

预测儿童和青少年高血压：使用机器学习分析预测因素

Hengyan Liu, MSc¹, Weibin Kou, BEng²,
Yik-Chung Wu, PhD², Pui Hing Chau,
PhD¹, Thomas Wai Hung Chung, MHA³,
Daniel Yee Tak Fong, PhD¹

¹School of Nursing, The University of Hong Kong, Hong Kong, PR China; ²Department of Electrical and Electronic Engineering, The University of Hong Kong, Hong Kong, PR China; and ³Family and Student Health Branch, Department of Health, Hong Kong, PR China

Address correspondence to: Daniel Yee Tak Fong, PhD, School of Nursing, The University of Hong Kong, 3 Sassoon Rd, Pokfulam, Hong Kong, PR China. dytfong@hku.hk, 852-39176645

缩略语

AUROC: 受试者工作特征曲线下面积

k-NN: k 近邻算法

ML: 机器学习

MLR: 多元逻辑回归

RF: 随机森林

SEI: 60 项与文化无关的自尊相关评估量表第二版

SES: 社会经济地位

SHAP: Shapley 加性解释

SHS: 学生健康服务

SMOTE: 合成少数类过采样技术

XGBoost: 极端梯度提升

摘 要

背景 儿童和青少年高血压问题日益凸显，给社会和经济带来了沉重负担。因此，早期识别可能导致儿童和青少年发生高血压的危险因素，显得极为关键。本研究尝试并验证了多种机器学习 (machine learning, ML) 算法，以准确预测儿童 1 年和 3 年后的血压状态 (包括正常血压、高血压前期和高血压)，同时在不影响模型性能的情况下识别重要预测因素。

方法 本研究纳入了中国香港 1995-1996 学年至 2019-2020 学年小学一年级至中学六年级的学生 (约 6 至 18 岁) 作为人群队列基础。共有 36 个易于评估的预测因素被用于预测儿童血压的初步建模，涉及的 ML 算法包括决策树、随机森林、k 邻近算法、极端梯度提升和多元逻辑回归等。模型的精准度评估使用了多个相关评价指标。此外，Shapley 加性解释 (Shapley Additive exPlanations, SHAP) 被用于识别预测结果中的关键性特征。

结果 本研究中 1 年和 3 年血压数据组分别纳入了 923 301 对和 602 179 对血压数据。在各 ML 运算中，XGBoost 预测准确度最高，在 1 年组中宏观受试者工作特征曲线下面积 (area under the receiver operating characteristic curve, AUROC) 达 0.92，微观 AUROC 达 0.91，3 年组则分别为 0.91 及 0.90。传统的多元逻辑回归法 1 年组宏观 AUROC 为 0.70，微观 AUROC 为 0.68，3 年组分别为 0.70 及 0.68，预测准确性最低。SHAP 共识别了 17 个关键预测因素，这些因素均不涉及血压测量或实验室检测。

结论 ML 预测模型无需借助血压测值或实验室检查即可较准确地预测 1 年和 3 年后儿童高血压前期和高血压状态。本研究识别出的多个关键预测因素可为高血压个体化预防提供参考依据。

引 言

高血压和高血压前期是当前威胁儿童健康的重要问题之一^[1-3]。令人担忧的是，即使儿童血压处于

正常范围，仍可能面临远期高血压并发症的风险，加重家庭及社会的经济负担^[3-9]。据相关研究统计，儿童高血压和高血压前期的综合患病率分别约为 4% 和 10%^[10,11]。值得庆幸的是，通过早期干预高血压风

险因素，例如增加体育活动、养成健康的饮食习惯等，能够有效降低血压水平，改善长期临床预后，并显著提升儿童的生活质量^[12-14]。特别是对于那些存在风险因素的高危儿童，初级预防的效果可能更为显著^[13,15,16]。因此，早期识别高危因素，并实施针对性的生活方式干预以及其他预防策略，对于有效预防高血压的发生与发展至关重要。

早期预防对于儿童的健康意义重大，但在儿科领域，目前仍缺乏专门用于预测高血压的模型^[17,18]。现有的相关研究大多集中于横断面研究，其预测效果往往不尽如人意^[19,20]。也有部分研究尝试使用人体测量学指标、生化指标或基因检测等作为预测指标，其预测准确性相对较高，但样本量普遍较小^[21-23]。另一方面，针对儿童高血压时间维度的预测研究极为稀缺，且现有的少数研究大多严重依赖于血压测量和实验室指标^[24,25]，然而在肥胖儿童群体中，获取这些指标往往较为困难^[25,26]。此外，医疗服务人员、医疗机构以及家长对于每年进行血压筛查重要性的认识还远远不足^[16,27,28]。鉴于上述情况，本研究特别纳入了中国香港的儿童和青少年人群队列，创新性地运用机器学习 (machine learning, ML) 技术，分别对 1 年和 3 年后的正常血压、高血压前期以及高血压情况进行精准预测。本研究的核心目标是提供一个用户友好、不依赖于血压测量和实验室检测指标的风险预测工具，帮助早期识别高危儿童，为预防策略的制定提供有力指导，增强家长对儿童血压健康问题的意识，并辅助临床专业人员更科学地制定预防措施决策。

方 法

研究设计

本项回顾性队列研究基于大样本人群，用于研究儿童高血压前期和高血压情况。

研究对象

研究纳入了中国香港 1995-1996 学年至 2019-2020 学年小学一年级 (P1; 相当于美国一年级; 通常为 6 岁) 至中学六年级 (S6; 相当于美国十二年级; 通常为 18 岁)、且至少有两次间隔 1 年或 3 年血压测量记录的学生。数据来源为 1995-1996 学年起，由香港卫生署学生健康服务处 (the Student Health Service, SHS) 发起的地区年度健康评估项目。项目详情可通过公共资源获取^[29,30]。

血压测量及结果分类

学生分别在小学五年级 (P5)、中学一年级 (S1)、中学三年级 (S3) 和中学五年级 (S5; 分别相当于美国的三、五、九和十一年级) 进行血压测量，频次为每两年一次。具体测量操作为：学生休息 10 分钟后，由经培训的护士根据年龄和体型使用合适的袖带在右臂进行血压测量。血压计为自动示波形血压计。当收缩压或舒张压超过对应性别、年龄、身高的第 90 百分位数，需重新测量血压。异常血压的判定参照 2017 年美国儿科学会高血压指南：收缩压或舒张压处于第 90 至 95 百分位数之间为高血压前期，达到或超过第 95 百分位数为高血压^[26]。

