，大幅提升了在复杂语境下的泛化性能。试验结果如表5所示。

表5　试验结果

Table 5　Test results　　%

数据集 Dataset	模型 Model	P	R	F_1
DuIE	−P	61.02	50.43	55.22
	LSTM	63.41	58.13	60.66
	−R	58.71	64.08	61.28
	BERT	66.20	61.27	63.64
	−BC	59.67	60.15	59.91
	−LC	64.70	64.92	64.81
	RoBERTa	63.45	67.15	65.25
	RoBFM	66.29	63.10	64.66
DLOU-CRE	−P	60.39	51.35	55.50
	LSTM	62.70	64.90	63.78
	−R	58.50	59.90	59.12
	BERT	61.48	66.35	63.82
	−BC	58.14	63.91	60.89
	−LC	62.93	65.01	63.96
	ChatGLM4-9B	58.25	62.10	60.11
	Qwen2.5-7B	60.45	65.30	62.78
	RoBERTa	64.36	69.71	66.93
	RoBFM	65.86	70.77	68.23

注：“−P”表示BiLSTM-CRF对比模型；“−R”表示TF-Chinese-ERE对比模型；“−BC”表示BERT-CRF对比模型；“−LC”表示BERT-BiLSTM-CRF对比模型。Note：‘−P’ represents the BiLSTM-CRF comparison model；‘−R’ represents the TF-Chinese-ERE comparison model；‘−BC’ represents the BERT-CRF comparison model；‘−LC’ represents the BERT-BiLSTM-CRF comparison model.

RoBFM模型在因果关系抽取任务中的表现显著优于其他传统方法及未集成BFM的预训练语言模型，F_1指标提升明显。表现在以下4个维度的优势：

1）泛化能力验证。为验证BFM机制的跨领域有效性，本研究通过通用数据集DuIE进行测试。DuIE涵盖了娱乐、人物等广泛的开放域文本。试验结果显示，RoBFM在DuIE上的F_1值达到64.66%，显著优于−P等主流基线模型。这一结果证明了BFM机制具备良好的跨领域迁移性：其核心的双向焦点策略本质上是对自然语言中普遍存在“原因-结果”的因果逻辑结构进行建模，而非单纯依赖于特定领域的词汇特征。因此，该机制不仅适用于水产病害领域，在处理其他领域的复杂因果文本时同样具备鲁棒性。

2）召回率R提升与风险阻断。在水产病害防控中，“漏判”意味着错失最佳治疗窗口，极易导致病情由点及面暴发。试验数据显示，RoBFM在DLOU-CRE数据集上的召回率高达70.77%，显著优于基线模型。这种高召回率的工程意义在于模型具备极高的敏锐度，能够有效捕捉“摄食量微降”“离群独游”等淹没在大量日常数据中的微弱前兆信号。基于业务场景的量化推演表明，相较于基线模型，RoBFM的性能提升意味着在每处理10 000条非结构化养殖日志时，能够多识别出约22条高危隐性预警。这种将“沉默数据”转化为“有效情报”的能力，支持系统在病害“潜伏期”即发出预警，对于从源头阻断对虾白斑综合征等高致死率传染病的扩散具有决定性的止损价值。

3）精确率P提升与降本增效。针对实际生产中存在的非因果噪声（如天气预报、市场行情等），RoBFM表现出卓越的抗干扰能力。表5数据显示，引入BFM机制后，模型在处理负例时的误报率较BERT等模型降低了约4.41百分点。从运维经济学的角度解读，精确率的提升直接对应于“虚警率”的下降。在集约化养殖的自动化监控场景中，这一改进意味着每1 000次系统报警中，可减少约44次无效的人工现场核查与不必要的应激性操作，如换水、投药。这不仅大幅降低了运维人员的无效劳动工时，更避免了因误判导致的药物滥用，从而在降低直接经济成本的同时，减少了对水体生态的次生破坏。

