

DOI: 10.13382/j.jemi.B2407936

融合注意力残差机制的 BP 神经网络在冠状动脉疾病诊断中的应用^{*}

张江文¹ 杨晓霞¹ 高娜¹ 王宁¹ 张翠翠²(1. 天津职业技术师范大学天津市信息传感与智能控制重点实验室 天津 300222;
2. 天津大学海洋科学与技术学院 天津 300072)

摘要: 在医疗健康领域, 冠状动脉疾病作为心脏病的一种, 对人民的生命健康造成严重威胁。但由于导致冠状动脉疾病发病的影响因素较为复杂, 且在发病初期存在隐匿性, 导致多数患者错过最佳治疗时段而无法痊愈甚至出现更悲剧的结果。为帮助人群在发病初期进行准确的诊断预测并提供相应的预防措施和治疗手段, 各类基于机器学习诊断算法被广泛应用于医疗健康领域。目前, 随着人工智能领域的快速发展, 深度学习也被逐渐应用于心脏病的诊断预测中。通过对克利夫兰心脏病数据集中的数据分布进行可视化, 通过特征选择, 揭示特定医学指标与冠状动脉疾病之间的紧密联系, 以探索关键因子对冠状动脉疾病发病的影响趋势。构建基于融合注意力与残差机制的 BP 神经网络的冠状动脉疾病诊断预测模型, 模型通过残差结构缓解梯度消失, 保持梯度流动的稳定性, 并通过多头注意力机制捕捉特征间的深层依赖关系, 实现特征权重的动态分配。该数据集在冠状动脉疾病诊断模型上进行训练获得 97.1% 的准确率。为了验证方法的有效性, 将其与现有机器学习算法进行比较评估并进行对比实验, 发现该算法在关键性能指标上均展现出更为优越的表现, 验证了其在医疗健康领域, 尤其是在心脏病诊断中的实际应用价值。

关键词: 冠状动脉疾病; 深度学习; 特征选择; BP 神经网络; 残差结构; 注意力机制

中图分类号: TN98; TP391.41 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Application of BP neural network with attention residual mechanism in the diagnosis of coronary artery disease

Zhang Huiwen¹ Yang Xiaoxia¹ Gao Na¹ Wang Ning¹ Zhang Cuicui²

(1. Tianjin Key Laboratory of Information Sensing and Intelligence Control, Tianjin University of Technology and Education, Tianjin 300222, China; 2. School of Marine Science and Technology, Tianjin University, Tianjin 300072, China)

Abstract: Coronary artery disease (CAD), as one of typical heart diseases, threatens people's lives and health. However, due to its complex influencing factors and its subtle initial symptoms, many patients miss the optimal treatment window for recovery. To enable early diseases prevention so as to get most appropriate treatment, many machine learning methods have been widely applied in this field, among which deep learning has been acknowledged as one of the cutting-edge techniques for CAD diagnosis. This paper develops a tailored BP neural network, which integrates BP with an attention-residual-mechanism for CAD detection. In order to find the key factors that contribute to CAD prediction, we first investigate a feature selection strategy based on data visualization and using several statistical methods on the commonly used cleveland heart disease dataset. Then, the attention-residual-mechanism informed BP network is conducted for CAD detection. The amended BP network alleviates the gradient vanishing problem by using a residual structure and captures deep dependencies between features through a multi-head attention mechanism, which can be used for dynamic allocation of feature weights. Extensive experiments demonstrate the better performance of our method than existing machine learning algorithms. It can achieve an accuracy of 97.1% on Cleveland Heart Disease dataset, which verifies the effectiveness of our method in CAD diagnosis.

Keywords: coronary artery disease; deep learning; feature selection; BP neural network; residual structure; attention mechanism

收稿日期: 2024-11-04 Received Date: 2024-11-04

* 基金项目:国家重点研发计划项目(2022YFC3104600)、国家自然科学基金(62001329)、天津市科技计划项目(24YDTPJC00740)、海南省重点研发计划项目(ZDYF2024SHFZ051)资助

0 引言

冠状动脉疾病 (coronary artery disease, CAD) 是一种常见的心脏病, 具体表现为冠状动脉发生粥样硬化, 难以向心肌输送足够的血液、氧气和营养。冠状动脉粥样硬化由多种因素导致, 且在发病前没有显著症状甚至察觉不到。然而, 当病症发作时, 冠状动脉发生粥样硬化可能导致患者心脏功能受损, 引发其他器官系统的并发症, 严重时甚至可能威胁生命。据统计, 心脏病是导致全球人口残疾和死亡的首要原因之一^[1], 冠状动脉粥样硬化是导致心肌缺血和损伤的主要原因。为了更好地预防心脏病对患者生命健康的危害, CAD 早期的诊断和预防治疗具有重要意义。

传统的医疗诊断方法主要取决于医生个人的经验, 且由于患者检测指标的多样化和复杂化, 可能导致不同医生给出的诊断结果存在差异。随着医疗和人工智能领域的快速发展, 基于机器学习的传统分类算法率先应用于医疗信息的诊断预测, 辅助医护人员做出决策, 完成 CAD 早期的诊断和预测, 防止部分患者因症状较轻或部分医疗发展落后地区医生经验不足造成漏诊误诊的事故。在医学领域应用智能算法早期, 科学家将传统分类算法与健康医疗大数据结合, 算法实现对 CAD 的预测。克利夫兰诊所通过判别函数模型和贝叶斯算法对 CAD 进行预测, 在高患病率环境中, 当概率阈值为 0.4 时, 判别模型准确率为 71% 低于准确率为 74% 的贝叶斯算法^[2]。Blachnik 等^[3] 使用 SVM 算法进行心血管疾病诊断预测, 准确率高于 80%。该类方法为医生诊断提供了帮助, 但逻辑回归、支持向量机 (SVM) 等分类算法通常对临床特征独立处理, 无法对特征间的相关性进行交互分析, 使特征因子的协同作用信息丢失, 存在一定不足。后续研究中, Luna 等^[4] 使用单棵决策树构建树状模型应用于心血管疾病预测。尹海宁等^[5] 将 Logistic 回归模型和随机森林模型用于对 AMI 患者 MACE 风险的预测价值评估工作。El-shafiey 等^[6] 基于随机森林引入混合遗传算法和粒子群优化方法来进行 CAD 诊断准确性的关键特征提取。杨敬柔等^[7] 采用逻辑回归、随机森林、神经网络 3 种方式来对 CAD 数据分类, 在逻辑回归算法中取得 88.52% 的最优准确率。随机森林、决策树等已在特征相关信息利用方向取得一定优势, 但机器学习模型结构简单^[8], 通过决策边界分割进行逻辑判断, 缺少非线性函数做支撑, 面对具有复杂特征的 CAD 数据时, 仍难以做出优秀的判断。王健等^[9] 将卷积神经网络应用于 CAD 预测, 实现精度的有效提高, 达到 89.89% 的预测精度。但 CAD 诊断中, CNN 网络更适用于二维图像数据的特征学习, 对于本文所使用的一维特征数据存在局限性, 难以

