

利用机器学习预测术前护理对手术压疮预防的效果

张倩莹^① 邱迪聪^② 张泽勇*

【摘要】 目的：引入机器学习技术对手术压疮的术前护理预防效果进行预测。方法：利用本院的评估标准及数值归一化对匿名采集到的474例手术数据预处理，用于训练干预组预测模型。对比干预组模型与对照组模型在校验数据集上的准确率以评估干预组模型学习效果，对比它们在测试数据集上的准确率以评估干预组模型在实际应用中的预测性能。结果：相较于对照组模型，经过100轮训练迭代后的干预组预测模型，在校验数据集上预测准确率达到 $90.03\% \pm 0.12\%$ ，差异有统计学意义 ($P < 0.001$)；在测试数据集上预测准确率达到 $90.35\% \pm 0.14\%$ ，差异有统计学意义 ($P < 0.001$)。结论：利用机器学习，可构建并训练出有显著学习效果的神经网络预测模型，能对压疮术前护理效果进行有效的预测，为压疮术前护理提供有意义的量化参考。

【关键词】 人工智能 机器学习 压疮 术前护理 预测

Doi:10.3969/j.issn.1673-7571.2021.04.010

【中图分类号】 R319 **【文献标识码】** A

Predict the Effect of Preoperative Nursing on the Prevention of Surgical Pressure Ulcers by Using Machine Learning / ZHANG Qian-ying, QIU Di-cong, ZHANG Ze-yong.

Abstract: Objective: To introduce machine learning technology in predicting preoperative care effectiveness for pressure ulcers. Methods: A total of 474 anonymous operative pressure ulcer records were collected and preprocessed following our hospital's standard procedures, which were then used to train a neural network predictive model as intervention group. The trained model was compared against random models in control group to evaluate its learning performance on the validation dataset and its practical predictive performance on the test dataset, respectively. Results: Compared to the control group, the intervention group model, after 100 training epochs, achieved predictive accuracy of $90.03\% \pm 0.12\%$ on validation data exhibiting significantly effective learning performance ($P < 0.001$), and that of $90.35\% \pm 0.14\%$ on test data exhibiting significantly effective practical predictive performance ($P < 0.001$). Conclusion: The application of machine learning technology facilitates preoperative care for pressure ulcers, by constructing and training effective neural network predictive models to project preoperative care effectiveness providing meaningful quantitative reference in practice.

Keywords: artificial intelligence, machine learning, pressure ulcers, preoperative care, prediction

Fund project: Medical Science Research Fund Project of Guangdong Province (No. B2021194)

Corresponding author: Operating Room, the First Affiliated Hospital of Guangzhou Medical University, Guangzhou 510120, Guangdong Province, P.R.C.

基金项目: 广东省医学科研基金项目 (编号: B2021194)

*通信作者: 广州医科大学附属第一医院手术室, 510120, 广东省广州市越秀区沿江西路151号

①广州医科大学附属第一医院手术室, 510120, 广东省广州市越秀区沿江西路151号

②卡耐基梅隆大学计算机学院, 15213, 美国宾夕法尼亚州匹兹堡市福布斯大街5000号

压疮 (pressure ulcers, PUs) 是一种常见于骨隆突处的局部皮肤或皮下组织损伤, 它由持久性的压力 (包括剪切力和摩擦力) 导致。由于手术类型、手术时长、手术体位、手术床接触面材质等多种因素的共同作用^[1], 手术患者是发生院内压疮的高危人群。Shafipour 等^[2]在2016年对9 527名病人进行的一项大规模调研显示, 手术患者术后压疮的出现几率高达18.96% (95%CI: 15.3~22.6)。压疮可导致患者住院时间的延长, 甚至严重影响患者治疗的质量, 进而增加患者的医疗成本, 影响医患关系的和谐发展。因此, 压疮一直以来都是手术室护理管理的重点内容, 也是评价手术室护理质量的重要指标。

然而在护理实践中, 压疮风险评估以及术前护理操作对手术压疮的预防效果评估受到护理人员经验和年资的影响。研究显示, 低年资 (1~5年) 护士对压疮的评分较容易出现偏差^[3], 需要进行一定的针对性培训以提高相应的能力水平,

