

中医智能辨证辨病与处方决策系统研究

——基于多任务BERT模型的一体化实现

郑雨昕, 郑丰奎, 胡旭文, 史妍, 陈静, 康子娟

嘉兴南湖学院信息工程学院, 浙江 嘉兴

收稿日期: 2026年5月1日; 录用日期: 2026年7月3日; 发布日期: 2026年7月15日

摘要

随着人工智能与中医药的深度融合, 中医辨证论治的数字化、智能化已成为推动中医药现代化的重要方向。本研究基于脱敏中医病历数据集, 构建了集多标签辨证辨病与中药处方推荐于一体的智能决策系统, 实现了从患者临床文本信息到证型识别、疾病诊断及个性化处方生成的一体化处理。系统采用预训练语言模型(BERT)与多任务学习架构, 同步完成辨证、辨病与处方推荐三大核心任务。实验以1500条真实脱敏病历为支撑, 按8:2:5划分训练、验证与测试集, 通过多维度指标评估模型性能。结果表明, 系统在辨证辨病任务上的综合准确率达0.52, 处方推荐任务的综合评分达0.48, 整体性能优于传统单一任务模型与基线模型。本研究为中医智能诊疗提供了可参考的技术方案, 有助于提升基层诊疗效率与规范化水平, 推动中医药事业的现代化发展。

关键词

中医智能诊疗, 多标签分类, 处方推荐, 自然语言处理, 多任务学习

Research on Intelligent Syndrome Differentiation, Disease Identification and Prescription Decision System for Traditional Chinese Medicine

—An Integrated Implementation Based on Multi-Task BERT Model

Yuxin Zheng, Fengkui Zheng, Xuwen Hu, Yan Shi, Jing Chen, Zijuan Kang

School of Information Engineering, Jiaxing Nanhu University, Jiaxing Zhejiang

Received: May 1, 2026; accepted: July 3, 2026; published: July 15, 2026

文章引用: 郑雨昕, 郑丰奎, 胡旭文, 史妍, 陈静, 康子娟. 中医智能辨证辨病与处方决策系统研究[J]. 人工智能与机器人研究, 2026, 15(4): 1037-1045. DOI: 10.12677/airr.2026.154093

Abstract

With the in-depth integration of artificial intelligence and traditional Chinese medicine (TCM), the digitalization and intelligentization of TCM syndrome differentiation and treatment have become an important direction for promoting the modernization of TCM. Based on a desensitized TCM medical record dataset, this study constructs an intelligent decision-making system integrating multi-label syndrome differentiation, disease identification, and Chinese herbal prescription recommendation, realizing the integrated processing from patients' clinical text information to syndrome type identification, disease diagnosis, and personalized prescription generation. The system adopts a pre-trained language model (BERT) and a multi-task learning architecture to synchronously complete three core tasks: syndrome differentiation, disease identification, and prescription recommendation. Supported by 1500 real desensitized medical records, the experiment divides the dataset into training, validation, and test set at a ratio of 8:2:5, and evaluates model performance through multi-dimensional indicators. The results show that the system achieves a comprehensive accuracy of 0.52 in the syndrome differentiation and disease identification task and a comprehensive score of 0.48 in the prescription recommendation task, with overall performance superior to traditional single-task models and the baseline model. This study provides a referable technical solution for intelligent TCM diagnosis and treatment, which helps improve the efficiency and standardization of primary-level diagnosis and treatment and promotes the modernization of TCM.

Keywords

Intelligent TCM Diagnosis and Treatment, Multi-Label Classification, Prescription Recommendation, Natural Language Processing, Multi-Task Learning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

中医辨证论治是中医诊疗体系的核心，其通过望、闻、问、切四诊收集患者临床信息，结合中医理论进行综合分析，确定证型与疾病，并制定个性化处方。然而，传统中医诊疗高度依赖医师个人经验，存在主观性强、标准化不足、基层诊疗水平参差不齐等问题[1][2]。随着电子病历技术的普及，大量中医诊疗数据得以沉淀，为人工智能技术在中医领域的应用提供了数据基础。近年来，自然语言处理与深度学习技术在医疗文本分析领域取得了显著进展，为中医病历的结构化处理、证型与疾病的智能识别以及处方的自动化生成提供了新的技术路径。