达到良好效果。

BP 神经网络作为一种典型的神经网络模型, 可将传统算法进行深度扩展, 并在一维数据的分类预测上占据主导性地位。其具有多层网络结构^[10], 且相比线性模型引入非线性函数来提高模型对复杂数据的拟合能力, 可以自动从输入数据中学习特征与 CAD 患病结果之间的复杂映射关系。但传统 BP 神经网络平等对待所有特征, 无法聚焦关键特征组合, 且在多层网络结构上数据随着梯度的加深存在梯度消失、过拟合等网络退化问题严重。为解决上述问题, 本文使用残差结构通过跳跃连接的形式构建数据输入以直接映射的方式加入到深层网络中, 突破传统网络的链式堆叠模式, 以跨层连接的方法有效缓解深层网络梯度消失问题, 并通过特征复用提升数据特征信息的无损传递。此外本文使用多头注意力机制通过多个注意力头同时捕捉特征之间的复杂交互作用, 分别学习特征间的关系并动态分配特征权重增强模型对复杂特征关系的学习能力, 挖掘静态数据深层关联以提高模型的表达和泛化能力。最终, 本文通过对 CAD 数据的特征进行特征选择并将其分布进行可视化, 清晰地观察到不同特征与 CAD 发病率之间的相关性, 确定影响冠状动脉发生病变的关键因子, 为后续的模型构建提供重要依据。随后对影响 CAD 发病的关键因子采用融合注意力与残差机制的 BP 神经网络构建 CAD 诊断的预测模型。为了验证所构建模型的有效性, 本研究选择在医疗健康领域广泛应用的克利夫兰数据库中的心脏病数据集进行实验, 在 UCI 官网 Heart Disease Data Set 中的其他 3 个心脏病数据集上进行验证, 并通过对比实验以及与现有机器学习诊断算法的最优结果进行对比评估模型性能, 达到更好的效果。

1 CAD 数据预处理

1.1 数据集概述

克利夫兰心脏病数据集是来源于 UCI 机器学习数据库中的开源数据集, 其数据收集了 303 名患者的 CAD 样本数据。在该数据集中, 每个样本的原始数据具有 76 个属性, 但这些属性中存在患者个人信息及临床检测项目的年月日等信息均与 CAD 的发生没有直接关系, 并且在这 76 个属性中部分数据具有大量缺失值影响数据分析和训练的效果, 不适合模型训练。出于以上原因, 参考文献[2-7]所引用的特征属性, 最终每个样本保留了原始数据 76 个属性中缺失值较少的 13 个特征属性和 1 个目标变量。所选目标变量分别为年龄 (age)、性别 (sex)、胸痛类型 (chest pain type, cp)、静息血压 (resting blood pressure, trestbps)、血清胆固醇水平 (serum cholesterol level, chol)、空腹血糖 (fasting blood sugar, fbs)、静息心

电图结果 (resting electrocardiogram result, restecg)、最大心率 (maximum heart rate achieved, thalach)、运动引起的心绞痛 (exercise-induced angina, exang)、运动相对于休息引起 ST 压低 (exercise-induced ST depression, oldpeak)、最高运动 ST 段斜率 (maximum slope of the ST segment, slope)、冠状动脉造影时荧光显色的主要血管数目 (coronary artery, ca)、地中海贫血类型 (thalassemia type, thal) 和 CAD 是否存在的目标变量 (prediction of the presence of heart disease, target)^[11]。

1.2 数据预处理

在官网原始 CAD 数据集中, cp 列存在 4 个缺失值, thal 列存在 2 个缺失值, 其行索引分别为 166、192、287、302、87、266。为了处理这些缺失数据, 将其填充为 0。但由于 cp 和 thal 均为分类数据, 为了防止网络在处理数据时将填充的 0 错误地解读为有效类别, 使用独热编码 (one-hot encoding) 的方式来规避这一问题。例如, 分类数据为 [1, 2, 3, 4] 时, 经过独热编码处理后, 对于不同类别数据的所属形式表现为 [1, 0, 0, 0]、[0, 1, 0, 0]、[0, 0, 1, 0]、[0, 0, 0, 1]。这样, 被填充为 0 的缺失值表示为 [0, 0, 0, 0], 避免了被识别为第 0 类的缺陷, 确保了数据分析结果的准确性不受影响。thal 其他指标 normal、fixed、reversible 分别用 1、2、3 进行替换。target 指标中患有 CAD 和不患有 CAD 分别用 1 和 0 进行替换。然后统一将数据集各字段特征值进行标准化处理。经过预处理后的数据集各属性特征描述如表 1 所示。

表 1 样本各特征属性的描述

Table 1 Description of feature attribute of samples

属性	类型	取值区间	描述
age	连续	29~77 岁	对象的年龄, 数字表示
sex	离散	0,1	1 表示男性, 0 表示女性 1 表示无症状, 2 表示非心绞痛, 3 表示有 ST-T 波异常, 2 表示明确的左心室肥厚
cp	离散	1,2,3,4	表示非典型性心绞痛, 4 表示典型心绞痛
trtbpes	连续	94~200 Hg	静息血压数值
chol	连续	126~564 mg/dL	通过 BMI 传感器获取的胆固醇
fbs	离散	0,1	0 表示 $\leq 120 \text{ mg/dL}$, 1 表示 $> 120 \text{ mg/dL}$
restecg	离散	0,1,2	0 表示正常, 1 表示有 ST-T 波异常, 2 表示明确的左心室肥厚
thalach	连续	71~202 b/min	最大心率
exang	离散	0,1	0 表示否, 1 表示是
oldpeak	连续	0~6.2 mV	运动时的 ST 段数值
slope	离散	1,2,3	1 表示上升, 2 表示平坦, 3 表示下降
ca	连续	0,1,2,3	荧光显色的主要血管数目
thal	离散	1,2,3	1 = 正常, 2 = 固定缺陷, 3 = 可逆缺陷
target	离散	0,1	0 表示否, 1 表示是