但即使在培训后仍出现15.28%的压疮预防知识不及格率^[4]。而且目前的手术压疮风险评估一般采用对风险因素进行分段离散化处理^[5], 例如把年龄因素划分为有限个年龄段等, 损失了一定的评估精度。机器学习^[6]能有效地对多维度的离散和连续数据进行学习和预测, 且随着可学习数据的增长, 其预测精度和统一度将随之提高, 有望有效地解决上述手术压疮术前护理难点。因此, 本研究尝试引入机器学习对手术压疮术前护理的效果进行预测, 探索人工智能和机器学习技术在手术压疮护理上的应用。

1 数据与方法

1.1 数据

1.1.1 数据采集 本院于2019年下半年引入手术室护理信息系统。利用该系统的手术压疮风险评估模块, 匿名化采集了474例有效手术数据, 每例数据样本均包括术前压疮风险评估、术前压疮护理措施、手术流程信息以及术后压疮

状况评估。

1.1.2 数据预处理 采集到的数据经过统一格式化及数据归一化预处理, 以满足后续机器学习流程对数据格式的要求并提升机器学习效果。术前压疮风险评估数据按照表1提取相关指标并进行评分, 实施的术前压疮护理措施以及术后压疮状况评估分别按照表2和表3的分类进行标注。这三项评估表格是我院参考多项研究及国际权威标准^[7], 根据本院的实际应用情况而制定的, 并且在手术压疮评估和预防中广泛使用。

1.1.3 数据集划分 采集到的数据样本按7:3的比例随机划分为训练数据和校验及测试数据。校验数据及测试数据由相同的样本组成, 不同点在于, 校验数据中术前评估项目的数据使用术后记录中的后验数据 (例如手术时间评估项以术后记录中的确切手术时间代替), 而测试数据中术前评估项目数据则使用术前评估时记录下的原始数据 (例如手术时间项使用护理人员在手术前

表1 术前压疮风险评估

分值	1分	2分	3分	4分
年龄 (岁)	< 50	50 ~ 64	65 ~ 79	≥ 80
体质指数 (BMI)	18.5 ~ 23.9	17.5 ~ 18.4 24.0 ~ 27.9	16.0 ~ 17.4 28.0 ~ 40.0	< 16.0 > 40.0
受力点皮肤	完好	红斑和 (或) 潮湿	淤斑和 (或) 水疱	破损
手术体位	仰卧或侧卧位	局麻俯卧位	斜坡卧位	全麻俯卧位
预计手术施加的外力	未施加外力作用	存在摩擦力或剪切力	冲击力	同时具有摩擦力、剪切力、冲击力
预计手术时间 (h)	< 3	3 ~ 4	> 4 且 ≤ 5	> 5

特殊手术因素

①全麻俯卧位时, 患者的面部皮肤菲薄、浮肿、瘦削, 加3分;

②控制性降压、低温麻醉, 加3分;

③其他情况 (如休克、水肿、严重创伤) 酌情加1~4分。

表2 术前压疮护理措施

分类	护理措施
减少摩擦力和剪切力	(1) 提式床单移动患者；(2) 床单和衣服干燥、平整、无皱褶；(3) 体位倾斜 $< 20^\circ$ ；(4) 使用过床板
压力减缓用具的使用	(5) 泡沫敷料；(6) 啫喱垫；(7) 棉垫；(8) 软布；(9) 赛肤润；(10) 改良体位垫
皮肤护理	(11) 暖风机保暖；(12) 盖被保暖；(13) 输液加温；(14) 输血加温；(15) 冲洗液加温；(16) 加温水毯；(17) 防止消毒液浸湿消毒区域以外皮肤；(18) 防止医疗器械相关性黏膜压力性损伤；(19) 保护眼角膜；(20) 耳廓、眼眶不受压
体位观察与护理	(21) 安全稳固；(22) 肢体功能位；(23) 良好暴露术野；(24) 肢体无接触金属；(25) 各管道、电极线无受压

