

基于深度学习的心血管病急诊患者运动处方开发与分析

孙妍* 张瑾 曾霞 冯卢

四川省医学科学院·四川省人民医院(电子科技大学附属医院)

DOI:10.12238/acair.v2i4.10292

[摘要] 目的: 利用深度学习技术为急诊心血管疾病(CVD)患者开发个性化运动处方。方法: 通过三维健康评估方法生成个性化运动处方。利用CNN和RNN组合生成深度学习模型,选取200名急诊CVD患者,随机分为实验组和对照组。实验为期12周,每4周评估一次。结果: 在深度学习模型训练后,运动处方信息归类准确度达88.5%,其中实验组在心率、收缩压、6分钟步行测试(6MWT)和最大摄氧量(VO_2 Max)等关键指标上显示出轻微的优势,特别是在收缩压和心率方面表现更为显著。结论: 基于深度学习生成的个性化运动处方能够有效提升急诊CVD患者的心血管功能、运动耐力及依从性。

[关键词] 心血管疾病; 深度学习; 运动处方; 急诊

中图分类号: R714.252 文献标识码: A

Development and Analysis of Exercise Prescriptions for Cardiovascular Emergency Patients Based on Deep Learning

Yan Sun* Jin Zhang Xia Zeng Lu Feng

Sichuan Academy of Medical Sciences • Sichuan Provincial People's Hospital (Affiliated Hospital of University of Electronic Science and Technology of China)

[Abstract] Objective: To develop personalized exercise prescriptions for emergency cardiovascular disease (CVD) patients using deep learning techniques. Methods: A personalized exercise prescription was generated through a three-dimensional health assessment method. A deep learning model was created using a combination of CNN and RNN. A total of 200 emergency CVD patients were randomly divided into an experimental group and a control group. The experiment lasted for 12 weeks, with evaluations conducted every 4 weeks. Results: After training the deep learning model, the classification accuracy for exercise prescription information reached 88.5%. The experimental group showed slight advantages in key metrics such as heart rate, systolic blood pressure, 6-minute walk test (6MWT), and VO_2 Max, with more significant improvements in systolic blood pressure and heart rate. Conclusion: Personalized exercise prescriptions generated by deep learning can effectively improve cardiovascular function, exercise endurance, and compliance in emergency CVD patients.

[Key words] Cardiovascular disease; Deep learning; Exercise prescription; Emergency

1 概述

心血管疾病 (Cardiovascular Disease, CVD) 是全球范围内导致死亡和残疾的主要原因之一,其发病率和急诊就诊人数呈持续上升的趋势^[1]。运动处方作为心血管疾病管理中的重要手段,已被证明可以有效改善患者的心血管功能和整体健康状况^[2]。然而,传统的运动处方通常基于临床医生的经验和指南,难以适应急诊CVD患者的复杂需求^[3]。急诊CVD患者通常存在更高的风险和更复杂的病情特征,针对这些患者的个性化运动处方需求更为迫切^[4]。随着信息技术的发展,结合人工智能手段的运动处方通过分析患者的健康状况、体力活动水平和疾病风险因素,以帮助患者更好地管理心血管疾病的一种运动干预手段。

但在急诊科这一特殊环境下,运用深度学习技术开发心血管疾病患者运动处方的研究还比较少见。本研究旨在基于深度学习技术开发个性化的运动处方,以提升急诊CVD患者的运动康复效果。

2 CVD患者三维运动处方构建

2.1 CVD患者三维运动处方算法

本研究基于《心血管疾病危险因素不同组合患者的运动处方》与《美国运动学会指南》^[5]中的运动处方设计原理,通过综合评估不同疾病风险因素来生成适合患者的运动处方。本研究的运动处方生成基于三维度的健康评估指标,包括一般情况、医疗主诊断及医疗指标、运动影响因素。一般情况包括:

年龄、性别、婚姻状况和既往病史。医疗指标: 身高、体重、BMI、血脂、血压, 脉搏, 呼吸。主要诊断为: 高血压、糖尿病、血脂异常。运动影响因素包括运动目标值(血压 $<140/90\text{mmHg}$)、运动警告症状(头晕或不适, 胸痛或不适, 异常呼吸困难, 运动中收缩压 $\geq 250\text{mmHg}$, 运动中舒张压 $\geq 115\text{mmHg}$)、体力活动类型(轻、中、重)、Borg评分及运动禁忌症(血压 $>180/105\text{mmHg}$, 运动前24小时内发生低血糖发作, 血糖浓度 $>17\text{mmol/L}$, 血糖浓度 $<7\text{mmol/L}$ 和设计明确的运动禁忌症疾病)。

2.2 CVD患者不同病种的三级运动处方

采用便利抽样法, 样本量为200名, 选取主诊断为高血压, 血脂异常和糖尿病并需要开具运动处方的患者, 具体的内容见表1。

表1 不同CVD患者三级运动处方内容

| 病种 | 运动处方类别 | 运动处方内容 |
|------|--------|---|
| 高血压 | 低运动量 | 时间: 30-50分钟/天, 5-7次/周 形式: 有氧或抗阻训练, 如呼吸操、太极、八段锦、坐立训练 标准: 心率储备 $<40\%$ |
| | 中运动量 | 时间: 30-50分钟/天, 5-7次/周, 其中阻力运动2-3次/周 形式: 有氧或抗阻训练, 如呼吸操、太极、八段锦、坐立训练 标准: 心率储备 $40\%-60\%$ |
| | 高运动量 | 时间: 70分钟-160分钟/次 形式: 间歇式有氧运动, 间隔2分钟 标准: 心率储备 $60\%-80\%$ |
| 血脂异常 | 低运动量 | 时间: 30-60分钟/天, 5次/周 形式: 有氧运动 标准: 运动强度 $<50\%$ 最高心率, Borg评分 <13 分 |
| | 中运动量 | 时间: 30-90分钟/次, 6-7次/周 形式: 有氧运动 标准: 运动强度在 $50\%-70\%$ 最高心率, Borg评分13-16分 |
| | 高运动量 | 时间: >3 次, 总消耗量5040-9240KJ 标准: 运动强度 $>70\%$ 最高心率, Borg评分 >16 分 |
| 糖尿病 | 低运动量 | 时间: 30分钟, 每周150分钟, >5 次/周。 形式: 步行、广播体操、下楼 标准: 有氧能力值 $<3\text{MET}$, 心率控制在最大心率的 $50\%-60\%$ |
| | 中运动量 | 时间: >5 天/周, 20分钟/次, 每周150分钟 形式: 慢跑、滑冰、羽毛球、骑自行车、下楼 标准: 有氧能力值在 $3-6\text{MET}$, 心率控制在最大心率的 $60\%-85\%$ |
| | 高运动量 | 时间: 5分钟/次, 每周90分钟 形式: 舞蹈、快速爬楼、游泳、跳绳、举重 标准: 标准: 有氧能力值 $>6\text{MET}$, 心率控制在最大心率 $>85\%$ |

3 基于深度学习的心血管病急诊患者运动处方开发模型

3.1 数据集收集与预处理

3.1.1 数据来源

本研究的数据主要来自于急诊心血管疾病(CVD)患者的临

床健康数据、运动相关数据和生活方式数据, 具体包括以下几类: (1)从医院信息系统(HIS)中提取的患者急诊数据, 包括患者的血压、血糖、血脂、心率、BMI等指标。(2)运动数据: 基于可穿戴运动手环收集的患者运动量、运动强度、心率波动等数据, 研究者获取患者在急诊后康复过程中运动的频率、强度和持续时间等关键信息, 为模型提供重要输入变量。经汇总, 共收集200条有效的病情数据。