当前中医智能诊疗研究多聚焦于单一任务，如仅实现证型分类或处方推荐，缺乏辨证、辨病与处方生成一体化的系统性解决方案，且部分研究存在模型可解释性不足、缺乏统一评估标准等问题。为此，本研究基于真实脱敏中医病历数据，构建了中医智能辨证辨病与处方决策系统，通过多任务学习框架同步完成证型分类、疾病诊断与处方推荐任务，并建立了多维度评估体系，旨在推动中医诊疗的智能化、标准化发展。

2. 相关工作

2.1. 中医智能辨证辨病研究

中医辨证辨病的核心是基于患者临床信息判断证型与疾病类型，属于多标签分类任务。早期研究多

采用传统机器学习方法,如支持向量机、随机森林等,通过人工提取症状特征进行分类[3]。随着深度学习技术的发展,预训练语言模型(如 BERT)被广泛应用于中医文本分析,通过对病历文本进行语义编码,实现证型与疾病的自动识别[1][4]。然而,现有研究多集中于单一证型或疾病的分类,缺乏对多标签辨证辨病任务的系统性研究,且模型泛化能力有待提升[5]。

2.2. 中医处方推荐研究

中医处方推荐是根据患者的症状、证型等信息生成个性化中药处方的任务,目前主要研究方法包括基于规则的推荐、协同过滤与深度学习方法。基于规则的推荐依赖中医知识图谱,根据症状-证型-药物的关联规则生成处方;协同过滤通过分析历史处方数据中的药物共现关系进行推荐;深度学习方法则利用序列生成模型学习症状、证型与药物之间的关联,实现处方的自动化生成。现有处方推荐研究多以证型为中间特征,缺乏与辨证辨病任务的端到端结合,且处方合理性评估方法有待完善[6]。

2.3. 多任务学习在中医智能诊疗中的应用

多任务学习是一种通过同时训练多个相关任务,利用任务间关联信息提升模型整体性能的机器学习方法。相比单一任务学习,它能充分利用数据共享信息,减少过拟合,提升泛化能力,尤其适用于数据有限、任务关联的场景。

近年来,多任务学习已在中医智能诊疗领域得到初步应用,相关研究证实其可利用任务间关联提升性能。但现有应用仍存在不足:多为双任务联合训练,缺乏对辨证、辨病与处方推荐三大核心任务的一体化实现,且任务权重与模型架构设计有待优化。为此,本研究采用多任务学习架构,实现三大任务的端到端联合训练,以提升模型整体性能。

3. 数据集构建与任务整体定义

3.1. 数据集与任务定义

本研究基于真实脱敏中医病历数据集开展实验,数据集来源于多家合作中医院的中医科门诊病历,经过脱敏处理(去除患者姓名、身份证号、联系方式等个人隐私信息),确保数据的安全性与合规性。数据集共包含 1500 条真实中医诊疗数据,涵盖 4 种常见中医疾病、10 种常见中医证型与 381 种常用中药,数据质量较高,能够满足模型训练与测试的需求。

数据集的具体构成如下:疾病类型包括胸痹心痛病、心衰病、眩晕病、胃脘痛病 4 种,均为中医临床常见疾病,每种疾病的病历数量分布相对均匀,其中胸痹心痛病 400 条、心衰病 350 条、眩晕病 350 条、胃脘痛病 400 条;证型包括气虚血瘀证、痰热蕴结证、阴虚燥热证、气阴两虚证、肝郁气滞证、痰湿阻络证、寒凝血瘀证、湿热蕴脾证、肝肾阴虚证、脾胃虚弱证 10 种,涵盖了中医临床常见的证型类型;中药包括黄芪、当归、川芎、丹参、白术等 381 种常用中药,涵盖了中医临床各科的常用药物,能够满足处方推荐任务的需求。