表3 术后压疮状况评估

评估项目	评估结果
检查受压皮肤	完好 有红斑 医疗器械性损伤 压之不褪色红斑 (I 期) 有水泡 (II 期)

预估的手术时间作为评估参考)。具体数据划分为：训练数据331例，校验数据143例，测试数据143例。

1.2 方法

1.2.1 神经网络预测模型架构设计

预测模型采用图1所示的多层全连接神经网络架构设计，该种架构设计被广泛应用于非时序性数值数据的处理，与本研究的应用场景切合。输入层包含 $M=7$ 维度的术前压疮风险评估信息及 $N=25$ 维度的术前护理措施信息，分别反映了表1中的7项术前压疮风险评估的分值，以及是否采取表2所述的25项术前护理措施中的某项或某几项。紧接着输入层的SELU隐层^[8]将输入层的两组输入信息汇合并转换为神经网络内部表达形式，其后的两层ELU隐层^[9]增加了该神经网络的记忆能力以及非线性处理能力。原

则上，神经网络隐层的层数和每层的节点数可以是任意的正整数，而且神经网络的记忆能力以及处理能力将随着层数及每层节点数的增加而变强，但是其训练的难度以及对数据量的要求也将随之上升。在设计该预测模型架构的时候，期望选取一组隐层组合，使其复杂度较低、易于训练，但同时有足够的层数和节点数以有效地记忆从相关数据中学习到的规律。经过一系列的先导实验，最终确定出了如图1所示的隐层组合，共计3层隐层，且每层均包含32个节点。最后的输出层为 $K=5$ 维度的Sigmoid层^[10]，输出表3所示的5种术后压疮状况出现的概率预测。

1.2.2 模型训练 模型参数随机初始化后，以交叉熵 (cross-entropy) 作为损失函数，使用Adam优化器^[11]，通过监督学习的方式，在训练数据集上对模型进行100轮的训练。

1.2.3 模型学习效果评估方式 模型的学习效果通过对比训练后的干预组模型与随机初始化的对照组模型在校验数据集上的预测准确率进行评估。有效的模型学习应能显著地

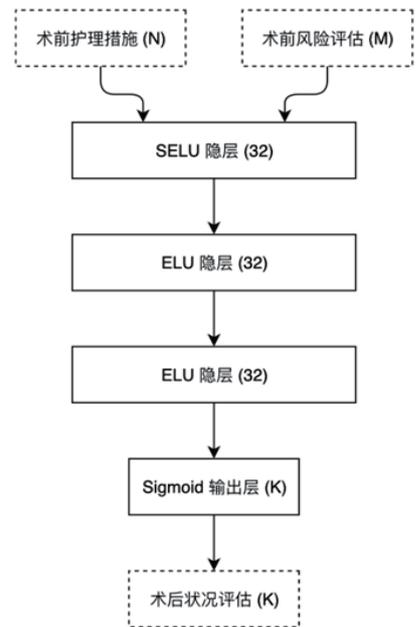


图1 本研究采用的神经网络预测模型架构

提高预测准确率。为了消除模型初始化和训练过程随机性对模型学习效果评估的影响，将对干预组模型和对照组模型分别进行10次随机重复实验。每次实验中，对干预组模型进行随机初始化和训练，对干预组模型进行随机初始化。然后把干预组模型和对照组模型的平均准确率进行对比评估。

1.2.4 模型预测效果评估方式 为了加入术前压疮风险评估时的不确定

性，以贴合实际应用场景，模型预测效果评估将在测试数据集上进行，其余评估流程与本研究所的模型学习效果评估流程相同。在此基础上，还加入了接收者操作特征（receiver operating characteristic, ROC）曲线下面积（area under curve, AUC）评估指标。

2 结果

2.1 模型学习效果评估结果 总结在校验数据集上的10次随机重复实验，相较于对照组模型50.10%±1.21%的平均预测准确率，经过100轮训练后的干预组模型平均预测准确率达到90.03%±0.12%，在统计学意义上表现出了显著的有效学习效果（ $P<0.001$ ）。