4）模型定位优势。引入ChatGLM4-9B和Qwen2.5-7B的对比结果表明，尽管LLMs拥有强大的通用理解能力，但在垂直领域序列标注任务中，其F_1值仍低于RoBFM。这是由于通用LLM缺乏领域深层知识注入，且在严格的实体边界识别上不如判别式模型精准。这证明了在算力受限且对精确率要求极高的专业场景下，经过设计小模型（RoBFM）在性能与效能比上依然优于通用大模型，具备不可替代的应用价值。

2.3　资源消耗与效率评估

为了评估RoBFM模型的实际部署可行性，本研究统计了该模型在参数量、训练效率及显存占用等方面的数据，并与RoBERTa-wwm-ext-large进行了对比，如表6所示。引入BiLSTM和BFM模块后，模

型整体参数量仅增加了约4×10^6，增长率约为1.1%，显存占用增加约0.7 GB。在推理速度方面，单样本处理延迟仅增加了6 ms。在训练效率上，RoBFM的单轮训练耗时仅为4.2 min，证明在极短时间内完成全量微调，便于应对水产病害数据的快速更新迭代。综上所述，RoBFM在显著提升因果抽取精度的同时，仅引入了极微小的计算开销，具备极高的工程部署性价比。

表6 模型资源消耗对比

Table 6 Comparison of model resource consumption

模型 Model	参数量 Number of parameters	单样本推理延迟/ms Single-sample inference latency	显存峰值/GB Peak memory usage	单轮训练耗时/min Time per training iteration
RoBERTa-wwm-ext-large	351×10^6	21	8.5	3.5
RoBFM	355×10^6	27	9.2	4.2

2.4 交叉验证与鲁棒性分析

针对水产病害防治领域标注数据获取难度大、样本量相对较小(3 682条)的现状，为了排除模型因数据划分偶然性导致的性能虚高，并严格评估模型在小样本环境下的过拟合风险，本研究在DLOU-CRE数据集上实施了5折交叉验证(5-fold cross-validation)。具体试验方案如下：将数据集随机打乱并均分为5个互斥的子集。依次选取其中1个子集作为测试集，其余4个子集作为训练集，共进行5轮独立试验。试验过程中保持超参数设置一致，最终记录每一折的F_1值及其波动情况。RoBFM模型在5折交叉验证下的详细表现如表7所示。试验结果显示：在5轮独立试验中，RoBFM的F_1值始终稳定在67.45%～69.29%，标准差仅为0.61%。这表明模型性能并未出现剧烈波动，证明其并未对特定的训练集划分产生过拟合现象；即便在表现最差的一折(Fold-4，F_1=67.45%)中，RoBFM的性能依然显著优于强基线模型RoBERTa(66.93%)。这一结果有力地证实了BFM机制在小样本高密度数据下的鲁棒性，即通过显式聚焦因果特征，降低了模型对背景噪声的敏感度，从而保证了在不同数据分布下的一致性表现。

表7 RoBFM模型5折交叉验证结果

Table 7 5-fold cross-validation results of the RoBFM model %

试验轮次 Test rounds	P	R	F_1
Fold-1	65.42	70.15	67.70
Fold-2	66.10	71.20	68.55
Fold-3	65.88	70.55	68.13
Fold-4	65.25	69.80	67.45
Fold-5	66.65	72.15	69.29
平均值 Average	65.86±0.54	70.77±0.82	68.23±0.61

注：表中的平均值即为本研究的最终模型性能指标，“±”后数值为标准差。Note: The average values in the table are the final model performance metrics reported in this paper, and the numbers following “±” are the standard deviations.

