

基于单层感知机预测模型的眼科患者慢性疾病风险评估*

——以糖尿病、高血压为例

林中燕¹ 朱岩² 张永泽³ 罗烈¹ 叶晓燕⁴ 曾华科^{5△}

【摘要】目的 对眼科疾病患者中糖尿病、高血压相关疾病特征开展研究。**方法** 选取某医院眼科疾病患者诊疗数据,运用单层感知机(single-layer perceptron, SLP)对数据进行线性拟合,揭示患者生理指标与特定疾病类型之间的潜在关联。**结果** 眼科患者诊疗数据中白蛋白水平、红细胞数量与糖尿病、高血压预测体现强相关,男性眼科疾病患者同时患有高血压、糖尿病的可能性高于女性。血红蛋白值、白蛋白、总胆固醇和甘油三酯等指标在预测糖尿病、高血压等慢性疾病的作用有限。**结论** 眼科患者生理指标与特定疾病之间存在关联,单层感知机能够有效提取疾病特征,提高诊疗结果准确性和预测效率。

【关键词】 眼科疾病 糖尿病 高血压 单层感知机

【中图分类号】 R195.1

【文献标识码】 A

DOI 10.11783/j.issn.1002-3674.2024.06.017

信息技术的快速发展,文本、图像、数值等组成的电子病历(electronic medical record, EMR)记录了患者的诊疗信息,成为极为宝贵的医疗数据资源,这些资源对于提升医疗服务质量、优化资源配置及开展科研活动具有重要意义。同时,深度学习和自然语言处理技术被广泛应用于电子病历数据的挖掘与分析中,单层感知机(single-layer perceptron, SLP)通过特征相关性分析,可识别和筛选出电子病历数据中的冗余维度或不相关维度,用较少的属性特征代替整体数据集,在保留电子病历数据原始特征的同时,解决数据维度过高的问题,有效提取出对诊断和治疗最有用的特征,从而提高分析的准确性和效率^[1]。

研究回顾

1. 眼科疾病与糖尿病、高血压的相关研究

已有研究关注糖尿病视网膜病变与高血压的关系,高血糖水平会导致视网膜血管病变,尤其在合并高血压的情况下,视网膜病变的风险显著增加,这一特征强调了早期筛查和干预的重要性,以减少视网膜损伤和视力丧失^[2]。在高血压对眼部健康的影响方面,包括视网膜出血、视网膜病变及其长期影响等,高血压会导致视网膜微血管的损伤,可能导致视力减退或失明,由此需要监测和控制血压,预防眼部并发症^[3]。在糖尿病和高血压对眼科疾病的共同影响方面,特别是存在视网膜病变的风险。控制血糖和血压可以有效降低

视网膜病变的发生率,对糖尿病患者尤为重要^[4]。此外,关于慢性疾病(包括糖尿病和高血压)对视力损害的影响,研究发现,未矫正的屈光不正和白内障是最常见的视力问题,而慢性疾病的存在则可能加重这些眼病并导致更高的视觉损害风险^[5]。同时,多种系统性疾病(如糖尿病和高血压)与视网膜病变之间存在关联,系统性疾病通过引起血管变化影响视网膜健康,建议在糖尿病及高血压患者中定期进行眼科检查,开展早期识别,干预潜在问题^[6]。

2. 单层感知机在医学领域的应用研究

单层感知机主要应用在医学图像分析、生理信号监测、特征分类、疾病风险评估等领域,已有研究利用 SLP 模型进行患者的临床特征和治疗反应预测,在预测准确性和可靠性方面表现良好^[7]。如在癌症和糖尿病的早期诊断中,利用了 SLP 模型对患者数据进行训练,表明该模型在分类精度上表现良好,适用于数据集较小的情境^[8];通过特征提取和 SLP 进行的分类能够有效识别病变区域,可为放射科医生提供辅助诊断^[9];利用 SLP 对心血管疾病风险的评估,结果表明 SLP 能够有效区分高风险与低风险患者^[10],同时能够准确识别心脏异常模式,有助于早期筛查心脏疾病^[11],为临床决策和疾病预测提供支持。

单层感知机结构及算法

单层感知机是一种由多个感知机构成的单层结构,其仅有输入层和输出层,由于单层感知机可以对数据进行线性拟合,因此可以使用其对数据进行学习并获取其输出的权重。

单层感知机的输入为一个训练样本的特征向量,本研究中特征向量包含患者的常规信息、血常规以及生化指标,输出为三种诊断名称的可能性概率。单层感知机整体结构如图 1 所示。

* 基金项目:福建省卫生健康重大科研专项(2021ZD01004);福建省科技计划对外合作产业化项目(闽科资(2022)17号);福建省自然科学基金项目(闽科资(2020)29号)

1. 闽江学院国际数字经济学院(350102)