2.2 模型预测效果评估结果 总结在测试数据集上的10次随机重复实验，相较于对照组模型49.97%±1.10%的平均预测准确率，经过100轮训练后的干预组模型平均预测准确率达到90.35%±0.14%。同时，干预组模型的平均AUC为75.49%±0.85%，高于对照组模型的49.38%±2.04%。干预组模型和对照组模型的接收者操作特征曲线见图2。干预组模型表现出了显著的预测效果（ $P<0.001$ ）。

3 讨论

3.1 数据样本分布多样性和均匀度 在机器学习中，为了防止预测模型在训练过程中出现过拟合，训练数据样本的多样性和均匀度是十分重要的。然而在真实的医疗护理应用

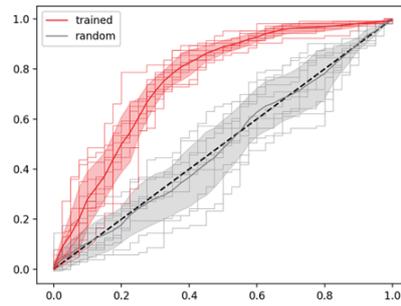


图2 干预组模型（“trained”）和对照组模型（“random”）的接收者操作特征曲线

注：黑色虚线为均匀概率随机响应特征曲线参照，不同颜色较粗的实线为不同模型10次随机实验结果的均值，而阴影部分为对应的标准误差，较细的实线为每次随机实验的原始结果。

场景下，数据样本的获取往往受限于多种条件的制约，而使得样本的分布无法达到理想的均匀和充足的状态^[12]。该问题在本研究的数据收集阶段尤为凸显。手术压疮防治是一项历经多年研究的课题，我院为此制定了多项术前有效的护理预防措施（表2），因此医疗器械性损伤、压之不褪色红斑（I期）及有水泡（II期）等较严重的手术压疮症状相对鲜见，故收集到的数据样本多集中分布于未发生手术压疮（完好）及症状较轻的皮肤出现红斑两种情况。同时，由于在本院接受手术的患者群体中儿童患者相对较少，故数据样本集中分布于成年和老年两个年龄段。为了减轻数据样本分布不均匀所带来的影响，除了尽可能多收集相关数据，并拓展数据获取渠道（如并入公开的数据集及其他医院提供的数据样本），在机器学习领域亦有相关研究提出应对的策略^[13-14]。其中，比较常用

的一种方法是重要性采样^[15]，该方法根据样本分布权重对数据进行重采样以达到均衡数据样本分布的目的。

3.2 术后跟踪观察的改进措施 在手术后72 h内出现的压疮都属于术中获得性压疮，应记入手术压疮相关记录中。但我院在手术压疮方面的术后跟踪观察措施暂未完善，故在我院未来的手术室流程规范建设中，可考虑增加对手术患者术后一段时间内的压疮发生状况进行跟踪观察，以完善流程规范，同时也为手术压疮量化护理和防治提供更优质的数据基础。

3.3 预测模型在术前压疮护理上的应用方式 本研究提出的神经网络预测模型可根据术前压疮风险评估（表1），对可施行的各种术前压疮护理措施组合（表2）进行评估，预测它们对术后发生各种压疮状况（表3）可能性的影响，从而为术前压疮护理提供参考。护理人员可在制定术前压疮预防方案时，使用预测模型对制定的方案进行相关的评估，估测是否需要增加护理措施或者减少不必要的护理措施。更进一步地，可以在确定术前风险评估结论后，对预测模型求出其费希尔信息矩阵（fisher information matrix）或者黑塞矩阵（hessian matrix），量化不同的术前护理措施对术后各种压疮状况发生可能性的影响，进而自动化术前护理措施的选取。

4 结论

本研究探讨了人工智能与机器学习技术在手术压疮术前护理中的

应用, 利用匿名化收集到的474例手术压疮评估记录对提出的神经网络预测模型进行训练, 得到了相较于对照组模型有显著学习效果及预测效果的干预组模型, 可为手术压疮术前护理提供有意义的量化参考。同时, 本研究也讨论了该研究在应用中可能面临的挑战及应对策略, 探讨了其在真实医疗护理场景下的实际应用方式。

参考文献

[1] Lindgren M, Unosson M, Krantz A-M, et al. Pressure ulcer risk factors in patients undergoing surgery[J]. Journal of Advanced Nursing, 2005, 50(6): 605-612.