1.3 特征选择

在构建 CAD 诊断模型前, 对数据集中特征属性进行特征选择。本文通过逻辑回归、决策树、随机森林、SHAP、F 值检验等多种特征选择方法选出 3 组重要特征。分别对所选特征及特征组合在传统基础 BP 神经网络上进行实验验证, 发现当特征选为 age、sex、thalach、exang、oldpeak、slope、ca、thal、cp 时模型准确率最高, 同时这组特征是其中逻辑回归、决策树、F 值检验所得到的一致识别结果, 具体实验准确率验证结果如表 2 所示。其中 F 值检验不仅仅可以判断单个变量对因变量的可解释能力, 并且可以将所有自变量看作一个整体, 分析其联合作用对因变量是否有显著的预测能力, 筛选对分类任务具有显著区分能力的特征。F 检验所得分值代表特征与目标变量间的相关程度, 其重要性排序如图 1 所示。其中 thalach、oldpeak 和 thal 得分最高, 这些特征对 CAD 诊断影响最为显著, slope、cp、exang、ca、age 以及 sex 对 CAD 诊断影响次之。因此基于多种实验结果共识以及基础网络实验验证以此组特征作为 CAD 诊断预测的关键因子。通过对关键因子进行分析, 可以准确地把握各个特征对诊断结果的影响并了解其发病趋势及病理特征, 为后续模型的诊断预测提供理论依据。

表 2 基于不同特征选择方法的准确率对比

Table 2 Performance comparison of different feature selection methods

特征选择方法	所选关键因子	准确率/%
SHAP	age、trestbps、thalach、exang、oldpeak、slope、ca、thal、cp	89.6
随机森林	age、chol、thalach、exang、oldpeak、slope、ca、thal、cp	91.7
多种方法特征组合	age、sex、thalach、exang、oldpeak、slope、ca、thal、cp、chol、trestbps	93.9
逻辑回归、决策树、F 值	age、sex、thalach、exang、oldpeak、slope、ca、thal、cp	95.3

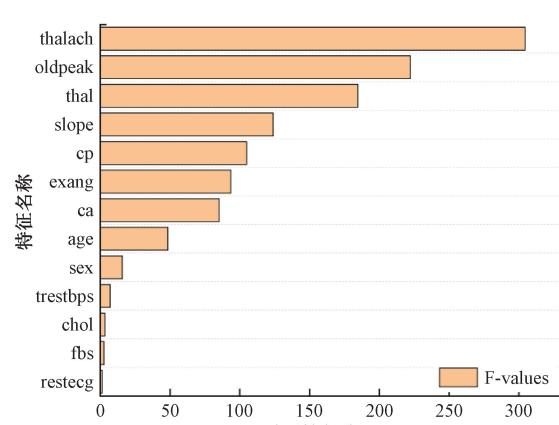


图 1 特征重要性得分

Fig. 1 The F-value of each feature

首先对样本数据的年龄和性别进行密度分析。通过绘制被测整体人群、CAD 患者以及正常人的年龄段核密度估计图,直观地比较这 3 类人群年龄段分布情况。如图 2 所示,CAD 患者的年龄段集中在 40~70 岁之间,说明 CAD 在中老年人群中具有较高发病风险,且发病人数聚集在 60 岁左右。而正常人集中在 40~60 岁,其分布情况几乎与被测人群年龄段相同。为了进一步探究性别因素对 CAD 患病概率的影响,绘制数据集全体样本性别比例和数据集中 CAD 患者性别比例对比,如图 3 所示。图 3(a) 中数据集的全体样本中男性占比 67.7%,大约为女性群体的 2 倍,但图 3(b) 中数据集 CAD 患者中男性占比 80.7%,竟超出女性群体 4 倍,CAD 患者的性别分布较总体样本发生明显偏移,一定程度说明男性更容易患病。因此应该对中老年人群尤其是男性群体加以关注和预防,做好早期筛查和诊断工作,及时有效地降低 CAD 发病风险,保障公众的健康与安全。

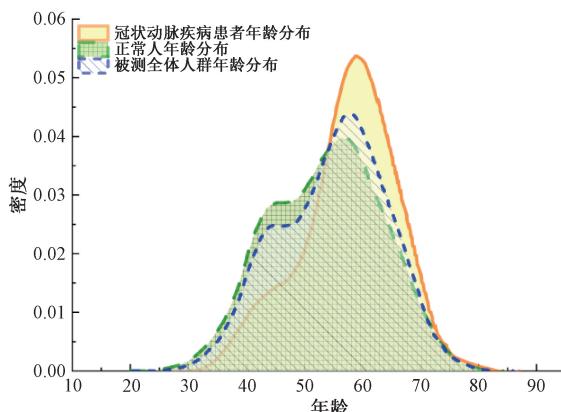


图 2 CAD 患者核密度估计图

Fig. 2 The visualization of age distribution of CAD using kernel density estimation

cp、exang、ca 和 thal 的 CAD 患病人数统计图如图 4(a)~(d) 所示。胸痛是 CAD 患者常见的症状,图 4(a) 中存在典型心绞痛(即 cp 取值为 4 时)的患者中,CAD 发病占 1/2 左右。而图 4(b) 运动会诱发心绞痛的患者中 CAD 发病概率超过 50%,说明是运动后出现心绞痛是 CAD 患病的显著信号,其反映了心脏在高需求状态下供血不足。ca 表示冠状动脉的钙化程度,其荧光显色血管数目越多表明动脉硬化越严重。图 4(c) 中 ca 数量大于 1 的患者大概率患有 CAD 且随荧光显色血管数目的增加患病概率会显著增加。表明冠状动脉钙化^[12]是 CAD 的一个重要表征因素。地中海贫血作为一种遗传性血液疾病,图 4(d) 中患有可逆缺陷型地中海贫血的患者中,CAD 发病率较高。这可能是因为具有可逆缺陷的地中海贫血症导致血液携氧能力下降造成心脏代偿性增大及功能受损,增大了 CAD 患病风险。

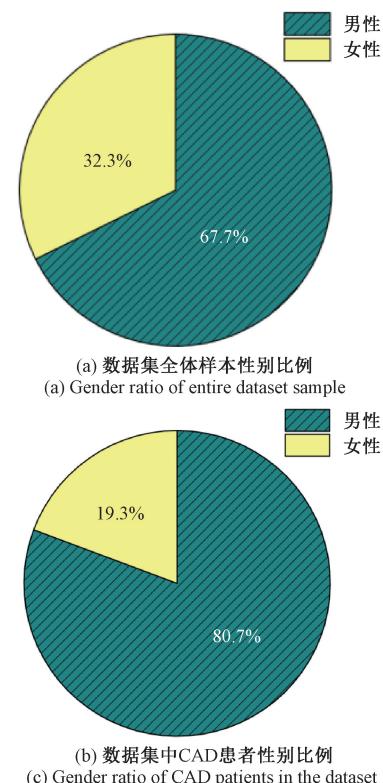


图 3 数据集总体性别比例与患 CAD 子集性别比例对比

Fig. 3 Comparison of the gender ration between the entire dataset sample and the CAD patient subset