为确保实验的科学性与可靠性,将数据集按 8:2:5 的比例划分为训练集、验证集与测试集,具体数量如下:训练集 800 条,用于模型的训练与参数优化;验证集 200 条,用于模型的超参数调整与早停机制的实现,防止模型过拟合;测试集 500 条,用于模型性能的最终评估,确保评估结果的客观性与准确性。数据集采用 JSON 格式存储,每条数据包含患者基本信息、临床信息与标签信息三部分,具体如下:

- 1) 患者基本信息:包括性别、年龄、职业、病程等,用于辅助分析患者的病情特点,其中性别分为男、女两类,年龄分布在 18~75 岁之间,病程分布在 1 个月~10 年之间;
- 2) 临床信息:包括主诉、现病史、既往史、望诊(面色、舌苔等)、闻诊(气味、声音等)、问诊(症状、

体征等)、切诊(脉象等),均为非结构化文本形式,是模型输入的核心内容;

3) 标签信息:包括证型标签、疾病标签与处方标签,其中证型标签与疾病标签为多标签形式(一个患者可能同时存在多种证型与疾病),处方标签为中药集合形式(包含中药名称与常用剂量范围)。

3.2. 数据预处理

由于原始中医病历数据存在文本不规范、无效信息多、术语不统一等问题,无法直接用于模型训练,因此需要对数据集进行一系列预处理操作,确保数据的规范性与可用性。数据预处理过程主要包括数据清洗、文本标准化、特征提取与标签处理四个步骤,具体如下:

3.2.1. 数据清洗

首先对原始数据集进行筛选,去除无效数据(如病历信息不完整、症状描述模糊、无明确证型与处方的病历)与重复数据(如同一患者的多次就诊病历,仅保留最完整的一条),最终得到 1500 条有效病历数据。同时,对病历文本中的错别字、语病进行修正,去除无关信息(如医师签名、就诊时间等),确保文本信息的准确性与简洁性[7]。

3.2.2. 文本标准化

中医病历文本中存在大量口语化描述、术语不统一等问题,因此需要对文本进行标准化处理。具体包括:一是统一中医术语表达,如将“心慌”统一为“心悸”、“拉肚子”统一为“泄泻”、“嗓子疼”统一为“咽痛”,参考《中医病证诊断疗效标准》与《中医药常用名词术语辞典》,确保术语的规范性;二是处理口语化描述,将口语化的症状描述转化为规范化的中医术语,如将“感觉浑身没力气”转化为“乏力”、“晚上睡不着觉”转化为“失眠”;三是文本分词与去停用词,采用 jieba 分词工具对病历文本进行分词,去除无意义的停用词(如“的”、“了”、“是”等),保留核心词汇(如症状、体征、病史等)[8]。

3.2.3. 特征提取

将预处理后的临床信息文本(主诉、现病史、望闻问切等)拼接为一个完整的文本序列,作为模型的输入特征。同时,对患者基本信息(性别、年龄、病程等)进行编码处理,将性别转化为二进制特征(男 = 1, 女 = 0),将年龄与病程转化为数值特征,与文本序列特征融合,提升模型的性能[9]。

3.2.4. 标签处理

对证型标签、疾病标签与处方标签进行标准化处理,确保标签的一致性与可用性。其中,证型标签与疾病标签采用 one-hot 编码方式,将 10 种证型与 4 种疾病分别转化为 10 维与 4 维的二进制向量,向量中 1 表示存在该证型或疾病,0 表示不存在;处方标签采用集合编码方式,将每个处方表示为 381 维的二进制向量,向量中 1 表示包含该中药,0 表示不包含该中药,同时记录每种中药的常用剂量范围,用于后续处方合理性评估[10]。

3.3. 任务定义

本研究的核心目标是构建中医智能辨证辨病与处方决策系统,实现从患者临床信息到证型识别、疾病诊断及处方推荐的一体化处理,因此定义了两个核心子任务,分别为中医多标签辨证辨病任务与中药处方推荐任务,两个任务共享输入特征,通过多任务学习架构实现联合训练,具体任务定义如下:

3.3.1. 子任务 1: 中医多标签辨证辨病

输入:患者临床信息文本(拼接后的主诉、现病史、望闻问切等文本)与患者基本信息(性别、年龄、病程等)融合后的特征向量;