[2] Shafipour V, Ramezani E, Gorji MAH, et al. Prevalence of postoperative pressure ulcer: A systematic review and meta-analysis[J]. Electronic Physician, 2016, 8(11): 3170.

[3] 刘万芳, 郑姣, 韦珊珊, 等. 压疮评分表在不同年资护士工作中应用的差异性[J]. 中国急救复苏与灾害医学杂志, 2016, 11(2): 189-190.

[4] 肖爱华, 丁力. 压疮护理小组在低年资护士压疮预防能力培训中的作用[J]. 护士进修杂志, 2009, 24(18): 1670-1671.

[5] 魏革, 胡玲, 祝发梅. 手术患者压疮风险因素评估表的设计与应用[J]. 中华护理杂志, 2011, 46(6): 578-580.

[6] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.

[7] Pancorbo-Hidalgo PL, Garcia-Fernandez FP, Lopez-Medina IM, et al. Risk assessment scales for pressure ulcer prevention: a systematic review[J]. Journal of Advanced Nursing, 2006, 54(1): 94-110.

[8] Klambauer G, Unterthiner T, Mayr A, et al. Self-normalizing neural networks[C]// Advances in neural information processing systems, 2017: 971-980.

[9] Clevert D-A, Unterthiner T, Hochreiter S. Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs) [C]// 4th International Conference on Learning Representations (ICLR), 2016.

[10] Han J, Moraga C. The influence of the sigmoid function parameters on the speed of backpropagation learning[C]// International Workshop on Artificial

Neural Networks, 1995: 195-201.

[11] Kingma DP, Ba J. Adam: A method for stochastic optimization[C]// The 3rd International Conference on Learning Representations (ICLR), 2015.

[12] Mac Namee B, Cunningham P, Byrne S, et al. The problem of bias in training data in regression problems in medical decision support[J]. Artificial Intelligence in Medicine, 2002, 24(1): 51-70.

[13] Huang J, Gretton A, Borgwardt K, et al. Correcting sample selection bias by unlabeled data[C]// Advances in neural information processing systems, 2007: 601-608.

[14] Cortes C, Mohri M, Riley M, et al. Sample selection bias correction theory[C]// International conference on algorithmic learning theory, 2008: 38-53.

[15] Geweke J. Bayesian inference in econometric models using Monte Carlo integration[J]. Econometrica: Journal of the Econometric Society, 1989: 1317-1339.

【收稿日期: 2020-06-29】

【修回日期: 2020-12-17】

(责任编辑: 郑艳)

《中国医疗人工智能发展报告(2020)》蓝皮书正式出版

《中国医疗人工智能发展报告(2020)》蓝皮书日前由社会科学文献出版社正式出版发行。本书由国家卫生健康委医院管理研究所、《中国数字医学》杂志社联合国内知名科研院所及三甲医院共同编写而成。全书共七章, 48万字。

本书从“我国医疗人工智能产品分类与发展”总报告入手, 内容涉及国际篇、政策法规篇、应用篇、学科技术篇及产业篇等。其中“国际篇”详细介绍了美国、欧盟地区医疗人工智能研究和应用现状; “政策法规篇”主要对我国医疗人工智能准入管理政策、相关法律研究以及医学伦理等内容进行了深入的剖析; “应用篇”除介绍了医疗人工智能在临床决策支持、语音识别、肺结节诊断中的典型应用外, 还针对精神心理学领域以及慢性病管理方面的应用进行了深入的探讨与分析; “学科技术篇”重点讨论了医学人工智能科技投入产出模型的建立、前沿技术发展研究以及人工智能在生命科学领域的前沿热点; “产业篇”主要从医疗人工智能企业融资、研发投入、产品情况、产业发展困难与期望等方面, 对我国医疗人工智能产业发展现状进行了分析, 也对未来发展提出了政策建议。



官方公众号



微信小店

手机扫一扫, 订阅更方便