在心脏病学中,ST 段的变化^[13]是评估心肌电生理活动及冠状动脉供血状态的重要指标之一。ST 相关因素与 CAD 关系的蜂群图如图 5 所示。在患有 CAD 的群体中,运动诱发的 ST 段变化斜率普遍呈平坦或下降趋势,且在运动状态下 ST 段的数值异常偏高,这强烈暗示了心肌细胞供血能力不足或心肌细胞受损。图中 ST 段数值尖峰在伴随斜率平坦或下降时的样本人群中几乎全部为 CAD 患者,这个现象在视觉上直观的呈现出 ST 相关因素与 CAD 患病的相关关系为 CAD 的早期诊断和风险评估提供了重要依据。

年龄-最大心率及 CAD 关系的散点图如图 6 所示,通过散点图可以看出,患有 CAD 的患者年龄较大并且心率较低。其中 40~70 岁病的被测试者在进行高强度活动或特定测试时,心率普遍集中在 140~180 次/min。随着年龄的增长,人体的生理机能包括心血管系统会有所衰退,可能导致最大心率的自然下降,但更显著地影响最大心率的降低因素是 CAD。这一结果表明年龄与最大心率之间呈负相关^[14],并且是否患有 CAD 与最大心率之间也呈负相关,但 CAD 对最大心率的影响更突出。