潜在预测因素

基于前期的文献调查，本研究从 SHS 数据库中共提取了 36 个潜在预测因素，涵盖人口统计学、身体和心理健康因素等方面的相关指标。其中人口统计学指标包括年龄、性别、学生住房类型、父母教育程度及职业。身体测量指标为体重与身高，每年评估一次。此外，P4 至 S6 年级的学生还参与了涉及社会、经济、自尊等因素的问卷调查以评估身体和心理健康。问卷包括 60 项与文化无关的自尊相关评估量表第二版 (60-item Culture-Free Self-Esteem Inventories- Second Edition, SEI)、112 项 Achenbach 青少年自评问卷 (112-item Achenbach's Youth Self-Report questionnaire) 和 4 项 Rutter 行为问卷 (4-item Rutter Behavior Questionnaire)，频次为每两年一次。详见补充信息“潜在预测因素收集”。

预测模型开发

数据准备

血压数据集分为1年和3年两个子集：1年数据集包含学生在P5、S1、S3和S5时间点的血压测量记录及对应的前1年数据；3年数据集则包含相同时间点记录及对应的3年前数据。针对训练集和测试集中的缺失数据，采用k-近邻算法(k-nearest neighbors, k-NN)进行填补，该算法处理随机缺失数据的计算效率和适用性较高^[31,32]。具体数据及算法流程详见补充信息“数据准备”。为进一步优化数据质量，运用相关性矩阵分析(阈值>0.95)清除冗余信息(被识别并清除的冗余数据见补充图1)，并应用合成少数类过采样技术(synthetic minority oversampling technique, SMOTE)解决各血压数据类别下人数不平衡的问题。SMOTE技术通过生成拟合样本来增强少数类代表性，有效降低了样本不均衡问题对预测性能的负面影响^[33]。

模型开发和评价

本研究将1年和3年数据集以80:20的比例随机分为训练集和测试集^[34]。在训练集中，首先运用决策树(decision tree)^[35]、随机森林(random forest, RF)^[36]、k-NN^[37]和极端梯度提升树(eXtreme Gradient Boosting, XGBoost)^[38]和传统的多元逻辑回归(multinomial logistic regression, MLR)等算法，开发了4个多级ML预测模型。随后，纳入整体准确性、微观和宏观受试者工作特征曲线下面积(area under the receiver operating characteristic curve, AUROC)、精确度、召回率和F1分数等精准度标准评估参数，来进一步评价及提高测试集的预测精确度。其中，精确度即阳性预测值，用于衡量模型在所有阳性预测中真阳性结果比例。召回率即灵敏度，用于衡量模型在所有实际阳性案例中真阳性比例。F1分数为精确度与召回率的调和平均值。为减少随机抽样的影响，数据集随机分配过程重复9次，共获得10组准确性指标，其平均值结果用于模型性能的比较分析。

特征降维

特征降维目的是筛选最小预测变量集，并确保预测准确性不受影响。具体步骤为：通过计算Shapley加性解释值(Shapley Additive Explanations, SHAP)量化各预测因素对预测模型的贡献，并据此对各因素进行重要性排序。此过程在10个随机抽样的训练集中重复运行以提高模型的稳健性^[39]。随后，将各因素依次添加，逐步纳入预测模型，最终构建了36个不同的模型组合。SHAP值在这一过程中的作用类似于线性回归模型中的回归系数，用于评估非线性模型中各特征的贡献度。若新增因素未能显著提升模型预测准确性，则停止筛选，当前因素组合即为最优集合。该流程分别应用于1年与3年数据集，具体方法见补充信息“特征降维”。

所有统计分析和模型开发均使用Python软件(V3.10)完成。

伦理审批

本研究遵循赫尔辛基宣言中规定的指南和法规进行，研究方案已获得香港大学/香港西区医院管理局机构审查委员会(参考编号UW19-796)和卫生署伦理委员会(参考编号L/M 44/2021)批准。所有参与者的父母和监护人每年均签署书面知情同意书，包括同意参与年度SHS健康评估，并同意将数据纳入研究。

结 果

参与者特征

1995-1996学年至2019-2020学年期间，SHS项目共纳入1 129 984名学生，累计参与7 516 730人次(分布情况见图1)。P5、S1、S3和S5各阶段共收集1 910 772条血压数据。经剔除问卷不一致及数据缺失记录后，1年与3年血压预测数据集分别包含923 301对和602 179对有效血压记录，每对记录中的前次测量值用于预测后次血压值。

1年数据集中，首次测量被诊断为高血压前期

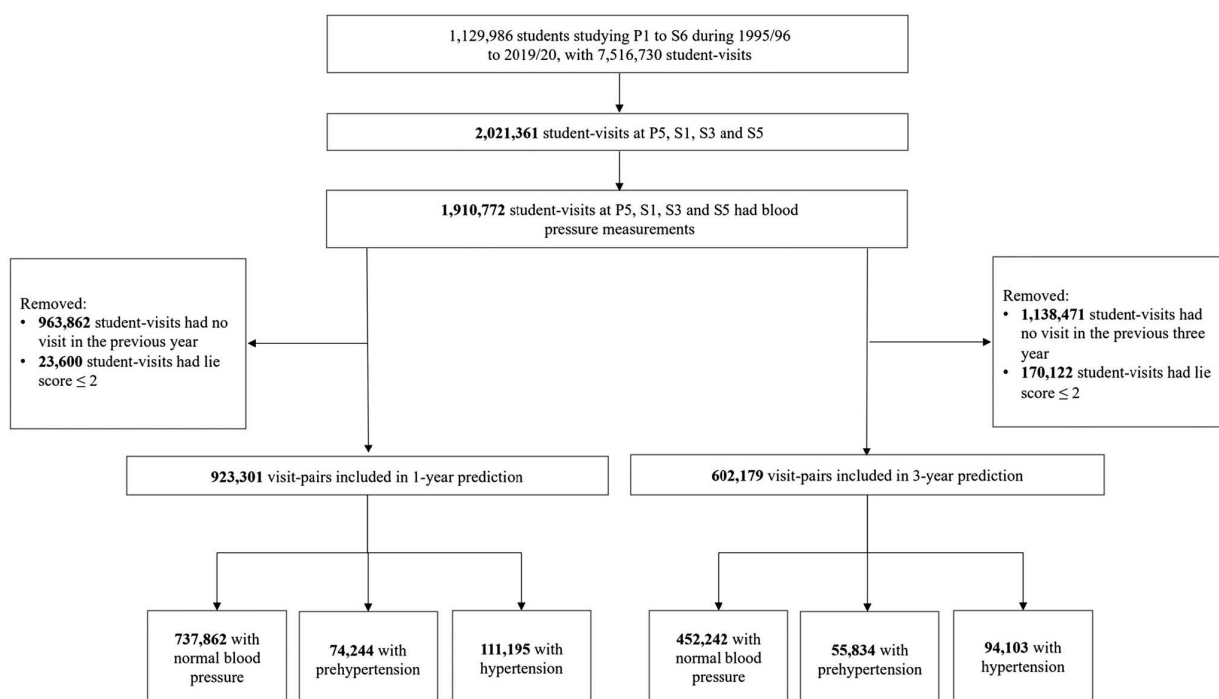


图 1 数据分布

和高血压的学生分别为 74 244 名 (8.0%) 和 111 195 名 (12.0%); 3 年数据集中相应为 55 834 名 (9.3%) 和 94 103 名 (15.6%)。参与者详细信息见表 1。性别分布显示女生比例略高 (1 年数据集 51.5%, 3 年数据集 52.4%)。1 年和 3 年数据集平均年龄分别为 11.8 岁 (标准差 = 2.01) 和 11.0 岁 (标准差 = 1.68)。正常、高血压前期与高血压三类血压状态间存在显著特征差异 (详见补充表 1)。