2.5 消融实验

为量化各组件对模型性能的边际贡献，本研究在DLOU-CRE数据集上实施了消融实验，结果如表8所示。完整模型RoBFM取得了最优的F_1值68.23%，验证了各模块的协同有效性。为便于分析，定义以下变体模型：

(1)RoBFM-R：移除完整模型中的RoBERTa组件；(2)RoBFM-Bi：移除完整模型中的BiLSTM组件；(3)RoBFM-B：移除完整模型中的BFM组件；(4)RoBFM：包含所有组件的完整模型。

由表8的数据可见：(1)RoBFM-R模型的F_1值较基线模型RoBFM下降8.04百分点，降幅显著。这证实了动态词嵌入在处理水产领域多义术语及复杂句式时的关键作用，缺失该模型会使模型退化为对静态词向量的浅层依赖，难以捕捉深层语义。(2)RoBFM-Bi模型的F_1值较基线模型RoBFM下降4.66百分点。这表明在处理“溶解氧过低……诱发缺氧性死亡”等长跨度文本时，BiLSTM提供的长距离依赖建模能力是连接远距离实体对的关键桥梁，有效弥补了Transformer架构在局部序列特征捕捉上的不足。(3)RoBFM-B模型的F_1值较基线模型下降3.61百分点。尽管降幅略低，但其对隐性因果

表8 消融实验

Table 8 Ablation experiment

变体模型 Variant model	RoBERTa	BiLSTM	BFM	F_1/%
RoBFM-R	×	√	√	60.19
RoBFM-Bi	√	×	√	63.57
RoBFM-B	√	√	×	64.62
RoBFM	√	√	√	68.23

注：“√”表示包含该模块，“×”表示移除该模块。Note: “√” indicates the module is included, and “×” indicates the module is removed.

的解析至关重要。消融结果证明，BFM 通过前向和后向权重的显式解耦如公式(8)～(12)，成功实现了从复杂背景噪声中对因果特征的精准剥离，显著提升了模型在多因素交互场景下的鲁棒性。

综上，这 3 个模块在 RoBFM 架构中均发挥着不可或缺的作用，共同构建了高性能的抽取框架。

2.6　应用实例分析与工程落地场景

通过典型实例进行详细说明，具体实例如表 9 所示。对比分析 RoBFM 相较于基线模型的行为差异，并探讨其实际生产价值。

1)复杂因果模式的解析。如表 9 所示，基线模型受限于对显性触发词的依赖，往往仅能抽取浅层直接因果。相比之下，RoBFM 展现了深层语义解析能力：在“水温突降…免疫力下降 …感染”案例中，RoBFM 精准捕捉了“免疫力下降”这一中间变量，完整复原了病害演化路径；针对“水质/饲料/密度”共同致病的多对一模式，模型利用前向焦点机制有效分离了并列原因实体，克服了传统模型易漏检并列项的缺陷；在“高温……而是由于继发感染”案例中，模型准确识别了“并未直接导致”的否定语义，成功排除了错误的直接因果，锁定了真实病因。