尽管通过多种方法共识筛选出关键因子有助于提高模型性能,但特征因子与目标变量中潜在的非线性映射

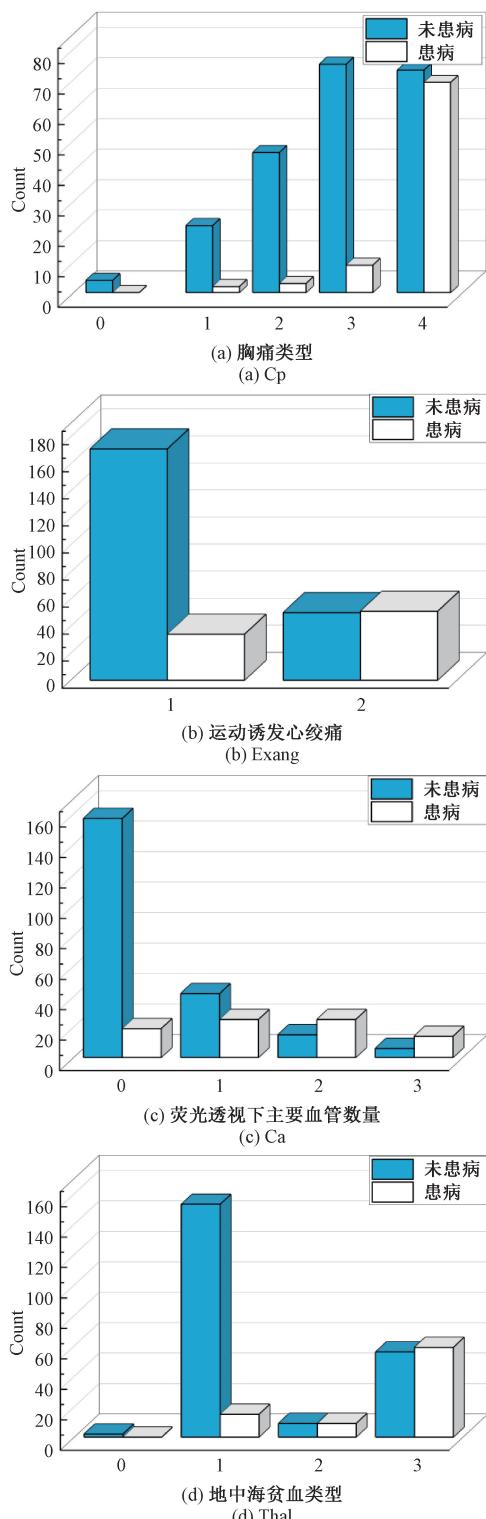


图 4 相关因素患 CAD 人数柱状图

Fig. 4 The symptoms of CAD patients

关系难以被传统线性模型充分捕捉。深度神经网络模型可以自主学习特征间的深层关系^[15], 对多因子协同作用进行端到端建模, 有效提高模型性能。

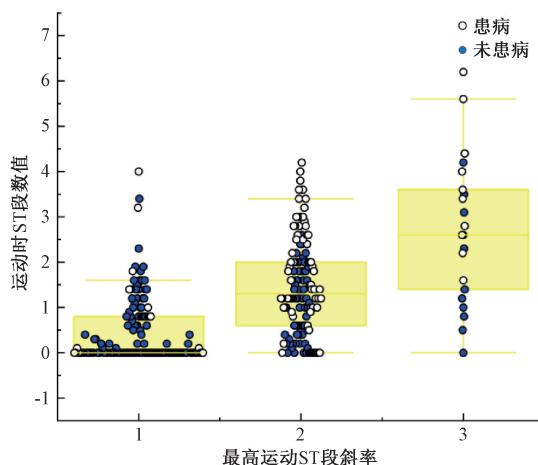


图 5 ST 相关因素与 CAD 关系的蜂群图

Fig. 5 Bee swarm plot of the relationship between ST-related factors and CAD

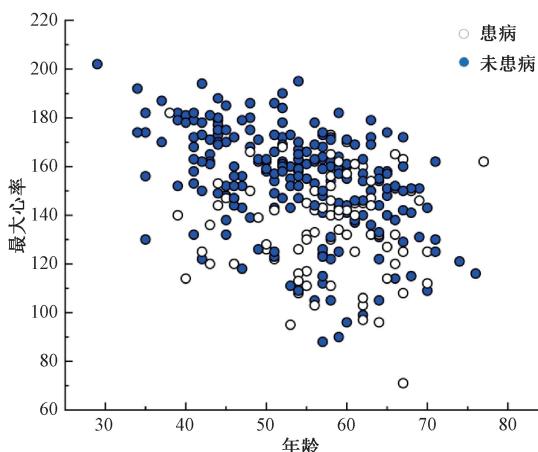


图 6 年龄-最大心率-CAD 关系的散点图

Fig. 6 Scatter plot of the relationship among age, thalach, and CAD

2 算法网络结构

2.1 融合注意力与残差机制的 BP 神经网络

本文构建了一个融合注意力与残差机制的 BP 神经网络, 其整体架构如图 7 所示。该模型定义了两个 Block 模块作为特征提取模块进行特征提取和转换, 每个 Block 模块以线性层、批量归一化层 (batch normalization, BN)、ReLU 激活函数及 Dropout 丢弃层构成。输入通过跳跃连接到特征提取模块后形成残差结构, 增强模型的学习能力和梯度传播。经残差连接后的特征以多头注意力机制的 3 个头并行处理数据捕捉特征间的相关性, 并拼接不同层次特征实现模型对输入数据的高效表征学习。对拼接后的特征进行线性变换在分类器模块利用 softmax 分类器完成分类任务。

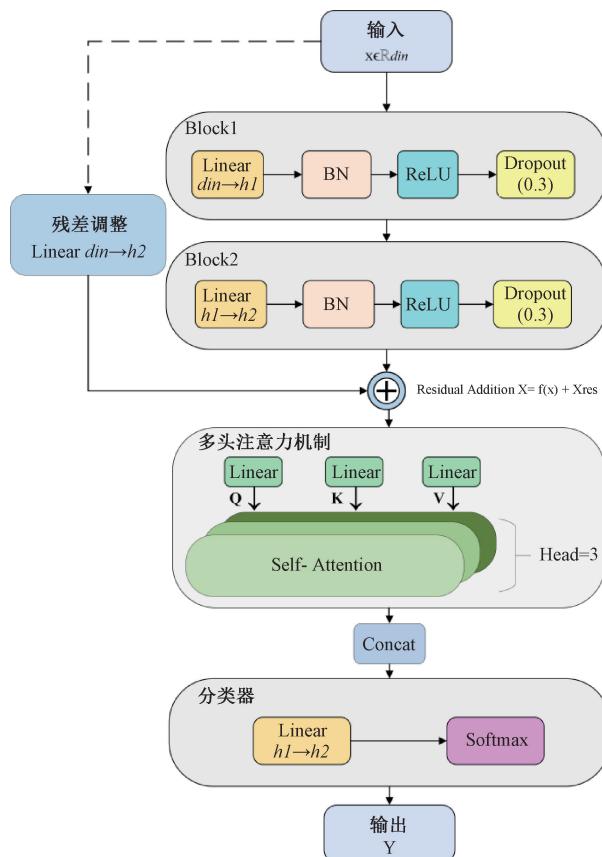


图 7 融合注意力与残差机制的 BP 神经网络结构

Fig. 7 The structure of BP neural network informed with attention and residual mechanisms

2.2 残差连接

残差连接指的是将维度相同的输入特征经短路路径直接添加到网络主路径的某一层输出上。这种线性叠加操作为信息和梯度的传播提供一个快速通道,使得信息可以更自由地流动,并且有效避免了梯度消失问题^[16]。本文将输入特征维度 din 经残差调整 (residual adjustment) 进行线性变换 $W_{res}(x)$ 维度映射成与主路输出维度 $h2$ 一致后获得残差特征 X_{res} 与主路输出 $f(x)$ 相加得到残差结构输出以增强梯度传播的稳定性,缓解深层网络的退化问题。残差调整与残差连接 (residual additions) 公式如下:

$$\text{Residual Adjustment: } X_{res} = W_{res} \cdot x \quad (1)$$

$$\text{Residual Additions: } X = f(x) + X_{res} \quad (2)$$

2.3 多头注意力机制

多头注意力机制由多个自注意力机制构成^[17],它通过模拟人类注意力的聚焦特性使用多个独立的注意力头,分别计算注意力权重,自动调整每个头的关注重点并将它们的结果进行拼接或加权求和,增强模型对特征之间复杂关系的学习能力^[18]。本文使用 3 个头的注意力

机制,将残差结构输出通过线性层形成查询向量 (query, Q)、键向量 (key, K) 和值向量 (value, V) 并将其分割成 3 个头的分别计算注意力,单个头执行缩放点积注意力计算注意力权重,如式(3)所示。

$$\text{Attention}_i(\mathbf{Q}_i, \mathbf{K}_i, \mathbf{V}_i) = \text{Softmax}\left(\frac{\mathbf{Q}_i \mathbf{K}_i^T}{\sqrt{d_k}}\right) \mathbf{V}_i \quad (3)$$

式中: d_k 其中为键向量维度, $i \in \{1, 2, 3\}$ 。

最后沿特征维度将每个头的输出拼接,并通过线性投影恢复维度以增强模型的表达能力和泛化能力,如式(4)所示。

$$\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{Att}_1, \text{Att}_2, \text{Att}_3) \mathbf{W}^0 \quad (4)$$

式中: \mathbf{W}^0 为输出线性投影矩阵; $\text{Att}_1, \text{Att}_2, \text{Att}_3$ 分别为 3 个注意力头计算的注意力权重。

2.4 激活函数

激活函数在深度学习网络中把输入非线性的映射给输出以帮助网络学习复杂的特征属性关系。常见的激活函数^[19]主要有 ReLU 激活函数、Sigmoid 激活函数、Tanh 激活函数和 Softmax 激活函数等。本文除分类器的输出层外均使用 ReLU 激活函数,解决了反向传播过程中的梯度消失问题,同时因 ReLU 激活函数中无指数计算使计算更简单。分类器输出层使用 sigmoid 激活函数更适用于 CAD 诊断的二分类任务。

2.5 网络参数设置

实验在使用的 PC 端为 LENOVO 制造的 81LG 型号。处理器搭载了基础频率为 1.80 GHz 的 Intel Core i7-8565U CPU,该 CPU 支持睿频约 2.0 GHz,拥有 8 个处理核心,内存配置了 8 GB 的 RAM。并在该 CP 端下载 Python3.8 版本,使用 CPU+2.4.1 版本的 Pytorch 框架构建融合注意力与残差机制的 BP 神经网络模型对克利夫兰数据集进行处理。该模型两个 Block 模块线性层分别将特征选择后的 9 个特征维度映射到 128 维、从 128 维压缩至 54 维,每个 Block 经线性变换后进行批量归一化及 ReLU 激活函数处理后随机失活 30% 的神经元作为正则化处理,保持特征的鲁棒性。注意力机制嵌入维度为 54,采用三头配置,每个注意力维度为 18,计算缩放点积注意力局部窗口大小 $K=3$ 。优化器采用 AdamW,学习率为 1×10^{-4} ,权重衰减为 1×10^{-3} ,将权重衰减与梯度更新分开处理,避免权重衰减对偏置参数的不必要影响,提高模型的训练效果。模型还引入早停机制监测验证集 F1 分数,在连续 15 个 Epoch 无提升时终止训练。将克利夫兰数据集按 7:3 的比例划分训练集和测试集,在该网络模型的预测性能。这一步骤不仅验证了模型在未见数据上的泛化能力,同时也为评估模型的实际应用价值提供重要依据。