模型性能

表 2 比较了各 ML 模型的预测性能, 结果显示 XGBoost 和 RF 在宏观平均 AUROC 指标上显著优于其他方法。在 1 年预测数据集中, XGBoost 和 RF 的宏观 AUROC 分别达到 0.92 和 0.91; 在 3 年预测数据集中分别为 0.91 和 0.90。相比之下, 其他 ML 方法及 MLR 的宏观 AUROC 在 1 年和 3 年数据集中均为 0.70。

XGBoost 在 1 年血压预测中的准确率为 0.85, 在 3 年预测中为 0.83; RF 在 1 年和 3 年预测中的准确率分别为 0.78 和 0.76。值得注意的是, XGBoost 对异常

血压状态的预测表现尤为突出: 在 1 年数据集中, 其对高血压前期的平均预测精确度为 0.89 (标准差 = 0.001), 高血压为 0.87 (标准差 = 0.001); 在 3 年数据集中, 平均精准度分别为 0.87 (标准差 = 0.002) 和 0.83 (标准差 = 0.001)。

重要预测因子的识别

图 2 展示了基于 XGBoost 和 RF 模型的各预测因素重要性排序, 其重要性通过平均绝对 SHAP 值量化。在每种预测方法的前 15 个预测因素中, 有 11 个表现出高度一致性, 包括性别、体重、身高、年龄、牛奶进食习惯、甜食偏好、有氧运动的频率和时长、与父母相关的自尊因素、垃圾食品摄入习惯以及水果和蔬菜摄入。

图 3 呈现了模型整体预测性能随纳入预测因素数量增加的变化趋势。在 1 年数据集中, XGBoost 和 RF 模型共识别出 13 个最优预测因素; 3 年数据中共筛选出 15 个预测因素。补充图 2 显示了简化模型在测试集中的预测性能表现。结果显示, XGBoost 模型

表 1 预测数据集中儿童和青少年的特征

特征	1 年预测数据集 N1 = 923 301	3 年预测数据集 N2 = 602 179	特征	1 年预测数据集 N1 = 923 301	3 年预测数据集 N2 = 602 179
性别, n (%)			YSR 分数, 均值 (标准差)		
男性	447 778 (48.5)	286 420 (47.6)	总分	27.5 (17.97)	26.4 (17.21)
女性	475 523 (51.5)	315 759 (52.4)	不能配合完成	3.1 (2.01)	2.9 (1.85)
年龄, 均值 (标准差), 岁	11.8 (2.01)	11.0 (1.68)	躯体不适	2.6 (1.91)	2.5 (1.85)
体重, 均值 (标准差), 千克	46.4 (12.08)	42.6 (11.71)	焦虑 / 抑郁	5.0 (4.10)	4.6 (3.86)
身高, 均值 (标准差), 厘米	152.4 (11.64)	148.4 (11.70)	社交问题	3.1 (2.00)	3.1 (1.94)
早餐习惯 (“old_A1”), n (%)			思维问题	2.1 (1.52)	2.1 (1.51)
数据缺失	26 145 (2.8)	25 239 (4.2)	注意力问题	4.4 (2.80)	4.2 (2.62)
在家吃早餐	754 244 (81.7)	494 579 (82.1)	违纪行为	2.3 (1.50)	2.3 (1.45)
很少在家吃	82 788 (9.0)	47 996 (8.0)	攻击行为	6.2 (4.32)	6.1 (4.25)
不吃早餐	60 124 (6.5)	34 365 (5.7)	RBQ 分数, 均值 (标准差)		
甜食偏好程度 (“old_A2”), n (%)			总分	8.8 (5.93)	9.0 (5.59)
数据缺失	282 875 (30.6)	161 383 (26.8)	行为	1.9 (1.20)	1.9 (1.07)
非常喜欢	191 470 (20.7)	133 222 (22.1)	情绪	2.0 (1.16)	2.0 (1.01)
一般	390 581 (42.3)	267 026 (44.3)	多动	2.4 (1.36)	2.5 (1.18)
偶尔尝试	39 984 (4.3)	27 673 (4.6)	父亲教育水平		
不喜欢	18 391 (2.0)	12 875 (2.1)	数据缺失	39 324 (4.3)	24 230 (4.0)
垃圾食品摄入习惯 (“old_A3”), n (%)			未受教育	6 831 (0.7)	4 133 (0.7)
数据缺失	283 073 (30.7)	161 518 (26.8)	幼儿园	1 186 (0.1)	735 (0.1)
每天均有摄入	32 708 (3.5)	22 065 (3.7)	小学	159 247 (17.2)	101 361 (16.8)
偶尔摄入	396 103 (42.9)	270 601 (44.9)	初中	199 779 (21.6)	129 223 (21.5)
很少摄入	202 348 (21.9)	141 615 (23.5)	高中	354 123 (38.4)	233 475 (38.8)
从不	9 069 (1.0)	6 380 (1.1)	预科	36 207 (3.9)	24 181 (4.0)
水果和蔬菜摄入 (“old_A4”), n (%)			非学位课程	36 482 (4.0)	24 572 (4.1)
数据缺失	283 236 (30.7)	161 652 (26.8)	学位课程	90 122 (9.8)	60 278 (10.0)
每天至少三次	147 859 (16.0)	104 198 (17.3)	母亲教育水平		
每天一次或两次	333 211 (36.1)	231 046 (38.4)	数据缺失	19 292 (2.1)	11 950 (2.0)
数天一次	123 879 (13.4)	81 628 (13.6)	未受教育	11 673 (1.3)	7 204 (1.2)
每周少于一次	35 116 (3.8)	23 655 (3.9)	幼儿园	1 322 (0.1)	823 (0.1)
牛奶进食习惯 (“old_A5”), n (%)			小学	164 336 (17.8)	104 859 (17.4)
数据缺失	283 446 (30.7)	161 721 (26.9)	初中	200 135 (21.7)	129 072 (21.4)
每天至少一次	188 826 (20.5)	136 284 (22.6)	高中	414 202 (44.9)	273 836 (45.5)
每几天一次	189 461 (20.5)	130 296 (21.6)	预科	35 083 (3.8)	23 385 (3.9)
每周少于一次	131 975 (14.3)	87 967 (14.6)	非学位课程	27 893 (3.0)	18 770 (3.1)
从不	129 583 (14.0)	85 911 (14.3)	学位课程	49 383 (5.3)	32 696 (5.4)
有氧运动频率 (SEI, “old_A6_SEI”), n (%)			父亲职业		
数据缺失	289 214 (31.3)	165 738 (27.5)	数据缺失	33 956 (3.7)	21 403 (3.6)
每周至少三次	186 106 (20.2)	125 566 (20.9)	待业	33 748 (3.7)	21 385 (3.6)
每周一次或两次	295 901 (32.0)	205 210 (34.1)	初级职业	112 245 (12.2)	71 664 (11.9)
每周少于一次	111 487 (12.1)	77 174 (12.8)	服务人员和销售人员	164 694 (17.8)	107 890 (17.9)
从不	40 593 (4.4)	28 527 (4.7)	工厂和机器操作员	143 004 (15.5)	90 189 (15.0)
有氧运动频率 (YSR, “old_A6_YSR”), n (%)			文员	81 669 (8.8)	54 824 (9.1)
数据缺失	667 440 (72.3)	466 654 (77.5)	手工艺及相关工人	153 113 (16.6)	98 985 (16.4)
从不或很少	42 676 (4.6)	20 432 (3.4)	助理人员	55 605 (6.0)	37 467 (6.2)