输出：患者对应的中医证型多标签(10 维二进制向量)与疾病多标签(4 维二进制向量)；

评估指标：为了全面评估模型在辨证辨病任务上的性能，采用辨证任务准确率($\text{syndrome}_{\text{acc}}$)、辨病任务准确率($\text{disease}_{\text{acc}}$)、以及综合指标 task1_acc 进行评估。

辨证任务准确率($\text{syndrome}_{\text{acc}}$):

$$\text{syndrome}_{\text{acc}} = \frac{\text{NUM}(y \cap \hat{y})}{\text{NUM}(y)}$$

其中， y 是数据集样本中真实证型的列表， $\hat{y}$ 是模型预测的证型列表； $\text{NUM}(x)$ 代表数量函数，用于计算集合 x 中元素的数量。

辨病任务准确率($\text{disease}_{\text{acc}}$):

$$\text{disease}_{\text{acc}} = \frac{\text{NUM}(y \cap \hat{y})}{\text{NUM}(y)}$$

其中， y 是数据集样本中真实疾病的列表， $\hat{y}$ 是模型预测的疾病列表； $\text{NUM}(x)$ 代表数量函数，用于计算集合 x 中元素的数量。

综合指标 task1_acc :

$$\text{task1_acc} = \frac{1}{2}(\text{syndrome}_{\text{acc}} + \text{disease}_{\text{acc}})$$

3.3.2. 子任务 2：中药处方推荐

输入：与子任务 1 相同的输入特征向量；

输出：推荐的中药处方集合(包含中药名称与常用剂量范围)，以 381 维二进制向量表示；

评估指标：采用多维度指标对方推荐任务的性能进行评估，包括 Jaccard 相似系数、Recall (召回率)、Precision (精确率)、F1 分数和药物平均数量(Avg Herb)，综合指标 task2_score 为各项指标的平均值。

Jaccard 相似系数:

$$\text{Jaccard}(y, \hat{y}) = \frac{\text{NUM}(y \cap \hat{y})}{\text{NUM}(y \cup \hat{y})}$$

Recall (召回率):

$$\text{Recall}(y, \hat{y}) = \frac{\text{NUM}(y \cap \hat{y})}{\text{NUM}(y)}$$

Precision (精确率):

$$\text{Precision}(y, \hat{y}) = \frac{\text{NUM}(y \cap \hat{y})}{\text{NUM}(\hat{y})}$$

F1 分数:

$$\text{F1}(y, \hat{y}) = 2 \cdot \frac{\text{Precision}(y, \hat{y}) \cdot \text{Recall}(y, \hat{y})}{\text{Precision}(y, \hat{y}) + \text{Recall}(y, \hat{y})}$$

药物平均数量(Avg Herb):

$$\text{AVG}(y, \hat{y}) = 1 - \frac{|\text{NUM}(y) - \text{NUM}(\hat{y})|}{\max(\text{NUM}(y), \text{NUM}(\hat{y}))}$$

其中, y 是真实处方, $\hat{y}$ 是模型预测的处方, $\text{NUM}(x)$ 代表数量函数, 用来计算 x 的数量。 $\max(a, b)$ 代表取 a, b 中的最大值, $|x|$ 代表计算 x 的绝对值。

综合指标 task2_score :

$$\text{task2_score} = \frac{1}{3} \cdot \frac{1}{N} \sum_{i=1}^N [\text{Jaccard}(y_i, \hat{y}_i) + \text{Fl}(y_i, \hat{y}_i) + \text{AVG}(y_i, \hat{y}_i)]$$

其中 y_i 是第 i 条样本的真实处方, $\hat{y}_i$ 是模型预测的第 i 条样本的处方, N 表示样本总数。

系统最终性能采用两个子任务得分的加权和进行评估, 其中两个子任务的权重均设置为 0.5, 即 $\text{task_score} = 0.5 * \text{task1_acc} + 0.5 * \text{task2_score}$, 权重设置参考相关研究, 并通过验证集进行优化, 确保评估结果的合理性。

4. 方法

4.1. 模型架构

本研究采用基于预训练语言模型的多任务学习架构, 整体模型分为文本编码层、共享特征层和多任务输出层三部分, 各层之间相互关联、协同工作, 实现辨证辨病与处方推荐任务的端到端联合训练。