2. 国家卫生健康委统计信息中心

3. 福建医科大学附属第一医院

4. 福州康为网络技术有限公司

5. 福建医科大学省立临床医学院

△通信作者:曾华科, E-mail: zenghuake@163.com

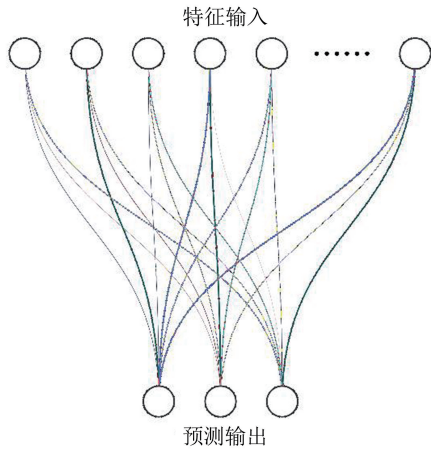


图1 SLP 结构示意图

对于输入数据的特征,单层感知机将其与对应学习到的权重相乘,最终输出对应病种的可能性。如图2所示,对于第*i*个病种的诊断概率 z_i ,单层感知机首先获取一个样本的全部特征 $x_i = x_i^1, x_i^2, \dots, x_i^j$,将其与单层感知机内保存的权重 $w_i = w_i^1, w_i^2, \dots, w_i^j$ 进行运算,得到对应概率 $z_i = \sum_{j=1}^n w_i^j x_i^j$ 。为加强网络对不同病种的区分程度,对所有的输出概率使用 softmax 函数进行处理,函数表达式如公式(1)所示。

$$\text{Softmax}(x_i) = \frac{e^{x_i}}{\sum_{i=1}^n e^{x_i}} \in (0, 1) \quad (1)$$

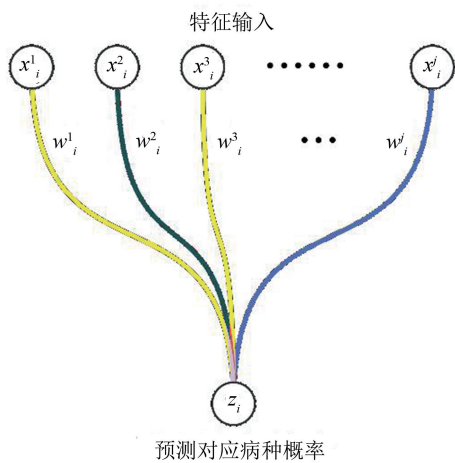


图2 SLP 预测单个病种原理

此外,为更好地使得单层感知机中的权重可以直接反应输入特征的重要性,首先对所有的数据进行标准化,并使得标准化后的最小值不小于0。对于每一个输入数据 x ,样本数量 n ,特征均值 μ ,样本最小值 x_{min} ,标准化后的数据 \hat{x} 计算方法如式(2)所示:

$$\hat{x} = \frac{x - x_{min}}{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2}} \quad (2)$$

单层感知机拟合病例数据过程如下所示:

输入:对于全部患者数量 n ,有训练样本 $X = x_1, x_2, \dots, x_n$,对应样本标签 $Y = y_1, y_2, \dots, y_n$ 。对于每一个训练样本 x_i 有 j 个特征值 $x_i = x_i^1, x_i^2, \dots, x_i^j$,学习率 η ,训练次数 $epoch$,批次大小 b 。

输出:最优权重向量 $W = w_1, w_2, \dots, w_j$

- ①随机初始化权重矩阵 W
- ②FOR i IN $epoch$:
- ③随机选择一组批次大小为 b 的训练样本 x_i, y_i
- ④计算输入加权和获取输出值 $z_i = \sum_{j=1}^j w_j^i x_i^j + b$
- ⑤应用激活函数 $\hat{z}_i = \frac{e^{z_i}}{\sum_i e^{z_i}}$
- ⑥计算误差 $\delta_i = y_i - \hat{z}_i$
- ⑦更新权重以及偏置 $w_j \leftarrow w_j + \eta \delta_i x_i^j$
- ⑧END FOR
- ⑨return 权重矩阵 W

统计结果与数理分析

1. 基础信息

数据集来源于福建某医院眼科手术室所收集到的眼科疾病患者数据(共12880条),从中选取诊断名称为2型糖尿病、高血压以及其他糖尿病(广义)的三类人群490个样本,其中,2型糖尿病患者数为226人,高血压患者数为157人,其他糖尿病患者数为107人。患者人群信息分为常规信息、血常规和生化指标三个部分,具体选取信息为:年龄、性别、入院情况、红细胞数量、平均红细胞血红蛋白含量、白蛋白、总胆固醇、甘油三酯。总性别比值中,男性样本均比女性样本多,但在2型糖尿病患者中,男女比例较为接近,约为1:1,在其他糖尿病(广义)患者中,男性比女性多出60.9%,如图3所示。