3.1.2 数据预处理与特征提取

(1)缺失值处理: 由于急诊数据往往存在信息不完整的情况, 本研究采用插补法对缺失值进行处理。对于连续变量, 如患者的血压、心率等, 采用均值插补或中位数插补; 对于分类变量, 如患者的疾病史、性别等, 采用众数插补。对于难以通过插补修正的严重缺失数据, 则考虑将该患者数据排除出分析集。(2)异常值检测: 通过统计分析方法对数据中的异常值进行检测, 并根据医疗标准对超出正常范围的数据进行修正或删除。例如, 若某患者的心率值超出了生理学合理范围, 则需进一步核查数据来源, 确认是否为录入错误。(3)数据标准化: 由于不同健康指标具有不同的量纲和范围, 为避免不同特征间的权重差异对模型产生不良影响, 本研究采用Z-score标准化方法对数据进行标准化处理。具体而言, 将每个变量的均值调整为0, 标准差调整为1, 以确保特征的可比性。(4)特征提取与选择: 通过初步的数据探索与专家反馈, 从中提取与心血管疾病风险评估和运动处方相关的重要特征。例如, 心率变异性、血糖波动等时间序列特征被认为对运动处方的个性化制定具有较大影响^[6]。此外, 采用主成分分析(PCA)等降维方法减少冗余特征, 从而提高模型的训练效率和泛化能力。

3.2 深度学习模型设计

本研究基于多层深度神经网络架构, 结合卷积神经网络(CNN)与递归神经网络(RNN), 开发了一个集成模型, 用于生成个性化运动处方。整个模型的工作流程如下图1所示:

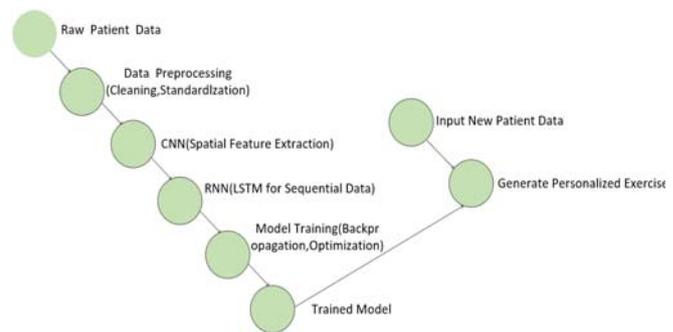


图1 个性化运动处方的模型工作流程图

该模型主要由CNN和RNN共同组合完成, 其中卷积CNN在医学影像分析中表现出色, 能够自动提取数据中的空间特征, 尤其适用于处理心血管影像数据和多维生理数据^[7]。在本研究中, CNN被用于处理心率数据。RNN, 特别是其变种长短时记忆网络(LSTM), 在处理时间序列数据方面表现突出, 适合分析患者的动态生理

指标(如心率、血糖波动等)。在本研究中,RNN主要用于分析急诊CVD患者的连续运动数据和生理数据。通过对这些时间序列数据的建模,RNN能够预测患者的康复进展,并在运动处方中进行实时调整。

3.3 模型集成与输出

为提高模型的整体性能,研究者将CNN与RNN的输出结果进行集成。具体来说,CNN负责提取患者的空间特征,而RNN负责处理患者的动态时间序列特征。集成后的模型能够根据患者的健康评估结果,生成个性化的运动处方,建议适宜的运动频率、强度、方式和持续时间^[8]。

3.4 模型参数设置与优化

为确保模型的有效性,本研究采用了交叉验证与独立测试集进行模型性能评估。评估指标包括准确率与精确度等。通过8:2的比例对训练集与验证集进行划分,优化模型的超参数如下:

a. CNN模型:

卷积层: 使用多层卷积层,每层包含32个的卷积核。

池化层: 在每层卷积层后使用2x2的最大池化层,以减少数据维度。

全连接层: 使用两层全连接层,每层包含128个神经元,激活函数为ReLU。

输出层: 使用softmax激活函数。

优化器: Adam优化器,学习率设置为0.001。

b. RNN模型参数

输入层: 与CNN模型相同,接受预处理后的心电图数据。

LSTM层: 使用两层LSTM层,每层包含64个LSTM单元。

全连接层: 与CNN模型相同,使用两层全连接层进行特征提取。

输出层: 与CNN模型相同,根据任务需求选择合适的输出层结构。

优化器与损失函数: 与CNN模型相同。

此外,模型的输出结果将与运动康复专家的人工处方进行比对,以确保其临床实用性。

3.5 运动处方生成与验证

3.5.1 运动频率

根据患者的心血管功能状况和健康评估结果,模型首先确定每周的运动频率。对于低风险患者,通常推荐每周进行3至5次中等强度的有氧运动。中高风险患者则建议从较低频率开始,并根据康复进展逐步增加运动次数。

3.5.2 运动强度

模型通过分析患者的心率、血压、Borg评分等数据,自动生成个性化的运动强度建议。例如,低风险患者可以参与中等强度的运动(如快走或慢跑),而中高风险患者则需要从低强度运动(如缓步行走、简单的力量训练)开始,逐步增加强度,同时避免因过度运动引发的心血管事件。

3.5.3 运动时间

每次运动的持续时间也是根据患者的健康评估数据确定的。低风险患者的运动时间通常为30至60分钟,而中高风险患者可能需要从更短的时间段(如10至15分钟)开始,逐步延长运动时间。

3.5.4 运动方式

根据患者的需求和偏好,结合他们的健康状况,模型建议不同的运动方式,如有氧运动(如步行、游泳)、力量训练(如抗阻训练)和柔韧性训练(如拉伸运动)等。对于中高风险患者,建议在医生或专业运动康复师的指导下进行训练,以确保安全。

3.6 实验设计

3.6.1 研究选取了200名急诊CVD患者,患者随机分为两组

一组接受基于深度学习模型生成的个性化运动处方(实验组),另一组接受由医生根据经验和临床指南手动制定的传统运动处方(对照组)。实验为期12周,每4周进行一次评估和调整。患者基本情况见表2。

表2 运动处方患者基本情况

| 变量 | 类别 | 例数 | 百分比 |
|--------|-------------|-----|------|
| 性别 | 男性 | 108 | 54 |
| | 女性 | 92 | 46 |
| 婚姻状况 | 已婚 | 52 | 26 |
| | 丧偶 | 50 | 25 |
| | 离婚 | 49 | 24.5 |
| | 单身 | 49 | 24.5 |
| 主诊断 | 高血压 | 68 | 34 |
| | 糖尿病 | 66 | 33 |
| | 血脂异常 | 66 | 33 |
| 体力活动类型 | 重度活动 | 77 | 38.5 |
| | 中度活动 | 64 | 32 |
| | 轻度活动 | 59 | 29.5 |
| 运动禁忌症 | 无 | 108 | 54 |
| | 血压>180/105 | 28 | 14 |
| | 低血糖发作 | 32 | 16 |
| | 血糖>17mmol/L | 20 | 10 |
| | 血糖<7mmol/L | 12 | 6 |
| 运动警告症状 | 无 | 99 | 49.5 |
| | 头晕或不适 | 33 | 16.5 |
| | 胸痛或不适 | 34 | 17 |
| | 异常呼吸困难 | 18 | 9 |
| | 运动中高血压 | 16 | 8 |

3.6.2 效果评估指标

为评估运动处方的效果,本研究使用了以下关键指标: (1) 心血管功能改善: 通过定期监测患者的心率、血压,评估其心血管功能的变化。(2) 运动耐力提升: 通过6分钟步行测试(6MWT)