每月一次或三次	62 332 (6.8)	30 748 (5.1)	专业技术人员	43 963 (4.8)	29 565 (4.9)
每周一次	74 668 (8.1)	39 442 (6.5)	管理人员	101 304 (11.0)	65 800 (10.9)
每周至少两次	77 185 (8.4)	44 903 (7.5)	母亲的职业		
有氧运动时长 (“old_A7”), n (%)			数据缺失	11 373 (1.2)	7 114 (1.2)
数据缺失	34 693 (3.8)	31 063 (5.2)	待业	526 311 (57.0)	343 090 (57.0)
超过一小时	319 361 (34.6)	199 948 (33.2)	初级职业	40 099 (4.3)	25 274 (4.2)
半小时至一小时	328 132 (35.5)	216 398 (35.9)	服务人员和销售人员	94 832 (10.3)	60 562 (10.1)
少于半小时	173 682 (18.8)	112 506 (18.7)	工厂和机器操作员	3 694 (0.4)	2 343 (0.4)
零	67 433 (7.3)	42 264 (7.0)	文员	155 789 (16.9)	104 333 (17.3)
每日电视观看时长 (“old_A8”), n (%)			手工艺及相关工人	11 065 (1.2)	6 947 (1.2)
数据缺失	600 552 (65.0)	414 156 (68.8)	助理人员	38 900 (4.2)	25 891 (4.3)
小于 1 小时	40 986 (4.4)	26 124 (4.3)	专业技术人员	14 298 (1.5)	9 482 (1.6)
1-2 小时	120 893 (13.1)	65 778 (10.9)	管理人员	26 939 (2.9)	17 341 (2.9)
2-4 小时	113 917 (12.3)	71 377 (11.9)	住房类型		
> 4 小时	46 953 (5.1)	24 744 (4.1)	数据缺失	62 552 (6.8)	38 401 (6.4)
SEI 分数, 均值 (标准差)			其他	8 152 (0.9)	4 741 (0.8)
总分	37.4 (7.12)	37.4 (6.95)	私人住房 (非独立单元)	14 603 (1.6)	9 337 (1.6)
一般	15.2 (3.31)	15.1 (3.22)	公共房屋、社会房屋	264 484 (28.6)	171 485 (28.5)
社交相关	6.7 (1.80)	6.6 (1.79)	自置房屋	156 199 (16.9)	103 813 (17.2)
学校相关	7.1 (1.87)	7.1 (1.81)	机构住所	10 891 (1.2)	7 015 (1.2)
谎言评分 (排除分数≤ 2)	6.1 (1.54)	6.0 (1.54)	别墅、平房或现代村屋	30 890 (3.3)	19 965 (3.3)
父母相关	8.6 (1.95)	8.6 (1.86)	私人住房 (独立单元)	275 530 (29.8)	247 422 (41.1)

RBQ: Rutter 行为问卷; SEI: 与文化无关的自尊相关评估量表; YSR: 青少年自评问卷。

较 RF 表现出更为优越的预测性能, 其 1 年数据集的 F1 分数大于 0.75, 3 年数据集大于 0.70。

XGBoost 在两个数据集中共识别出 17 个非重复的预测因素, 此集合与初始包含 11 个预测因素的集合被同步应用于训练集的 XGBoost 运算。如表 3 所示, 采用 17 个预测因子的模型在 1 年及 3 年血压预测中均表现出更优的性能。其中, 1 年数据集预测高血压前期的 F1 分数为 0.79, 高血压为 0.75; 3 年数据集分别为 0.77 及 0.72。补充图 3 进一步展示了 17 个预测因素的 SHAP 值、总体相关性和方向性。

讨 论

本研究通过回顾性分析, 首次开发了用于预测香港儿童和青少年 1 年和 3 年后的血压状态的 ML 模型。该模型在不依赖血压测量和实验室检测的前提下, 展现出了较高的预测准确性。基于 SHAP 值分

析, 模型共识别出 17 个易于评估的预测因素, 为高血压及高血压前期风险儿童提供了及时的预防干预依据。

研究结果表明, 性别、体重和年龄为 1 年和 3 年预测中最重要的预测因素, 其中体重作为唯一可人为干预且便于测量的因素, 具有显著的临床意义。超重或肥胖个体的高血压风险显著增加, 这提示儿科医生和家长需密切监测这类儿童的血压变化。被归类为超重、肥胖以及接近超重的个体, 应定期完成准确的血压测量。此外, 饮食情况、体育活动习惯等对儿童高血压影响较大。加强有氧运动、减少久坐行为和改善营养等方式或习惯的重要性在此项研究中再次被验证^[40]。增加有氧运动时间、增加水果蔬菜进食量均可显著降低短期和长期高血压前期和高血压的风险。因此, 针对体重异常学生实施系统的健康管理计划至关重要。香港现行的