2)实际生产应用价值分析。RoBFM 的高精度抽取能力可直接转化为智慧渔业的决策生产力：

①前置性干预：通过识别链式因果中的中间环节，如免疫力下降，智能系统可提前预警潜在风险，指导养殖户从“事后治疗”转向“事前阻断”，如投放增强剂。

②精准诊疗支持：模型对隐性病理机制，如呼吸功能受损及否定因果的准确解析，可为制定科学急救方案提供依据，有效防止因误诊或盲目用药，如错误的物理降温造成的经济损失。

③综合病害防控：对多重致病因子的完整溯源，支持系统生成全方位的治理清单，协助养殖户实施水质、饲料与密度的综合调控，避免病情反复。

综上所述，RoBFM 不仅实现了算法层面的精度突破，更为构建高可信的水产病害知识图谱与临床决策支持系统提供了核心技术支撑。

表 9　应用实例

Table 9　Application examples

文本信息 Text information	未使用BFM结果 Results without BFM	使用BFM结果 Results with BFM
水温突降会导致鱼体免疫力下降，从而诱发细菌性感染。	关系：水温突降→细菌感染	因果关系 1：触发词：导致，原因：水温突降，结果：鱼体免疫力下降 因果关系 2：触发词：从而，原因：鱼体免疫力下降，结果：细菌性感染
溶解氧过低会影响鱼类呼吸功能，进而引发缺氧性死亡。	关系：溶解氧过低→缺氧	因果关系 1：触发词：影响，原因：溶解氧过低，结果：鱼类呼吸功能受损 因果关系 2：触发词：进而，原因：鱼类呼吸功能受损，结果：缺氧性死亡
多重原因导致单一结果：水质恶化、饲料变质、高密度养殖共同引起鱼类大量死亡。	关系：水质恶化→死亡	因果关系 1：触发词：引起，原因：水质恶化，结果：鱼类大量死亡 因果关系 2：触发词：引起，原因：饲料变质，结果：鱼类大量死亡 因果关系 3：触发词：引起，原因：高密度养殖，结果：鱼类大量死亡
否定性因果：高温季节并未直接导致鱼群死亡，而是由于继发感染。	关系：高温季节→无死亡	因果关系：触发词：而是由于，原因：继发感染，结果：鱼群死亡

3)模型在典型养殖模式中的工程化应用。实际上，RoBFM 模型不仅是一个因果关系提取算法，更是构建水产病害智能诊疗系统的底层逻辑引擎。针对当前主流的工厂化循环水养殖与集约化池塘养殖 2 种生产模式，本研究设计了差异化的应用流程，以解决不同场景下的痛点，如图 4 所示。

①工厂化循环水养殖中的风险因子智能联动。在高度自动化的工厂化循环水养殖车间中，传统系统往往仅依据单一水质指标，如氨氮、溶氧的阈值进行机械报警，缺乏对病害发生的预判能力。RoBFM 模型在此场景中充当了“推理中枢”的角色。当物联网传感器捕捉到水质异常波动时，系统不再是孤立地报错，而是调用 RoBFM 构建的因果知识库进行链式推理。例如，当监测到“亚硝酸盐持续微升”配合“投饵量未变”的数据特征时，模型能迅速激活“残饵分解不全(原因)到亚硝酸盐胁迫(环境因子)再到鱼类鳃组织充血(病理结果)”的隐性因果链。基于此推理，中控系统将自动匹配预设的防控策略，执行“暂停投喂”“开启蛋白分离器”或“加大换水率”的组合指令。这种机制将传统的“阈值报警”转变为主动的“调水决策”，有效利用了模型对长距离因果依赖的捕捉能力，降低了系统性养殖风险。

②高密度池塘养殖中的移动端辅助诊疗。面对基层养殖户专业病理知识匮乏、描述不规范的现状，RoBFM 被部署于移动端专家系统的后台，用于处理非结构化的自然语言查询。在池塘养殖现场，养殖