图3 各疾病组不同性别患者患病人数比较

数据集体现与眼科疾病相关的患病率在45~60岁之间逐步上升,60~70岁达到高发段,同时慢性疾病

年轻化的趋势需要重视(图 4)。




图 4 各疾病患病人数分布

2. 单层感知机训练过程

为更好地梳理眼科疾病相关指标与糖尿病、高血压等疾病的关系,本研究使用单层感知机模型,Python 为编程语言,Pycharm 为集成开发环境,Pytorch 为深度学习框架。损失函数为交叉熵损失,优化器为 Adam,学习率为 10^{-3} ,训练轮数为 25 epoch。数据测试过程中采用测试集与训练集,损失函数如图 5,在训练过程中训练和测试损失先快速下降,之后测试损失略有波动。

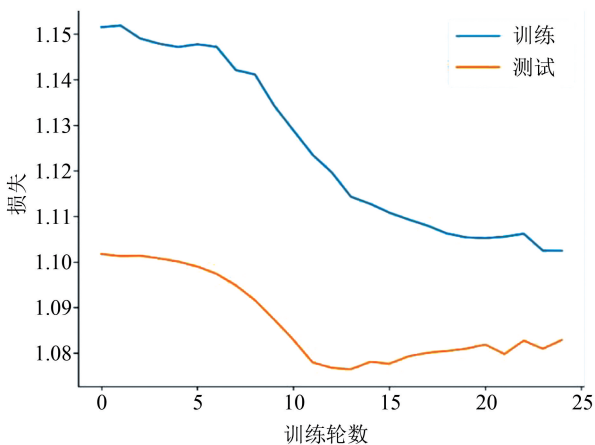


图 5 SLP 训练过程

为检验该模型权重的可靠性,使用数据集获取该单层感知机的混淆矩阵,结果如图 6 所示。单层感知机的召回率、精确率、F1 分数计算如公式(3)至(5)所示,其中 TP 表示预测正确的正样本, FN 表示错误预测的负样本, FP 表示错误预测的正样本。

$$\text{召回率} = \frac{TP}{TP+FN} \quad (3)$$

$$\text{精确率} = \frac{TP}{TP+FP} \quad (4)$$

$$F1 \text{ 分数} = 2 \times \frac{\text{精确率} \times \text{召回率}}{\text{精确率} + \text{召回率}} \quad (5)$$




图 6 SLP 混淆矩阵

单层感知机对各疾病判别效果如表 1 所示,单层感知机可以一定程度上有效分类三种疾病,其中该模型可以召回过半数的 2 型糖尿病样本,且对糖尿病的诊断精度接近 60%,尽管可能有更高精度的模型,如多层感知机、Transformer 等,但模型太过于复杂,无法解释患者生理特征与患病之间的联系,而单层感知机能够分离出相关性,在本研究中为最优解,也验证了已有文献中提到“该模型在分类精度上表现良好,适用于数据集较小的情境”^[8]。

表 1 单层感知机对各疾病判别效果 (%)

| 诊断名称 | 召回率 | 精确率 | F1 值 |
|-----------|-------|-------|-------|
| 2 型糖尿病 | 57.69 | 42.86 | 49.26 |
| 高血压 | 45.45 | 46.88 | 46.16 |
| 其他糖尿病(广义) | 45.95 | 58.62 | 51.51 |

结论与展望

本研究通过单层感知机模型对眼科患者数据进行分析,揭示了患者生理指标与特定疾病类型[2 型糖尿病、高血压及其他糖尿病(广义)]之间的潜在关联,为临床辅助诊断预测提供了有价值的参考。

年龄和血液中白蛋白水平是预测 2 型糖尿病的重要正向指标,即随着年龄增长和血液中白蛋白含量的增加,患者罹患 2 型糖尿病的风险增加。而甘油三酯和血红蛋白值则表现为负向关联,即这些指标的升高可能降低患者被诊断为 2 型糖尿病的概率。性别和红细胞数量对 2 型糖尿病的预测作用不显著,表明这些因素在该疾病的发生中可能不是主要影响因素。与预期相反,研究发现总胆固醇和甘油三酯的升高以及年龄的增长,实际上降低了患者被诊断为高血压的可能性。这可能与样本选择、数据偏差或高血压发病机制的复杂性有关,需进一步深入研究。同时,红细胞和白蛋白的增多则与高血压呈正相关,提示这些指标可能

是高血压风险增加的标志。此外,男性患者相比女性更可能患有高血压,这与既往研究中的性别差异观察相一致。在其他糖尿病(广义)人群中,男性患者患糖尿病的风险明显高于女性,红细胞数量的增加也被认为是糖尿病的一个风险因素,但血红蛋白值、白蛋白、总胆固醇和甘油三酯等指标在预测糖尿病方面的作用有限,表明糖尿病的发病机制可能更为复杂,涉及多种因素的相互作用。