表 2 多种机器学习模型的平均性能评估

模型	随机森林	XGBoost	决策树	k-NN	多元逻辑回归 (MLR)
			1 年预测		
准确性, 均值 (标准差)	0.78 (0.000)	0.85 (0.001)	0.69 (0.001)	0.72 (0.001)	0.50 (0.002)
宏观平均 AUROC, 均值 (标准差)	0.91 (0.001)	0.92 (0.001)	0.77 (0.001)	0.84 (0.001)	0.70 (0.000)
微观平均 AUROC, 均值 (标准差)	0.91 (0.000)	0.91 (0.001)	0.77 (0.001)	0.86 (0.001)	0.68 (0.000)
精确度, 均值 (标准差)					
正常	0.81 (0.002)	0.82 (0.002)	0.80 (0.002)	0.85 (0.002)	0.52 (0.005)
高血压前期	0.76 (0.002)	0.89 (0.001)	0.65 (0.001)	0.66 (0.001)	0.42 (0.003)
高血压	0.77 (0.003)	0.87 (0.001)	0.63 (0.002)	0.72 (0.005)	0.53 (0.008)
召回率, 均值 (标准差)					
正常	0.94 (0.002)	0.97 (0.001)	0.77 (0.002)	0.45 (0.001)	0.64 (0.009)
高血压前期	0.77 (0.004)	0.82 (0.000)	0.67 (0.002)	0.88 (0.001)	0.26 (0.009)
高血压	0.64 (0.003)	0.78 (0.002)	0.63 (0.002)	0.82 (0.000)	0.61 (0.007)
F1 分数, 均值 (标准差)					
正常	0.87 (0.001)	0.89 (0.001)	0.79 (0.001)	0.59 (0.001)	0.58 (0.003)
高血压前期	0.76 (0.001)	0.85 (0.001)	0.66 (0.001)	0.76 (0.001)	0.33 (0.007)
高血压	0.70 (0.001)	0.82 (0.001)	0.63 (0.002)	0.77 (0.003)	0.57 (0.002)
AUROC, 均值 (标准差)					
正常	0.96 (0.000)	0.96 (0.001)	0.84 (0.000)	0.78 (0.001)	0.75 (0.002)
高血压前期	0.89 (0.002)	0.89 (0.001)	0.75 (0.001)	0.90 (0.001)	0.54 (0.001)
高血压	0.87 (0.001)	0.88 (0.001)	0.72 (0.001)	0.90 (0.001)	0.75 (0.001)
			3 年预测		
准确性, 均值 (标准差)	0.76 (0.001)	0.83 (0.002)	0.67 (0.001)	0.69 (0.001)	0.49 (0.001)
宏观平均 AUROC, 均值 (标准差)	0.90 (0.001)	0.91 (0.001)	0.76 (0.001)	0.82 (0.001)	0.70 (0.001)
微观平均 AUROC, 均值 (标准差)	0.90 (0.001)	0.90 (0.001)	0.76 (0.001)	0.84 (0.001)	0.68 (0.001)
精确度, 均值 (标准差)					
正常	0.79 (0.003)	0.76 (0.003)	0.78 (0.001)	0.78 (0.004)	0.51 (0.008)
高血压前期	0.75 (0.002)	0.87 (0.002)	0.63 (0.001)	0.65 (0.002)	0.40 (0.008)
高血压	0.74 (0.002)	0.83 (0.001)	0.60 (0.003)	0.69 (0.001)	0.52 (0.010)
召回率, 均值 (标准差)					
正常	0.92 (0.001)	0.95 (0.001)	0.76 (0.001)	0.44 (0.002)	0.61 (0.028)
高血压前期	0.74 (0.002)	0.78 (0.002)	0.65 (0.003)	0.85 (0.000)	0.26 (0.051)
高血压	0.63 (0.003)	0.75 (0.001)	0.61 (0.001)	0.78 (0.004)	0.62 (0.027)
F1 分数, 均值 (标准差)					
正常	0.85 (0.002)	0.87 (0.002)	0.77 (0.001)	0.56 (0.002)	0.56 (0.007)
高血压前期	0.75 (0.002)	0.82 (0.002)	0.64 (0.002)	0.74 (0.001)	0.31 (0.038)
高血压	0.68 (0.000)	0.79 (0.001)	0.61 (0.002)	0.73 (0.002)	0.57 (0.006)
AUROC, 均值 (标准差)					
正常	0.95 (0.001)	0.96 (0.001)	0.83 (0.001)	0.77 (0.001)	0.75 (0.000)
高血压前期	0.87 (0.002)	0.87 (0.002)	0.73 (0.001)	0.88 (0.001)	0.52 (0.002)
高血压	0.86 (0.001)	0.87 (0.000)	0.71 (0.001)	0.87 (0.001)	0.76 (0.001)

AUROC: 受试者工作特征曲线下面积; k-NN: k 邻近算法; XGBoost: 极端梯度提升。表格内所示数值为平均性能, 每个模型重复 10 次, 所有测试集上性能均已列出。