4.1.1. 文本编辑层

文本编码层的核心功能是对输入的临床信息文本进行语义编码, 提取文本中的上下文特征表示, 为后续任务提供有效的特征支撑。本研究采用 BERT (Bidirectional Encoder Representations from Transformers) 预训练语言模型作为文本编码器, BERT 模型是由 Google 提出的预训练语言模型, 采用双向 Transformer 架构, 能够有效捕捉文本的上下文语义信息, 在自然语言处理任务中表现优异。

4.1.2. 共享特征层

对 BERT 输出的隐藏状态进行池化操作, 得到融合的文本特征向量, 作为后续任务的共享特征。

4.1.3. 多任务输出层

包含三个任务分支:

证型分类分支: 采用全连接层对共享特征进行映射, 输出证型多标签分类结果;

疾病分类分支: 与证型分类分支结构相同, 输出疾病多标签分类结果;

处方推荐分支: 采用全连接层结合 Sigmoid 激活函数, 输出每个中药的推荐概率, 通过阈值筛选生成处方集合。

4.2. 损失函数

模型采用多任务联合训练方式, 总损失函数为各任务损失的加权和:

$$L_{\text{total}} = \alpha L_{\text{syndrome}} + \beta L_{\text{disease}} + \gamma L_{\text{prescription}}$$

其中, 证型与疾病分类任务采用多标签交叉熵损失:

$$L_{\text{syndrome}} = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^C y_{ij} \log \hat{y}_{ij} + (1 - y_{ij}) \log (1 - \hat{y}_{ij})$$

$$L_{\text{disease}} = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^D y_{ij} \log \hat{y}_{ij} + (1 - y_{ij}) \log (1 - \hat{y}_{ij})$$

处方推荐任务采用二元交叉熵损失:

$$L_{\text{prescription}} = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M y_{ij} \log \hat{y}_{ij} + (1 - y_{ij}) \log (1 - \hat{y}_{ij})$$

其中： N 为样本总数； C 、 D 、 M 分别为证型、疾病、中药的标签数； y_{ij} 为第 i 个样本第 j 个标签的真实值(0/1)； $\hat{y}_{ij}$ 为模型预测的概率值； α 、 β 、 γ 为任务权重系数，本研究中均设置为 1。

4.3. 实验设置

本研究采用 PyTorch 框架实现模型，BERT 模型采用中文预训练权重，隐藏层维度为 768，训练批次大小为 16，学习率设置为 $2e-5$ ，采用 AdamW 优化器进行模型训练，训练轮次为 20 轮，早停机制用于防止过拟合。

优化器更新公式(AdamW):

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} (\hat{m}_t + \lambda \theta_t)$$

其中， η 为学习率(本研究取 2×10^{-5})， $\hat{m}_t$ 、 $\hat{v}_t$ 为一阶、二阶矩偏差修正项， λ 为权重衰减系数。

早停机制判断公式:

$$\text{patience_count} = \begin{cases} \text{patience_count} + 1, & \text{val_acc}_t \leq \text{best_val_acc} \\ 0, & \text{val_acc}_t > \text{best_val_acc} \end{cases}$$

当 patience_count 达到设定阈值时，停止训练以防止过拟合。

5. 实验结果与分析

5.1. 实验结果

本研究在测试集上对模型性能进行评估，并与基线模型进行对比，实验结果见表 1:

Table 1. Model performance evaluation results data

表 1. 模型性能评估结果数据

模型	基线模型	本研究模型
task1_acc	0.45	0.52
task2_score	0.41	0.48
task_score	0.43	0.50

由实验结果可知，本研究模型在两个子任务上的性能均优于基线模型，综合指标提升了 0.07，表明多任务学习架构能够有效利用辨证辨病与处方推荐任务之间的关联信息，提升模型整体性能[4]。

5.2. 结果分析

5.2.1. 辨证辨病任务

本研究模型的证型分类准确率与疾病分类准确率均高于基线模型，表明 BERT 预训练模型能够有效捕捉中医病历文本中的语义信息，提升多标签分类任务的性能。同时，共享特征层的设计使得模型能够同时学习证型与疾病之间的关联特征，进一步提高了分类准确率。