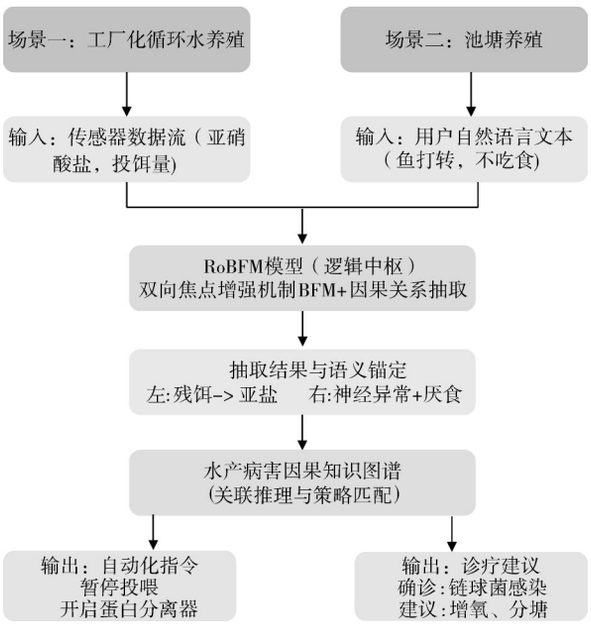


图4 应用流程图

Fig. 4 Application flowchart

户往往使用“鱼在水面打转”“不吃食”等口语化、模糊的表述。得益于BFM机制对语义焦点的双向增强，模型能够穿透这些非专业术语，精准锚定其背后的病理特征，如“神经系统异常”“摄食障碍”，并将其映射至知识图谱中对应的致病源，如链球菌感染。随后，系统不仅能输出确诊结果，还能依据抽取的“环境-病害”因果逻辑，生成具体的管理处方。例如，当模型识别出病害是由“养殖密度过大”诱发的应激反应时，系统会优先推送“适度分塘”或“通过轮捕轮放降低密度”的建议；若识别出病因为“底质恶化导致的缺氧”，则指导养殖户执行“开启底层微孔增氧”与“投放微生物制剂”的操作。这一流程将抽象的因果关系直接转化为“增氧、调水、控密”等一线操作指南，解决了通用大模型在垂直领域建议空泛的问题，为缺乏技术支持的个体养殖户提供了可信的科学决策依据。

3 讨 论

本研究提出的RoBFM模型，通过深度融合RoBERTa-wwm-ext-large的高质量语义表征、BiLSTM的长距离依赖建模能力以及创新的BFM机制，显著提升了水产病害防治领域隐性与复杂因果关系的抽取效能。试验结果表明，该模型在自建的DLOU-CRE数据集上F_1值达到了68.23%，有效突破了传统方法在无显性触发词场景下的因果推理瓶颈。

在当前LLMs引领NLP技术变革的背景下，本研究基于前文的对比试验（表5），进一步辩证探讨了专用小模型在垂直领域的生态定位。尽管ChatGLM4、Qwen2.5等生成式模型在通用任务中展现了强大的理解能力，但在水产病害防治这一特定的垂直应用场景中，RoBFM模型相较于LLMs仍具备显著的“边界优势”，具体体现在以下3个维度：

1）RoBFM约3.55亿的参数量赋予了其在工程部署上独特的边缘计算优势。与依赖海量算力的通用大模型不同，RoBFM可以低成本地适配于塘口智能网关、手持式水质分析仪等算力受限的嵌入式设备中。这意味着，即便在深远海养殖平台或网络信号覆盖较弱的偏远池塘，设备依然能够基于本地集成的轻量化因果知识库，实现实时的病害逻辑推理与风险预警。这种“端侧智能”的工程定位，切实解决了智慧渔业技术落地“最后一公里”的难题，为构建高覆盖、低成本的数字化防疫体系提供了可行的技术路径。

2）生成式LLMs固有的“幻觉”问题可能导致虚构病害名称或错误的诊疗建议，这在严肃的疾病诊断领域是不可接受的风险。RoBFM作为基于监督学习的判别式模型，其输出空间严格约束于预定义的实体与关系类别内。这种机制赋予了模型极高的结果可信度与可解释性，有效规避了知识谬误风险，确保了辅助诊断的科学性与安全性。

3）在严格的序列标注任务中，LLMs性能仍低于RoBFM（68.23%）。这表明，在缺乏海量领域数据进行全参数微调的情况下，LLM对水产特有的隐性因果逻辑和实体边界的捕捉能力依然有限。RoBFM通过BFM机制显式聚焦因果特征，在“高精度”要求的专业任务中表现出更高的效能比。

此外，明确RoBFM在智慧渔业系统架构中的角色定位对于工程落地至关重要。本研究将RoBFM定义为“嵌入式语义推理中间件”，而非独立的终端应用。在实际部署中，它作为辅助核心模块集成于现有的水产物联网管控平台或专家诊疗系统中。其工程运行逻辑体现为“感知-认知”的解耦与协作：前端监控系统负责采集多源异构数据（如传感器数值、养殖日志文本），RoBFM负责在后台实时解析非结构化文本中的隐性因果逻辑，并将抽取出的结构化三元组注入系统的知识图谱库。为确保系统集成的标准化与通用性，该模块在工程实现上采用轻量级微服务架构，通过RESTful API接口接收前端传输

的养殖日志文本流，并向决策层实时返回标准的JSON格式因果三元组（包含实体ID、关系类型及置信度）。这一设计实现了数据层面的无缝交互，使得最终的决策支持系统（DSS）基于这些动态更新的因果知识生成具体的控制指令（如增氧、换水）。这种“低耦合、可插拔”的模块化设计，使得RoBFM能够灵活赋能于工厂化车间中控、移动端APP等多种业务终端，无需重构现有系统架构即可提升其认知推理能力，从而显著增强了成果的工程适用性与系统集成度。