“EatSmart@school.hk” 和 “StartSmart@school.hk” 等 校园健康计划^[41-43]，为推广健康饮食和加强体育锻炼

提供了良好示范。同时强调家长和监护人应积极参与，全面掌握科学的体重管理及营养策略^[43]。

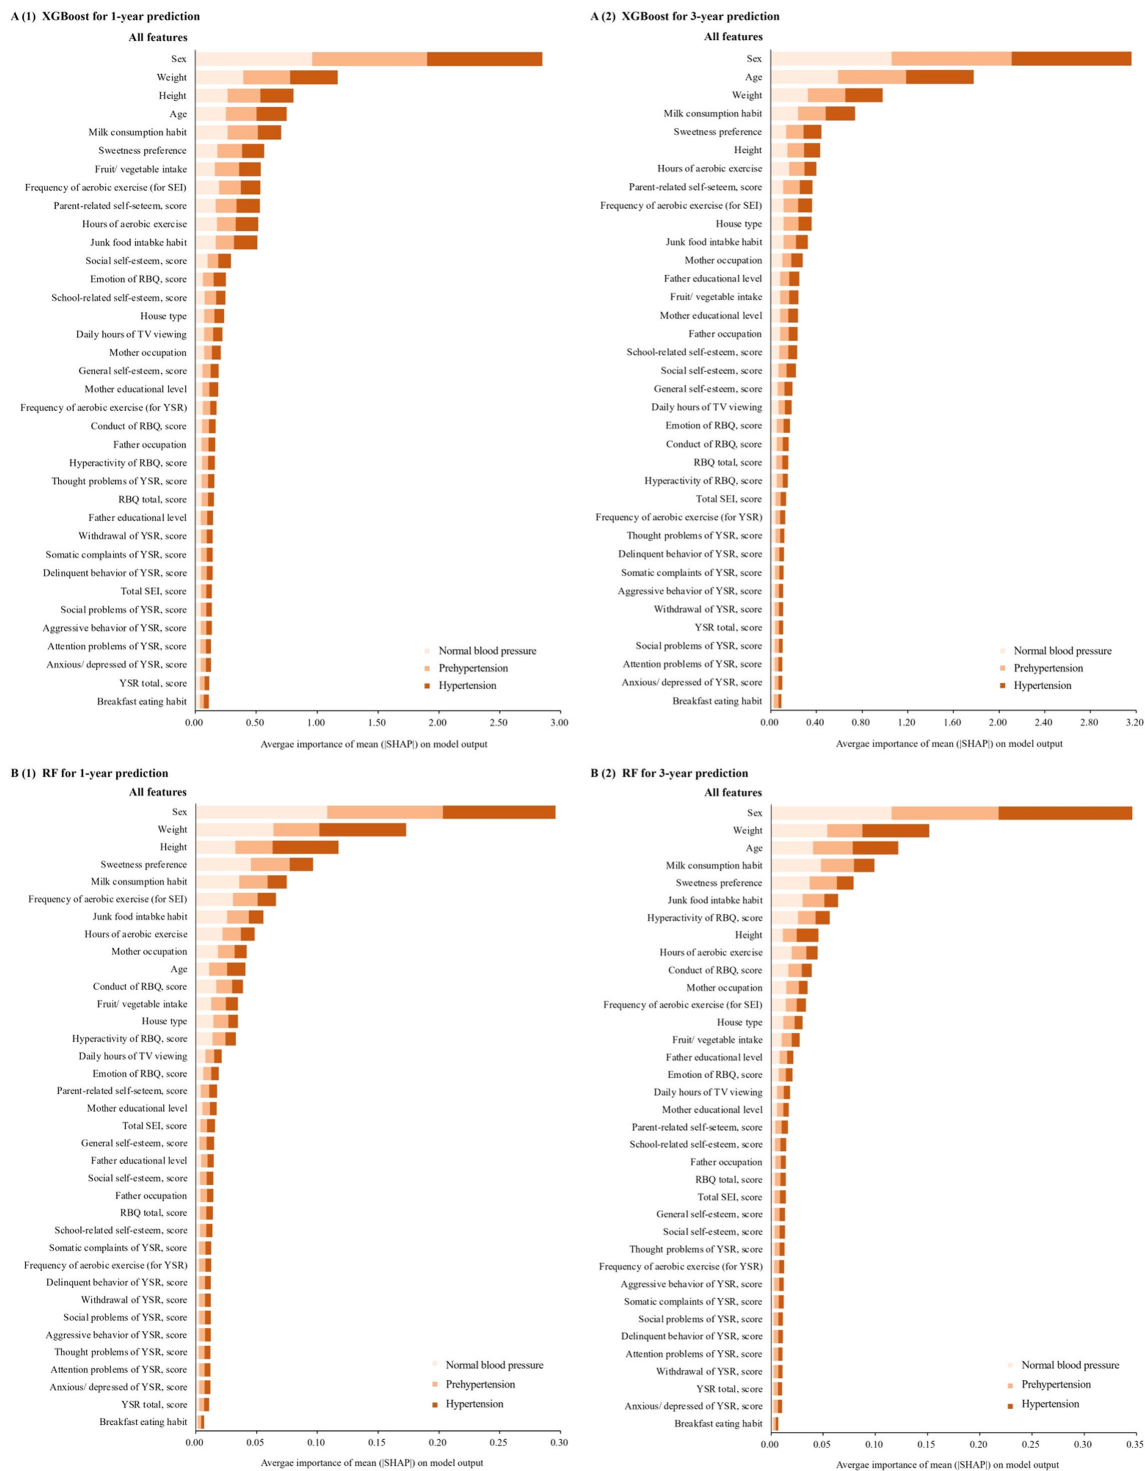


图 2 1 年和 3 年预测集中预测因子的重要性排序 (基于平均绝对 SHAP 值)。图中展示了在训练集上表现优异的两个多元预测模型 (XGBoost 和 RF) 中预测因子的重要性排序及其平均绝对 SHAP 值。
RF: 随机森林; SHAP: Shapley 加性解释; XGBoost: 极端梯度提升。