在证型识别中，气虚血瘀证与气阴两虚证、痰湿阻络证与湿热蕴脾证混淆率较高，主要原因在于这些证型在症状表述上存在较多重叠(如乏力、胸闷、舌苔厚腻等)，仅依靠文本表层语义难以完全区分；在疾病诊断中，胸痹心痛病与心衰病因均涉及心悸、胸闷、气短等症状，也存在一定程度的误判。

5.2.2. 处方推荐任务

本研究模型在 Jaccard 相似系数、F1 分数和药物平均数量等指标上均优于基线模型，表明模型能够根据患者临床信息生成更合理、更接近真实处方的中药推荐结果。此外，多任务学习框架使得处方推荐任务能够利用辨证辨病任务的监督信息，提升了处方推荐的准确性与合理性。

进一步分析模型的预测行为可以发现，其错误模式呈现出两类典型特征：一是遗漏核心君药，如在气虚血瘀证的处方预测中，模型常遗漏黄芪、丹参等针对核心病机的关键药物，仅推荐陈皮、甘草等辅助性药物，导致处方缺乏明确的治疗方向；二是加入关联性较弱的药物，例如在单纯气虚证的处方中加入大量滋阴药物，或在湿热蕴脾证中推荐温阳类药物，反映出模型对“症状 - 证型 - 药物”的中医配伍规律理解不足。这些错误表明，模型虽然能学习到症状与药物之间的统计关联，但仍未完全掌握中医处方“君臣佐使”的配伍逻辑，对核心病机的药物指向性仍有待加强。

5.2.3. 定性错误案例分析

为深入探究模型出错的深层原因，本研究从测试集中随机抽取 20 例预测错误样本，结合中医理论进行定性分析，典型案例如表 2：

Table 2. Qualitative analysis of model error cases
表 2. 定性错误案例分析

错误类型	临床文本示例	真实标签/处方	模型预测结果	错误模式与中医理论分析
证型混淆	患者胸闷心悸、气短乏力、口干、舌暗有瘀斑、脉细涩	证型：气虚血瘀证	证型：气阴两虚证	受高频症状“口干”干扰，模型优先匹配气阴两虚证特征，忽略了“舌暗瘀斑、脉涩”提示的血瘀核心病机，无法区分病机相近、症状重叠的证型。
疾病误判	患者阵发性胸闷胸痛、头晕、心悸、舌淡红、脉细	疾病：胸痹心痛病	疾病：眩晕病	受高频症状“头晕”干扰，模型优先匹配眩晕病特征，忽略了“阵发性胸闷胸痛”这一胸痹心痛病的特异性诊断依据。
处方推荐 - 遗漏君药	患者胃脘胀痛、嗳气反酸、情绪抑郁、舌苔薄白、脉弦	处方：柴胡、香附、白芍、陈皮、枳壳	处方：陈皮、枳壳、甘草	模型识别出“胃脘胀痛、嗳气”等气滞症状，但未关联“情绪抑郁、脉弦”提示的肝郁病机，遗漏柴胡、香附等疏肝理气君药，仅推荐理气和胃辅助药，处方针对性不足。
处方推荐 - 配伍逻辑混乱	患者神疲乏力、少气懒言、纳差便溏、舌淡苔白、脉弱	处方：黄芪、党参、白术、茯苓、炙甘草	处方：黄芪、麦冬、五味子、陈皮	模型识别出气虚症状，但错误加入滋阴药物麦冬、五味子，违背了单纯气虚证“补气健脾”的核心治法，反映出模型对“症状 - 证型 - 药物”的配伍规律理解不足。

上述案例表明，模型错误主要源于三方面：一是症状重叠导致语义歧义，难以区分相似证型/疾病；二是缺乏中医理论先验知识，无法精准识别核心病机；三是过度依赖高频症状，忽略特异性诊断信息。后续研究需引入中医知识图谱，强化模型对病机 - 症状 - 药物关联规则的学习，提升预测的准确性与合理性。