和最大摄氧量($VO_2\max$)测试,评估患者的运动耐力和心肺功能改善程度。(3)患者依从性:全部依从记2,部分依从记1,没有依从记0。结果见表3。对表3的结果再进行显著性检验,结果显示, $VO_2\max$:在第4周(t 值=2.14, p 值=0.033)。依从性:在第4周(t 值=-5.23, p 值<0.0001)和第8周(t 值=-2.15, p 值=0.033),实验组显著高于对照组,其余组间比较无差异。

表3 运动处方的效果评价表

| 组别 | 周次 | 平均心率 (次/分钟) | 平均收缩压 (mmHg) | 平均舒张压 (mmHg) | 平均6MWT 距离(米) | 平均 $VO_2\max$ (ml/kg/min) | 平均依从性 |
|-----|----|-----------------|------------------|------------------|------------------|------------------------------|---------------|
| 对照组 | 4 | 81.5± 13.37 | 163.32 ±26.3 | 97.34± 15.3 | 451.44± 69.4 | 31.08±6.42 | 1.14± 0.71 |
| 实验组 | 4 | 81.45 ±12.15 | 166.26 ±27.4 | 98.19± 15.87 | 465.56± 67.31 | 29.17±6.14 | 1.61± 0.57 |
| 对照组 | 8 | 83.37 ±13.59 | 166.44 ±27.18 | 99.46± 16.28 | 470.14± 65.06 | 31.56±7.13 | 1.21± 0.76 |
| 实验组 | 8 | 83.43 ±13.01 | 170.46 ±25.88 | 100.16± 16.86 | 455.93± 58.59 | 30.87±5.93 | 1.43± 0.71 |
| 对照组 | 12 | 85.08 ±14.25 | 168.85 ±25.43 | 101.15± 15.64 | 478.54± 66.6 | 32.11±6.96 | 1.21± 0.75 |
| 实验组 | 12 | 84.55 ±12.73 | 173.85 ±28.01 | 101.16± 15.9 | 467.63± 66.05 | 32.22±6.13 | 1.39± 0.66 |

4 结果与讨论

4.1 模型的准确性与有效性分析

4.1.1 深度学习模型评估指标

经训练,本实验所采用的RNN+CNN深度学习组合模型对个性化处方生成取得了良好的分类成绩,具体见表4:

表4 模型实验评估结果

| 评估指标 | 模型结果 |
|------------------|-------|
| 准确率(Accuracy) | 88.5% |
| 召回率(Recall) | 86.3% |
| F1分数(F1-Score) | 87.2% |
| 特异性(Specificity) | 90.7% |
| 敏感性(Sensitivity) | 86.3% |