综上所述，RoBFM在“高精度、低资源、高可信”的边界内，提供了比通用大模型更具性价比和可行性的行业解决方案。

然而，尽管模型表现优异，但仍存在局限性：（1）长文本处理限制：受限于BERT架构的最大序列长度512 Token，模型在处理超长农业技术报告时可能面临信息截断损失；（2）数据分布偏差：虽然数据集经过专家校验，但仍可能存在特定病害样本分布不均的问题。未来的研究计划进一步引入基于滑动窗口的长文本处理机制，探索多语言跨模态迁移学习，并结合知识图谱增强推理，以期为水产健康养殖的智能化发展提供更精准、更全面的技术支持。

参考文献 References

[1] LI Z L，ZHANG S J，ZHANG J Q，et al.AquaMTL-chain：advancing multi-task learning for event extraction in aquaculture [J/OL]. Aquaculture，2026，611：743001 [2025-06-30]. https://doi.org/10.1016/j.aquaculture.2025.743001.

[2] 冉紫涵，张仰森，向尕，等.因果关系抽取研究综述[J].北京信息科技大学学报（自然科学版），2023，38（3）：89-100.RAN Z H，ZHANG Y S，XIANG G，et al.A review of causality extraction studies [J]. Journal of Beijing Information Science & Technology University，2023，38（3）：89-100（in Chinese with English abstract）.

[3] 张思佳，于红.大模型在水产养殖病害防治中的创新应用与展望[J].大连海洋大学学报，2024，39（3）：369-382.ZHANG S J，YU H.Innovative applications and prospects of large models in disease prevention and control for aquaculture：a review [J].Journal of Dalian Fisheries University，2024，39（3）：369-382（in Chinese with English abstract）.

[4] KHOO C S G，KORNFILT J，ODDY R N，et al.Automatic extraction of cause-effect information from newspaper text without knowledge-based inferencing [J]. Literary and linguistic computing，1998，13（4）：177-186.

[5] GIRJU R，MOLDOVAN D. Text mining for causal relations [C]//Proceedings of the 15th International Florida Artificial Intelligence Research Society Conference. Palo Alto：AAAI Press，2002：360-364.

[6] GIRJU R. Automatic detection of causal relations for question answering [C]//Proceedings of the ACL 2003 Workshop on Multilingual Summarization and Question Answering. Sapporo：Japan Association for Computational Linguistics，2003：76-83.

[7] LUO Z Y，SHA Y C，ZHU K Q，et al. Commonsense causal reasoning between short texts [C]//International Conference on Principles of Knowledge Representation and Reasoning. Cape Town，South Africa：Association for the Advancement of Artificial Intelligence（AAAI），2016：421-431.

[8] DE SILVA T N，XIAO Z，ZHAO R，et al. Causal relation identification using convolutional neural networks and knowledge based features [J]. International journal of mechanical and mechatronics engineering，2017，11（6）：703-708.

[9] LI P F，MAO K Z. Knowledge-oriented convolutional neural network for causal relation extraction from natural language texts [J]. Expert systems with applications，2019，115：512-523.

[10] DASGUPTA T，SAHA R，DEY L，et al. Automatic extraction of causal relations from text using linguistically informed deep neural networks [C]//Proceedings of the 19th Annual SIGdial Meeting on Discourse and Dialogue. Melbourne：Australia Association for Computational Linguistics，2018：306-316.

[11] DEVLIN J，CHANG M W，LEE K，et al. Bert：Pre-training of deep bidirectional transformers for language understanding [C]//Proceedings of the 2019 conference of the North American chapter of the association for computational linguistics：human language technologies，volume 1（long and short papers）. Minneapolis：Association for Computational Linguistics，2019：4171-4186.

[12] LIU Y H，OTT M，GOYAL N，et al. RoBERTa：a robustly optimized BERT pretraining approach [PP/OL]. arXiv，2019：1907.11692 [2025-06-30]. https://arxiv.org/abs/1907.11692.