6. 讨论

本研究构建的中医智能辨证辨病与处方决策系统，实现了从临床文本信息到证型、疾病诊断及处方

推荐的一体化处理,实验结果表明模型性能优于基线模型,验证了多任务学习架构在中医智能诊疗任务中的有效性。然而,本研究仍存在一些局限性:首先,数据集规模较小,且病种覆盖有限,模型泛化能力有待进一步提升;其次,模型的可解释性不足,无法清晰展示中医辨证论治的推理过程;最后,处方推荐任务未引入中医知识图谱,难以保证处方的中医理论合理性。

未来研究将从以下几个方面进行改进:

扩充数据集规模,增加不同地区、不同病种的病历数据,提升模型的泛化能力;

引入中医知识图谱,将中医理论规则融入模型中,提升模型的可解释性与处方合理性;

优化模型架构,采用更适合中医文本分析的预训练模型,进一步提升模型性能;

开展临床验证,邀请中医医师对模型输出的辨证辨病结果与处方进行评估,验证模型的临床实用性。

7. 结论

本研究基于脱敏中医病历数据集,构建了集多标签辨证辨病与中药处方推荐于一体的智能决策系统。系统采用基于 BERT 的多任务学习架构,实现了两个子任务的端到端联合训练,实验结果表明模型性能优于基线模型,为中医智能诊疗的临床应用提供了可参考的技术方案。未来,通过扩充数据集、引入中医知识图谱与临床验证,系统性能将得到进一步提升,有望为基层中医诊疗提供有效的辅助支持,推动中医药的智能化、标准化发展[1][2][6]。

致 谢

本研究感谢阿里云平台提供的脱敏病历数据,感谢项目组成员在数据预处理、模型训练与实验分析过程中的辛勤付出,同时感谢指导老师在本研究过程中给予的悉心指导与帮助。

基金项目

嘉兴南湖学院 2025 年度大学生科研训练计划(SRT),项目编号: 8517252087,项目名称: 中医智能辨证辨病与处方决策系统研究——基于多任务 BERT 模型的一体化实现。

参考文献

- [1] 夏淑洁, 杨朝阳, 周常恩, 等. 常见机器学习方法在中医诊断领域的应用述评[J]. 广州中医药大学学报, 2021, 38(4): 826-831.
- [2] 张晓航, 石清磊, 王斌, 等. 机器学习算法在中医诊疗中的研究综述[J]. 计算机科学, 2018, 45(S2): 32-36.
- [3] 顾天宇, 严壮志, 蒋皆恢. 基于支持向量机的中风病中医证候分类[J]. 中医药信息, 2021, 38(9): 1-3.
- [4] 孙资金, 吉静, 马重阳, 等. 基于机器学习的中风中医辨证模型的构建与应用[J]. 湖南中医药大学学报, 2023, 43(4): 694-699.
- [5] 刘丽蓉, 詹秀菊. 基于 BP 神经网络和支持向量机的荨麻疹证候分类探讨[J]. 广州中医药大学学报, 2020, 37(3): 573-577.
- [6] 柏杨, 郝平生. 常见机器学习技术在中医证候诊断中的应用进展[J]. 计算机科学与应用, 2024, 14(3): 169-177.
- [7] 贺鹏飞, 刘聪, 李红典, 等. 运用机器学习构建慢性肾炎中医辨证智能模型及内部验证[J/OL]. 辽宁中医药大学学报: 1-11. <https://link.cnki.net/urlid/21.1543.R.20240124.1503.010>, 2024-02-18.
- [8] 田艳鹏, 丁学义, 朱羽硕, 等. 基于决策树和神经网络的高血压病痰湿壅盛证诊断模型研究[J]. 中华中医药杂志, 2018, 33(8): 3579-3584.
- [9] 彭素霞, 杨多, 钟俐芹, 梁昊. 中医舌诊智能化的研究进展[J]. 中医学, 2024, 13(7): 1590-1598.
- [10] 姜超, 冯哲, 王均琴, 等. 三种机器学习方法在脑出血中医辨证分类中应用的比较研究[J]. 中国卫生统计, 2023, 40(6): 921-924, 928.