准确率:RNN+CNN模型的准确率为88.5%,这表明组合模型在预测心血管疾病患者病情方面具有更高的准确性。

召回率:RNN+CNN模型的召回率为86.3%,召回率反映了模型识别正例(即心血管疾病患者)的能力,组合模型在这方面表现更好。

F1分数:RNN+CNN模型的F1分数为87.2%,F1分数是准确率和召回率的调和平均数,能够综合反映模型的性能。

特异性和敏感性:RNN+CNN模型在特异性和敏感性方面也

表现出色,分别达到了90.7%和86.3%,特异性和敏感性分别反映了模型识别非病例和病例的能力,组合模型在这两方面都更具优势。

4.1.2 运动处方结果分析

实验组接受了基于深度学习生成的个性化运动处方,而对照组接受了由医生根据经验和临床指南手动制定的传统运动处方。心率和血压:实验组的心率和血压在12周内有所改善,特别是在第12周,实验组的平均心率从第4周的81次/分钟上升到85次/分钟,而对照组从82次/分钟上升到85次/分钟,差异不大。但是实验组在收缩压方面表现出更明显的改善,从166mmHg增加到174 mmHg,这表明模型生成的运动处方对心血管压力的管理有一定效果。6分钟步行测试(6MWT):6MWT是评估患者运动耐力的重要指标。实验组在第12周的6MWT平均成绩为468米,较第4周的466米有所提升,尽管提升幅度有限。但与对照组相比(479米),实验组的改善并未显著超出对照组。考虑到个体差异和样本的局限性,模型在运动耐力改善上的效果需进一步探索。 $VO_2\max$ (最大摄氧量):实验组的 $VO_2\max$ 从第4周的29ml/kg/min上升到第12周的32ml/kg/min,说明在心肺功能上有所提升。对照组在12周内也从31ml/kg/min提升至32ml/kg/min,显示出两组患者的改善程度相当。这意味着模型生成的运动处方与传统处方在心肺功能改善方面表现相近,具有一定的有效性。依从性:实验组的依从性在第4周时高于对照组(2vs1),表明深度学习生成的个性化运动处方可能更能激励患者坚持完成运动任务。但到了第12周,依从性差异缩小,这可能与长期干预的患者行为变化有关,也可能与模型生成的处方需进一步优化相关。

4.2 深度学习生成运动处方对CVD患者的影响

个性化运动方案:相比于传统的手动处方,深度学习模型能够根据患者的实时数据动态调整运动方案,确保运动强度适合个体健康状况。这种动态调整使得实验组患者在早期阶段的依从性明显高于对照组,说明个性化运动处方在提高患者运动积极性和依从性方面具有较大优势。

健康指标改善:实验组的心血管功能指标,如心率、血压、6MWT和 $VO_2\max$,在12周内都显示出一定的改善,说明深度学习生成的运动处方在增强心血管功能、提升运动耐力方面是有效的。虽然两组在大多数指标上差异不大,但实验组在依从性上的初期优势可能有助于长期干预效果的进一步显现。

长期效果及可持续性:尽管实验组在第12周时的依从性与对照组相近,但早期依从性的提高有可能带来长期的健康收益。未来的研究可以继续关注深度学习生成的处方在长期干预中的持续效果。

5. 结论

本研究的数据表明,深度学习生成的运动处方在提高患者依从性、改善心血管功能和运动耐力方面具有一定的优势。然而,短期内与传统处方相比,效果差异并不显著,未来的研究可进一步优化模型,提升个性化处方的准确性与长期有效性。

四川省科技计划资助,项目编号: 2023YFS0068。

[参考文献]

[1]WorldHealth Organization.Cardiovascular diseases (CVDs). WHO, 2021.

[2]Fletcher GF,Ades PA,Kligfield P,etal.Exercise standards for testing and training: a scientific statement from the American Heart Association[J]. Circulation. 2013;128(8):873-934.

[3]Esteva A, Robicquet A,Ramsundar B,etal.A guide to deep learning in healthcare. Nature Medicine[J].2019;25(1):24-29.

[4]Benjamin EJ,Virani SS, Callaway CW, et al. Heart Disease and Stroke Statistics—2019Update:A Report From the American Heart Association. Circulation[J].2019;139(10).

[5]Fletcher GF,Ades PA,Kligfield P,etal.Exercise standards for testing and training: a scientific statement from the American Heart Association[J].Circulation.2013;128(8):873-934.

[6]Topol EJ.High-performance medicine: the convergence of human and artificial intelligence.Nature Medicine[J].2019; 25(1):44-56.

[7]Song X, Baghoolizadeh M, Alizadeh A, et al. Utilizing machine learning algorithms for prediction of the rheological behavior of ZnO (50%)–MWCNTs (50%)/Ethylene glycol (20%)–water (80%) nano-refrigerant[J].International Communications in Heat and Mass Transfer,2024,156:107634.

[8]Miotto R,Wang F,Wang S,etal.Deep learning for health care: review, opportunities, and challenges[J]. Briefings in Bioinformatics.2018;19(6):1236-1246.

作者简介:

孙妍(1979—),女,汉族,四川成都人,博士,四川省医学科学院·四川省人民医院(电子科技大学附属医院),研究方向: 医工结合大数据分析。