3 结果评估分析

3.1 评估指标

在评估模型时, 使用准确率(accuracy)、精确度(precision)、召回率(recall)以及F1分数(F1 score)等多个性能指标, 量化地评价模型在实际应用中的表现。

准确率:

$$\text{Accuracy} = \frac{TP + TN}{TP + FN + FP + TN} \quad (5)$$

精确度:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (6)$$

召回率:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (7)$$

F1 分数:

$$F_1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (8)$$

式中: TP 和 TN 分别表示被准确预测为患有 CAD 和不患有 CAD 的患者样本个数; FP 和 FN 分别表示被错误预测为患有 CAD 和不患有 CAD 的患者样本个数。

3.2 评估结果

在 CAD 诊断过程中, 需要对多种化验指标进行综合分析来判断患者患病情况。为了更加快速、更加显著地得到 CAD 的诊断结果, 从众多因素中筛选出对诊断结果有显著影响的关键因子进行分析以提高诊断的准确性。本文通过特征选择找出对 CAD 影响显著的关键因子为 age、sex、thalach、exang、oldpeak、slope、ca、thal、cp。将这些关键因子作为 CAD 诊断模型的输入, 并验证对比特征选择前后的模型性能。实验结果显示模型在进行特征选择后准确率提高 2.3%, 彰显了特征选择的重要性和有效性。最终在构建的 CAD 诊断模型上测试集准确率达到 97.1%, 损失值仅为 0.093, 这表明模型能够达到相对较高的准确率。

3.3 对比实验

为验证本文所构建 CAD 诊断预测模型的有效性, 通过构造传统 BP 神经与引入注意力与残差机制两处改进后的 4 种模型配置进行对比实验, 获得不同模型在训练过程中准确率和损失变化的对比曲线如图 8、9 所示。单独引入注意力机制的网络模型准确率提升最快, 但损失曲线存在较大波动, 表明注意力机制强化了关键特征的提取但同时可能因注意力权重的动态调整引入了优化噪声, 使其鲁棒性不足。单独引入残差结构的网络模型对比传统 BP 神经网络也表现出更优的性能, 对 BP 神经网络损失下降滞后且停滞于较高水平的情况有所改善, 有

效缓解了网络退化问题。融合注意力与残差机制的 BP 神经模型的准确率最高且损失值最低, 其损失曲线收敛后变化平滑且改善了波动问题, 表明残差连接在稳定梯度传播的同时增强了模型训练的鲁棒性, 而注意力机制在动态特征分配中对模型稳定性的破坏也得到改善。基于以上分析, 注意力与残差机制的引入显著提高了模型的准确率且具有较强的鲁棒性。

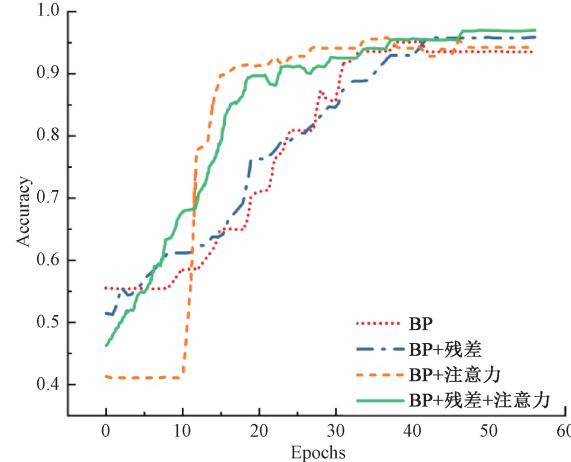


图 8 准确率对比曲线

Fig. 8 Accuracy comparison of different methods changing along with epochs

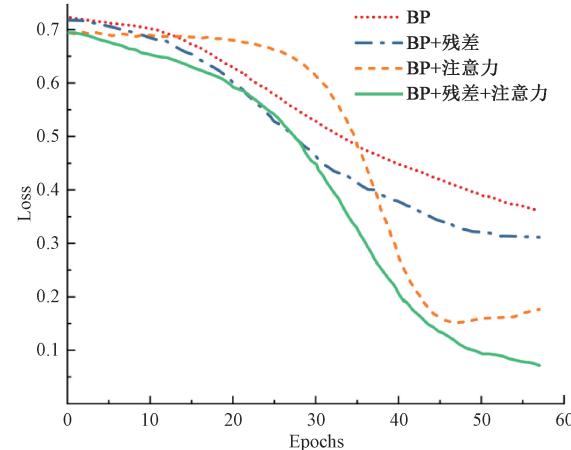


图 9 损失对比曲线

Fig. 9 Loss comparison of different methods changing along with epochs

同时在 UCI 官网 Heart Disease Data Set 中的其他 3 个心脏病数据集上进行验证, 并通过对比实验对比传统 BP 神经与引入融合注意力与残差机制两处改进后的性能差异, 验证模型在实际医学诊断中的泛化能力和鲁棒性。UCI 官网 Heart Disease Data Set 中的其他 3 个心脏病数据集分别为匈牙利数据集、弗吉尼亚长滩数据集和瑞士数据集, 其均为 CAD 数据集且样本分类极不平衡,

具体类别分布如表3所示。分别进行对比实验验证的准确率结果如表4所示,通过实验数据的验证及交叉对比,可以清晰地观察到引入注意力与残差机制的BP神经网络在4个数据集上取得最佳效果。尽管在其他3个数据集上表现效果稍逊于克利夫兰数据集,但其性能差异主要源于特征数据存在冠状动脉造影时荧光显色的主要血管数目和地中海贫血类型的数据缺失,且缺失特征被验证为影响CAD诊断关键因子。虽然数据质量制约了模型的泛化能力,但仍取得了相对不错的预测性能。因此,所提方法不仅能够准确诊断预测CAD的患病情况,还能有效应对数据不平衡的问题,从而验证了模型的鲁棒性。