[13] LI Z L，ZHANG S J，AN Z S. Base on ChatGLM extraction of medication events in aquaculture with few samples [J/OL]. Aquaculture international，2025，33（2）：89 [2025-06-30]. https://doi.org/10.1007/s10499-024-01686-y.

[14] YUAN J Y，ZHANG F Y，QIU Y M，et al. Document-level biomedical relation extraction via hierarchical tree graph and relation segmentation module [J/OL]. Bioinformatics，2024，40（7）：btae418 [2025-06-30]. https://doi.org/10.1093/bioinformatics/btae418.

[15] ANUYAH S，VANSCHAIK J，JAIN P，et al. An empirical study of causal relation extraction transfer：design and data [PP/OL]. arXiv，2025：2503.06076 [2025-06-30]. https://arxiv.org/abs/2503.06076.

[16] CUI Y M，CHE W X，LIU T，et al. Pre-training with whole

word masking for Chinese BERT [J]. IEEE/ACM transactions on audio, speech, and language processing, 2021, 29: 3504-3514.

[17] GAO W, ZHENG X, ZHAO S. Named entity recognition method of Chinese EMR based on BERT-BiLSTM-CRF[C/OL]//Journal of physics: conference series. IOP Publishing, 2021, 1848(1): 012083[2025-06-30]. https://doi: 10.1088/1742-6596/1848/1/012083.

[18] ZHAO X, DENG Y, YANG M, et al. A comprehensive survey on relation extraction: recent advances and new frontiers [J]. ACM computing surveys, 2024, 56(11): 1-39.

[19] HU S, ZHANG H, HU X, et al. Chinese named entity recognition based on BERT-CRF model [C]//2022 IEEE/ACIS 22nd international conference on computer and information science (ICIS). IEEE, 2022: 105-108.

[20] LI W, DU Y, LI X, et al. UD_BBC: Named entity recognition in social network combined BERT-BiLSTM-CRF with active learning [J/OL]. Engineering applications of artificial intelligence, 2022, 116: 105460 [2025-06-30]. https://doi. org/10.1016/j.engappai.2022.105460.

RoBFM: causal relationship extraction for aquaculture disease prevention and control via a bidirectional focus enhancement mechanism

CAO Peirong[1], ZHANG Sijia[1,2], LI Zhenglin[1], AN Zongshi[1], ZHANG Jiaqi[1]

1. *College of Information Engineering, Dalian Ocean University/Dalian Key Laboratory of Smart Fishery/Key Laboratory of Facility Fishery, Ministry of Education, Dalian Ocean University, Dalian 116023, China*;
2. *Liaoning Provincial Key Laboratory of Marine Information Technology, Dalian 116023, China*

Abstract To enhance the accuracy of extracting complex, multi-level causal relationships in aquatic disease control, this study introduces a bidirectional focus enhancement mechanism (BFM) and proposes the RoBFM model (RoBERTa-wwm-ext-large integrated with bidirectional focus enhancement mechanism). The model integrates the RoBERTa-wwm-ext-large pre-trained language model to generate high-quality word embeddings and leverages Bi-directional long short-term memory (BiLSTM) networks to strengthen long-distance dependency modeling. The core innovation of RoBFM resides in the BFM mechanism, which employs forward and backward weight allocation to explicitly decouple and focus on causal semantic roles. To systematically evaluate the model's performance, this paper conducts baseline comparison and ablation experiments on the public dataset DuIE and the self-constructed, domain-specific dataset DLOU-CRE. Experimental results demonstrate that the proposed model surpasses existing baselines in terms of F_1 score and other metrics on both datasets. Notably, the model achieves an F_1 score of 68.23% on the DLOU-CRE dataset, demonstrating that the proposed method is more effective for causal relationship extraction in the prevention and control of aquatic animal diseases.

Keywords causal relationship extraction; bidirectional focus enhancement mechanism; RoBFM; aquaculture disease prevention and control

(责任编辑:边书京)