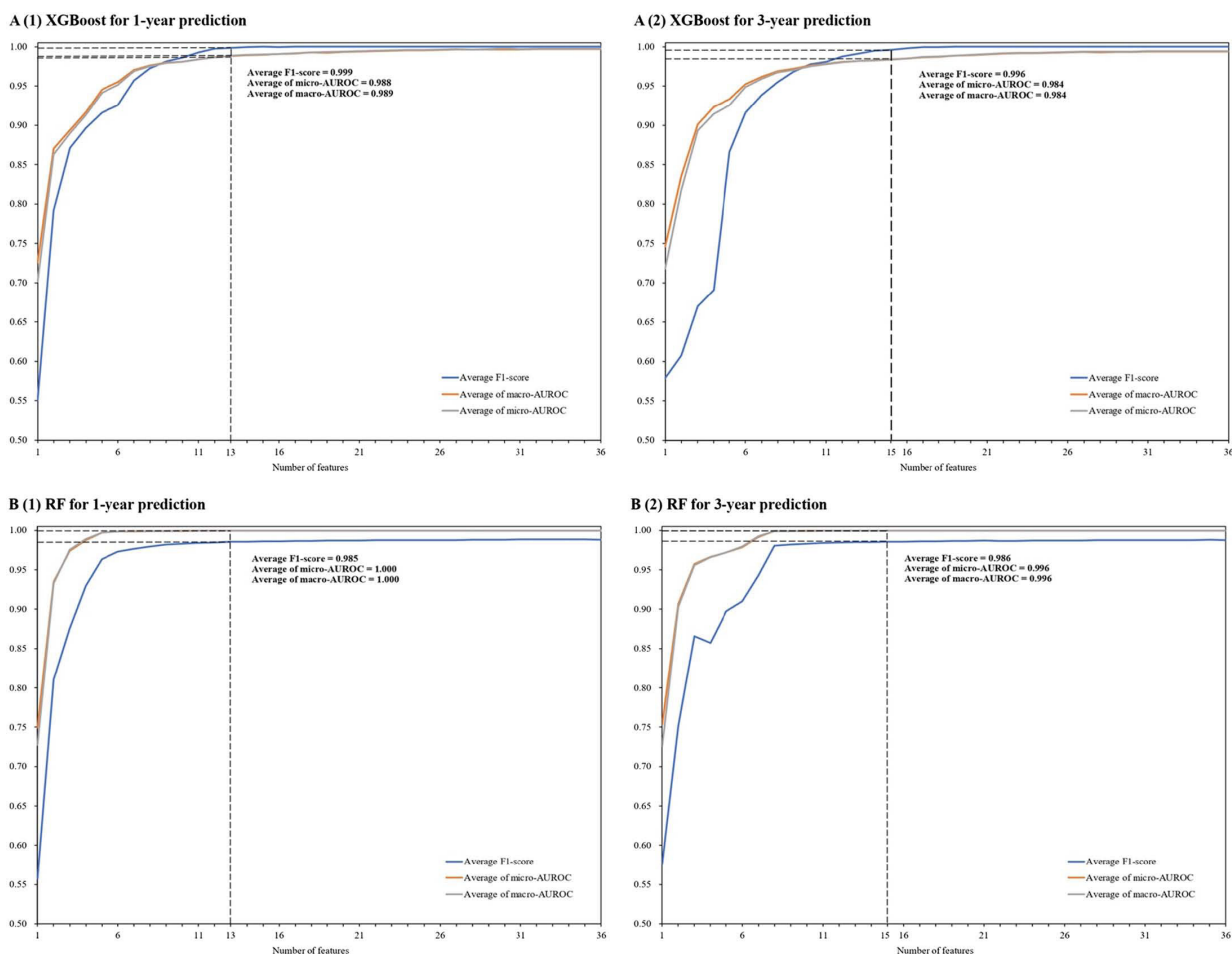


图3 预测因素筛选过程中 F1 分数和 AUROC 平均值。
XGBoost 模型 (A) 和 RF 模型 (B) 中，按序纳入 1 至 36 个预测因素，图片显示了训练集样本的 F1 分数、微观 AUROC 和宏观 AUROC 的平均值趋势。模型计算时选择了相同且数据量较大的风险因素，以降低数量因素对预测性能造成的影响，其中 1 年数据集识别出 13 个预测因子，3 年数据集有 15 个。
AUROC：受试者工作特征曲线下面积；RF：随机森林；XGBoost：极端梯度提升。

值得注意的是，社会经济地位 (socioeconomic status, SES) 被证实为儿童高血压的重要预测因素。既往关于 SES 与血压关系的研究，结论存在不一致的情况，考虑可能与 SES 指标不统一有关^[44,45]。本研究通过纳入了多个 SES 指标如父母双方教育水平、母亲的职业以及住房类型等，明确了极低 SES 与儿童和青少年的高血压高风险存在相关性。总体而言，SES 与血压之间的关系较为复杂^[44,45]，较低的童年 SES 与夜间血压下降不足（即夜间非勺型血压）有关，这可能提示了该分类下的儿童日后患心血管疾病的风险增加^[46]。另一方面，父母教育水平、收入

等保护性因素可能改善低 SES 居住环境导致的不良结果^[45]。住房类型则包含了生活环境相关的不良因素，如噪音、拥挤等，这些因素可能对儿童和青少年原发性高血压及相关的其他健康情况造成不良影响^[47]。虽然改变 SES 难度较大，但这一发现为公共卫生政策制定者提供了重要依据，提示需关注居住环境对儿童健康的影响。

除此以外，本研究首次将与父母相关的自尊情况、社会自尊及情绪行为纳入高血压风险预测体系。情绪调节障碍和低自尊可能通过影响饮食行为

和体力活动^[48]，间接导致体重增加和血压升高^[48-50]。既往研究也强调了父母支持和良好的社会环境因素在促进健康发展和预防儿童肥胖中具有重要作用^[51,52]。总结来说，对于儿童的健康促进策略需更为全面，应早期干预实施，并侧重于降低社会和情感因素对健康结果的不良影响。

本研究的人口背景为中国香港，该地区高血压的患病率较高且未被充分认识。在香港，15至24岁的青少年人群中高血压患病率为4.9%，然而，仍有约41%并不了解本人的高血压疾病状况^[53,54]。香港独特的人口特征为本研究提供了特殊背景。作为高度发达的非西方地区，香港经历了快速的社会经济转型^[55,56]，其高人口密度、特殊居住环境^[57-59]对儿童生活方式产生深远影响。虽然本研究基于全港

地区大量数据，但由于香港汉族人口比例较高（2006年至2021年汉族人口约占95.0%至91.6%）^[60]，人种同质化程度较高，因此本研究结果在其他种族中的适用性目前仍需验证。

在方法学方面，ML预测性能的提高归功于这一技术捕捉预测因素之间复杂的、非线性关系的强大效能^[61]，特别是XGBoost计算效率高，并且计算能力强，用于临床预测适用性强^[30]；其采用了有效的正则化技术以防止过拟合，模拟数据的泛化能力强^[61]。XGBoost算法凭借其广泛的可调超参数，能够进一步优化模型的预测性能^[61]。该算法采用梯度提升框架，通过迭代方式添加决策树并修正前序模型的预测误差，使其在本研究测试的所有ML模型中展现出最优的预测准确度^[62]。尽管XGBoost已在急性心力衰竭预测^[63]、中风风险评估^[64]以及空气污染预测^[65]等多个领域证实了其有效性，但本研究构建的模型仍需通过外部数据验证来评估其泛化能力。

表 3 XGBoost 模型在 1 年和 3 年数据集中的预测性表现

指标	11 个预测因素		17 个预测因素	
	1 年预测	3 年预测	1 年预测	3 年预测
准确性 (均值)	0.76	0.75	0.81	0.79
宏观平均 AUROC (均值)	0.9	0.89	0.91	0.9
微观平均 AUROC (均值)	0.88	0.88	0.9	0.89
精确度 (均值)				
正常	0.81	0.79	0.81	0.79
高血压前期	0.75	0.75	0.82	0.81
高血压	0.72	0.69	0.8	0.76
召回率 (均值)				
正常	0.95	0.94	0.96	0.94
高血压前期	0.7	0.67	0.76	0.73
高血压	0.64	0.64	0.71	0.69
F1 分数 (均值)				
正常	0.88	0.86	0.88	0.86
高血压前期	0.72	0.71	0.79	0.77
高血压	0.68	0.67	0.75	0.72
AUROC (均值)				
正常	0.96	0.96	0.96	0.96
高血压前期	0.85	0.84	0.87	0.86
高血压	0.83	0.83	0.85	0.84

AUROC：受试者工作特征曲线下面积；XGBoost：极端梯度提升。

研究局限性

本研究仍存在一些局限性。首先，SHS数据集未完全涵盖已知的儿童高血压风险因素，如家族史、二手烟暴露和睡眠障碍等重要变量，这些因素需要在后续研究中加以补充。其次，研究中虽然采用SMOTE方法处理了类别不平衡问题，但在样本量较小或阳性结果易受人为因素影响的分类中，该方法可能无法充分反映真实数据的变异特征，从而导致过拟合和模型精度下降。第三，当前模型尚未经过外部独立数据集的验证，未来可在其他人群中测试本研究所建立的ML模型，以评估其实际泛化性能。最后，本研究主要关注预测因素的筛选和重要性评估，尚未深入分析各变量的具体效应量、相互作用机制及混杂效应，这一方向值得在后续研究中进一步探索。

结 论

本研究证实,应用 ML 算法 (特别是 XGBoost) 可显著提升时间预测模型的准确性。儿童高血压的一级预防关键因素包括: 体重管理、健康生活习惯、社会经济地位以及社会情感健康。未来需要在不同人群中验证本研究结果,以建立更具稳健性和准确性的预测模型,从而有效降低儿童高血压发病率。