表3 验证数据集样本分布

Table 3 Sample distribution of the validation dataset

	患 CAD	未患 CAD	总数
匈牙利	106	188	294
弗吉尼亚长滩	149	51	200
瑞士	115	8	123

表4 每个数据集在不同模型上的准确率

Table 4 The performance comparison of different

methods on variant datasets (%)

	BP+残差+注意力	BP+注意力	BP+残差	BP
克利夫兰	0.971	0.969	0.958	0.953
匈牙利	0.900	0.898	0.898	0.831
长滩	0.949	0.895	0.750	0.700
瑞士	0.945	0.936	0.864	0.859

为了更加有效地评估本模型的性能,通过计算模型准确率、精确度、召回率和F1分数评价模型各项指标并与经典机器学习算法得到的最优结果作比较,发现基于融合注意力与残差机制的BP神经网络的CAD诊断预测模型不仅在准确率上有较大提升,并且在其检测精度和召回数量上的提升效果也显著,表明模型不仅能准确识别患有CAD的患者而且漏检结果的概率较低,体现了融合注意力与残差机制的BP神经网络在CAD诊断预测中的核心竞争力。其对比表格如表5所示。

表5 各模型在克利夫兰数据集中的对比结果

Table 5 Comparison of our method with existing methods on the Cleveland heart disease dataset

模型	准确率	精确度	召回率	F1 分数
逻辑回归 ^[7]	0.885	0.878	0.906	0.892
随机森林 ^[20]	0.869	0.853	0.906	0.879
支持向量机 ^[21]	0.842	0.844	0.887	0.863
决策树 ^[20]	0.803	0.857	0.750	0.800
朴素贝叶斯 ^[20]	0.869	0.900	0.844	0.871
K最近邻 ^[22]	0.907	0.385	0.114	0.173
融合注意力与残差机制的BP神经网络	0.971	0.975	0.965	0.970

综上所述,深度学习的引入显著提高了以往基于机器学习的CAD诊断预测模型的预测准确性和性能。并通过对比经特征选择前后的模型和不同数据集对比实验验证分析可以清楚地看到特征选择及注意力残差机制引入的有效性和重要性。

4 结 论

本文提出一种融合注意力与残差机制的BP神经网络模型应用于CAD的诊断预测。其针对现有机器学习模型和传统BP神经网络所存在的特征间相关信息利用不足,模型泛化能力的局限性以及深层网络退化的问题进行革新。通过对克利夫兰数据集进行特征选择并可视化特征分布规律,降低数据维度减少冗余信息并为后续模型构建提供理论依据。融合注意力机制以提高模型对特征交互信息的捕捉能力,动态聚焦关键特征。引入残差结构缓解梯度消失促进信息的高效传递,并优化样本信息在模型训练中的利用率。在改进过程中通过两者的协同作用实现训练准确率的优化和稳健性的平衡,最终实现分类诊断的功能。通过实验的反复验证及各类理论模型的对比,该CAD诊断预测模型分类性能达到97.1%的准确率,显著优于传统机器学习模型和传统BP神经网络模型。此外,对UCI官网Heart Disease Data Set中的其他3个心脏病数据集应用此模型仍能获得较高的准确率,验证了所提模型在CAD诊断中显著的泛化能力和鲁棒性。此研究为CAD诊断预测提供了更有效的决策机制,未来继续发展有助于实现CAD早期的诊断和预测,为深度学习算法应用于医疗诊断领域开拓新思路。

虽然该模型在CAD的诊断预测性能上表现良好,但其决策过程的直观解释性存在挑战。这一挑战制约了模型在医学诊断中的临床实用性,因此未来有必要应用可解释性增强技术以揭示模型决策背后的逻辑和依据,保障模型与临床实践的紧密结合。

参考文献

- [1] 丁伟杰. 分类算法在心脏病预诊中的研究[D]. 西安: 西安电子科技大学, 2019.
- DING W J. Research on classification algorithms in the prediagnosis of heart disease [D]. Xi'an: Xidian University, 2019.
- [2] DETRANO R, JANOSI A, STEINBRUNN W, et al. International application of a new probability algorithm for the diagnosis of coronary artery disease [J]. American Journal of Cardiology, 1989, 64(5): 304-310.
- [3] BLACHNIK M, DUCH W. Prototype rules from SVM[C]. Proceedings of Rule Extraction from Support Vector Machines. Berlin: Springer, 2008.