本研究基于有限数据集进行,尽管揭示了眼科患者生理指标与特定疾病之间的初步关联,未来研究应纳入更多样本,涵盖不同地域、种族及年龄层的患者,以提高研究结果的普适性和准确性。其次,在技术方面应引入多因素综合分析,采用更复杂的机器学习模型,如深度学习、随机森林等,结合更多的临床信息(如家族史、生活方式等),进行多因素综合分析,以更全面地理解疾病的发生机制。第三,应加强眼科与内分泌科、心血管科等学科的交叉合作,共同探索眼科症状与全身性疾病之间的内在联系,促进医学领域的综合发展,同时重视患者的个体差异,开展个性化医疗研究,为不同患者制定更加精准的治疗方案,提高治疗效果和生活质量。

参 考 文 献

[1] 牟冬梅,王萍,赵丹宁.高维电子病历的数据降维策略与实证研究[J].数据分析与知识发现,2018,2(1):88-98.
 [2] Al-Khawaldeh OA, Al-Hassan MA, Froelicher ES. Self-efficacy, self-management, and glycemic control in adults with type 2 diabetes

mellitus[J]. J Diabetes Complications, 2012, 26(1):10-16.
 [3] Cheung CY, Ikram MK, Sabanayagam C, et al. Retinal microvasculature as a model to study the manifestations of hypertension [J]. Hypertension, 2012, 60(5):1094-1103.
 [4] Lövestam-Adrian M, Agardh CD, Torffvit O, et al. Diabetic retinopathy, visual acuity, and medical risk indicators; a continuous 10-year follow-up study in Type 1 diabetic patients under routine care [J]. J Diabetes Complications, 2001, 15(6):287-294.
 [5] Naidoo KS, Leasher J, Bourne RR, et al. Global vision impairment and blindness due to uncorrected refractive error, 1990—2010 [J]. Optom Vis Sci, 2016, 93(3):227-234.
 [6] Frank RN. Diabetic retinopathy and systemic factors[J]. Middle East Afr J Ophthalmol, 2015, 22(2):151-156.
 [7] Lopes de Faria JM, Russ H, Costa VP, Retinal nerve fibre layer loss in patients with type 1 diabetes mellitus without retinopathy [J]. Br J Ophthalmol, 2002, 86(7):725-728.
 [8] Shen D, Wu G, Suk HI. Deep Learning in Medical Image Analysis [J]. Annu Rev Biomed Eng, 2017, 19:221-248.
 [9] Celermajer DS, Chow CK, Marijon E, et al. Cardiovascular disease in the developing world: prevalences, patterns, and the potential of early disease detection [J]. J Am Coll Cardiol, 2012, 60(14):1207-1216.
 [10] Voss R, Cullen P, Schulte H, et al. Prediction of risk of coronary events in middle-aged men in the Prospective Cardiovascular Münster Study (PROCAM) using neural networks [J]. Int J Epidemiol, 2002, 31(6):1253-1262.
 [11] Chang C, Shi W, Wang Y, et al. The path from task-specific to general purpose artificial intelligence for medical diagnostics: A bibliometric analysis [J]. Comput Biol Med, 2024, 172:108258.

(责任编辑:林美艺)

(上接第 888 页)

[8] Liu S, Liu S, Cai W, et al. Fulham, Multimodal neuroimaging feature learning for multi-class diagnosis of Alzheimers disease [J]. IEEE Trans Biomed Eng, 2015, 62(4):1132-1140.
 [9] Suk HI, Lee SW, Shen D. Latent feature representation with stacked auto-encoder for AD/MCI diagnosis [J]. Brain Structure and Function, 2015, 220(2):841-859.
 [10] Ju R, Hu C, Zhou P, et al. Early diagnosis of Alzheimer's disease based on resting-state brain networks and deep learning [J]. IEEE/ACM Trans Comput Biol Bioinform, 2019, 16(1):244-257.
 [11] Jin D, Xu J, Zhao K, et al. Attention-based 3D convolutional network for Alzheimer's disease diagnosis and biomarkers exploration

[C]. 2019 IEEE 16th International Symposium on Biomedical Imaging, 2019: 1047-1051.
 [12] Jack CR, Bernstein MA, Fox NC, et al. The Alzheimer's Disease Neuroimaging Initiative (ADNI): MRI methods [J]. Journal of Magnetic Resonance Imaging, 2008, 27(4):685-691.
 [13] He K, Zhang X, Ren S, et al. Identity Mappings in Deep Residual Networks [EB/OL]. (2016-07-25) [2023-02-19]. https://arxiv.org/pdf/1603.05027.
 [14] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision [C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2016:2818-2826.

(责任编辑:张悦)