- [4] LUNA J M, EATON E, UNGAR L H , et al. Tree-structured boosting: Connections between gradient boosted stumps and full decision trees [J]. ArXiv preprint arXiv:1711.06793, 2017.
- [5] 尹海宁,张文杰. Logistic 回归模型和随机森林模型对 AMI 患者 MACE 风险的预测价值[J]. 心血管病学杂志,2022,31(2):131-137.
- YIN H N, ZHANG W J. Predictive value of logistic regression model and random forest model for MACE risk in AMI patients [J]. Chinese Journal of Cardiovascular Rehabilitation Medicine, 2022, 31(2) : 131-137.
- [6] EL-SHAFIEY M G, HAGAG A, EL-DAHSHAN E A , et al. A hybrid GA and PSO optimized approach for heart-disease prediction based on random forest [J]. Multimedia Tools and Applications, 2022, 81 (13) : 18155-18179.
- [7] 杨敬桑,罗胤. 机器学习在心脏病风险预测中的应用研究[J]. 福建电脑,2024,40(8):12-16.
- YANG J S, LUO Y. Application research of machine learning in heart disease risk prediction [J]. Fujian Computer, 2024, 40(8) : 12-16.
- [8] 刘铭璇,唐东林,何媛媛,等. CNN 集成机器学习的金属缺陷少样本分类方法[J]. 电子测量与仪器学报, 2023,37(3):86-94.
- LIU M X, TANG D L, HE Y Y, et al. A CNN-integrated machine learning method for metal defect classification with small sample [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3):86-94.
- [9] 王健,李孝虔. 一种基于特征组合和卷积神经网络的心脏病预测新方法[J]. 黑龙江大学自然科学学报, 2019,36(1):115-120.
- WANG J, LI X Q. A new method for heart disease prediction based on feature combination and convolutional neural networks [J]. Natural Science Journal of Heilongjiang University, 2019,36(1) : 115-120.
- [10] 李涵,胡少兵,程为彬. CPSO 优化 BP 网络的 MEMS 陀螺随机误差补偿[J]. 电子测量与仪器学报, 2024, 38(11):228-234.
- LI H, HU SH B, CHENG W B. MEMS gyroscope random error compensation for CPSO optimized BP network [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(11) : 228-234.
- [11] 张一宁. 数据挖掘技术在医疗诊断中的应用——感知机模型诊断心脏病[J]. 电子制作,2019(4):8-10.
- ZHANG Y N. Application of data mining technology in medical diagnosis-diagnosis of heart disease using perceptron model [J]. Electronic Production, 2019 (4) : 8-10.
- [12] 王颖,赵晓静,马素文,等. 一站式护理在心脑血管 CTA 造影中的应用效果研究 [J]. 护理管理杂志, 2022,22(8):613-616.
- WANG Y, ZHAO X J, MA S W, et al. Study on the application effect of one-stop nursing in cardio-cerebrovascular CTA angiography [J]. Journal of Nursing Administration, 2022, 22(8) : 613-616.
- [13] 肖美娟,杨丽,付宇,等. 影响非器质性心脏病患者心电图 ST 段压低的因素分析 [J]. 现代医学, 2020, 48(6):736-740.
- XIAO M J, YANG L, FU Y, et al. Analysis of factors influencing ST-segment depression in non-organic heart disease patients [J]. Modern Medicine, 2020, 48(6) : 736-740.
- [14] 崔春生,曹艳丽,王美琦,等. 基于证据理论的心血管病预测方法研究 [J]. 数学的实践与认识, 2021, 51(13):121-128.
- CUI CH SH, CAO Y L, WANG M Q, et al. Research on cardiovascular disease prediction method based on evidence theory [J]. Mathematics in Practice and Theory, 2021, 51(13) : 121-128.
- [15] 钱伟,王亚丰,王晨,等. 基于 BP 神经网络与 $H\infty$ 滤波的锂电池 SoH-SoC 联合估计研究 [J]. 仪器仪表学报, 2024,45(6):307-319.
- QIAN W, WANG Y F, WANG CH, et al. Study on joint estimation of SoH and SoC of lithium battery based on BP neural network and $H\infty$ filter [J]. Journal of Instrumentation, 2024,45(6):307-319.
- [16] TOUVRON H, BOJANOWSKI P, CARON M, et al. ResMLP: Feedforward networks for image classification with data-efficient training[C]. International Conference on Learning Representations, 2021.
- [17] HEO B, YUN S, HAN D, et al. Rethinking spatial dimensions of vision transformers[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2021.
- [18] 谷瑞,宋翠玲,李元昊. 改进 Res2Net 和注意力的中药饮片识别模型 [J]. 国外电子测量技术,2024,43(9): 130-140.
- GU R, SONG C L, LI Y H. Improved Res2Net and attention-based identification model of Chinese herbal slices [J]. Foreign Electronic Measurement Technology, 2024,43(9):130-140.
- [19] 李忠兵,袁章雨,梁海波,等. 多层非线性局部感受野极限学习机方法用于录井气体分析 [J]. 仪器仪表学报,2024,45(3):157-169.
- LI ZH B, YUAN ZH Y, LIANG H B, et al. Multi-layer nonlinear local receptive field limit learning machine

- method for logging gas analysis [J]. Journal of Instrumentation and Measurement, 2024, 45 (3): 157-169.
- [20] 蒋美艳,张辉.机器学习算法对心脏病预测效能的研究[J].中国医学物理学杂志,2024,41(7):905-909.
JIANG M Y, ZHANG H. Study on the predictive efficacy of machine learning algorithms for heart disease [J]. Chinese Journal of Medical Physics, 2024, 41(7): 905-909.
- [21] 章珊珊,陈蒙蒙,方振红,等.基于机器学习的心脏病预测模型构建与探讨[J].医院管理论坛,2024,41(5):58-61.
ZHANG SH SH, CHEN M M, FANG ZH H, et al. Construction and discussion of heart disease prediction model based on machine learning [J]. Hospital Management Forum, 2024, 41(5): 58-61.
- [22] 梁靖涵,许亚杰.基于机器学习算法的心脏病预测诊断模型研究[J].现代信息科技,2022,6(19):67-70.
LIANG J H, XU Y J. Research on heart disease prediction and diagnosis model based on machine learning algorithms [J]. Modern Information Technology, 2022, 6(19): 67-70.

作者简介



张汇文,2023年于天津职业技术师范大学获得学士学位,现为天津职业技术师范大学硕士研究生,主要研究方向为检测技术与自动化装置。

E-mail: 0521231029@ tute. edu. cn

Zhang Huiwen received her B. Sc. degree from Tianjin University of Technology and Education in 2023. Now she is M. Sc. candidate at Tianjin University of Technology and Education. Her main research interests include detection technology and automation equipment.

杨晓霞(通信作者),2009年于长春理工大学获得学士学位,2011年于天津大学获得硕士学位,2014年于天津大学获得博士学位,现为天津职业技术师范大学副教授,主要研究方向为信息传感与处理。

E-mail: yangxiaoxia0925@ 163. com



Yang Xiaoxia (Corresponding author) received her B. Sc. degree from Changchun University of Science and Technology in 2009, M. Sc. degree from Tianjin University in 2011 and Ph. D. degree from Tianjin University in 2014, respectively. Now she is an associate professor in Tianjin University of Technology and Education. Her main research interests include information sensing and processing.



高娜,2023年于唐山师范学院获得学士学位,现为天津职业技术师范大学硕士研究生,主要研究方向为检测技术与自动化装置。

E-mail: 2966043442@ qq. com

Gao Na received her B. Sc. degree from Tangshan Normal College in 2023. Now she is a M. Sc. candidate at Tianjin University of Technology and Education. Her main research interests include detection technology and automation equipment.



王宁,2016年于天津工业大学获得学士学位,现为天津职业技术师范大学硕士研究生,主要研究方向为检测技术与自动化装置。

E-mail: w490277874@ 163. com

Wang Ning received his B. Sc. degree from Tiangong University in 2023, M. Sc. Now he is a M. Sc. candidate at Tianjin University of Technology and Education. His main research interests include detection technology and automation equipment.



张翠翠,2008年于山东大学大学获得学士学位,2011年于山东大学获得硕士学位,2015年于日本京都大学获得博士学位,现为天津大学副教授,主要研究方向为智能信息处理与识别。

E-mail: cuicui. zhang@ tju. edu. cn

Zhang Cuicui received her B. Eng. degree and M. Eng. degree from Shandong University in 2008 and 2011, respectively. She received Ph. D. degree from Kyoto University, Japan in 2015. Now she is an associate professor in Tianjin University. Her main research interests include intelligent information processing and recognition.