(沈洁 译 黄洁 校)

联系人: 丁欣 etyxcbzx@suda.edu.cn

参考文献

- 1 Falkner B. Hypertension in children and adolescents: epidemiology and natural history. *Pediatr Nephrol*. 2010;25(7):1219–1224. PubMed doi: 10.1007/s00467-009-1200-3
- 2 Jacobs DR Jr, Woo JG, Sinaiko AR, et al. Childhood cardiovascular risk factors and adult cardiovascular events. *N Engl J Med*. 2022;386(20):1877–1888. PubMed doi: 10.1056/NEJMoa2109191
- 3 Forouzanfar MH, Afshin A, Alexander LT, et al; GBD 2015 Risk Factors Collaborators. Global, regional, and national comparative risk assessment of 79 behavioural, environmental and occupational, and metabolic risks or clusters of risks, 1990-2015: a systematic analysis for the Global Burden of Disease Study 2015. *Lancet*. 2016;388(10053):1659–1724. PubMed doi: 10.1016/S0140-6736(16)31679-8
- 4 Hinton TC, Adams ZH, Baker RP, et al. Investigation and treatment of high blood pressure in young people: too much medicine or appropriate risk reduction? *Hypertension*. 2020;75(1):16–22. PubMed doi: 10.1161/HYPERTENSIONAHA.119.13820
- 5 Falkner B, Gidding SS, Baker-Smith CM, et al; American Heart Association Council on Hypertension; Council on Lifelong Congenital Heart Disease and Heart Health in the Young; Council on Kidney in Cardiovascular Disease; Council on Lifestyle and Cardiometabolic Health; and Council on Cardiovascular and Stroke Nursing. Pediatric primary hypertension: an underrecognized condition: a scientific statement from the American Heart Association. *Hypertension*. 2023;80(6):e101–e111. PubMed doi: 10.1161/HYP.0000000000000228
- 6 Flynn JT. What level of blood pressure is concerning in childhood? *Circ Res*. 2022;130(5):800–808. PubMed doi: 10.1161/CIRCRESAHA.121.319819
- 7 Lurbe E. Childhood blood pressure: a window to adult hypertension. *J Hypertens*. 2003;21(11):2001–2003. PubMed doi: 10.1097/00004872-200311000-00004
- 8 Erlingsdottir A, Indridason OS, Thorvaldsson O, Edvardsson VO. Blood pressure in children and target-organ damage later in life. *Pediatr Nephrol*. 2010;25(2):323–328. PubMed doi: 10.1007/s00467-009-1350-3
- 9 Yang L, Magnussen CG, Yang L, Bovet P, Xi B. Elevated blood pressure in childhood or adolescence and cardiovascular outcomes in adulthood: a systematic review. *Hypertension*. 2020;75(4):948–955. PubMed doi: 10.1161/HYPERTENSIONAHA.119.14168
- 10 Song P, Zhang Y, Yu J, et al. Global prevalence of hypertension in children: a systematic review and meta-analysis. *JAMA Pediatr*. 2019;173(12):1154–1163. PubMed doi: 10.1001/jamapediatrics.2019.3310
- 11 Wang L, Song L, Liu B, et al. Trends and status of the prevalence of elevated blood pressure in children and adolescents in China: a systematic review and meta-analysis. *Curr Hypertens Rep*. 2019;21(11):88. PubMed doi: 10.1007/s11906-019-0992-1
- 12 Falkner B, Lurbe E. Primordial prevention of high blood pressure in childhood: an opportunity not to be missed. *Hypertension*. 2020;75(5):1142–1150. PubMed doi: 10.1161/HYPERTENSIONAHA.119.14059
- 13 Hassan MA, Zhou W, Ye M, He H, Gao Z. The effectiveness of physical activity interventions on blood pressure in children and adolescents: a systematic review and network meta-analysis. *J Sport Health Sci*. 2024;13(5):699–708. PubMed doi: 10.1016/j.jshs.2024.01.004
- 14 Hao G, Wang X, Treiber FA, Harshfield G, Kapuku G, Su S. Blood pressure trajectories from childhood to young adulthood associated with cardiovascular risk: results from the 23-year longitudinal Georgia Stress and Heart Study. *Hypertension*. 2017;69(3):435–442. PubMed doi: 10.1161/HYPERTENSIONAHA.116.08312
- 15 Hayman LL, Meininger JC, Daniels SR, et al; American Heart Association Committee on Atherosclerosis, Hypertension, and Obesity in Youth of the Council on Cardiovascular Disease in the Young; American Heart Association Council on Cardiovascular Nursing; American Heart Association Council on Epidemiology and Prevention; American Heart Association Council on Nutrition, Physical Activity, and Metabolism. Primary prevention of cardiovascular disease in nursing practice: focus on children and youth: a scientific statement from the American Heart Association Committee on Atherosclerosis, Hypertension, and Obesity in Youth of the Council on Cardiovascular Disease in the Young, Council on Cardiovascular Nursing, Council on Epidemiology and Prevention, and Council on Nutrition, Physical Activity, and Metabolism. *Circulation*. 2007;116(3):344–357. PubMed doi: 10.1161/CIRCULATIONAHA.107.184595
- 16 Flynn JT, Kaelber DC, Baker-Smith CM, et al; SUBCOMMITTEE ON SCREENING AND MANAGEMENT OF HIGH BLOOD PRESSURE

- IN CHILDREN. Clinical practice guideline for screening and management of high blood pressure in children and adolescents. *Pediatrics*. 2017;140(3):e20171904. PubMed doi: 10.1542/peds.2017-1904
- 17 Chowdhury MZI, Naeem I, Quan H, et al. Prediction of hypertension using traditional regression and machine learning models: a systematic review and meta-analysis. *PLoS One*. 2022;17(4):e0266334. PubMed doi: 10.1371/journal.pone.0266334
- 18 Dionne JM. Evidence gaps in the identification and treatment of hypertension in children. *Can J Cardiol*. 2020;36(9):1384–1393. PubMed doi: 10.1016/j.cjca.2020.02.076
- 19 Liang JH, Zhao Y, Chen YC, et al. Development and validation of a nomogram-based prognostic model to predict high blood pressure in children and adolescents-findings from 342,736 individuals in China. *Front Cardiovasc Med*. 2022;9:884508. PubMed doi: 10.3389/fcvm.2022.884508
- 20 Hamoen M, Welten M, Nieboer D, et al. Development of a prediction model to target screening for high blood pressure in children. *Prev Med*. 2020;132:105997. PubMed doi: 10.1016/j.ypmed.2020.105997
- 21 Wieniawski P, Werner B. Prediction of the hypertension risk in teenagers. *Cardiol J*. 2022;29(6):994–1003. PubMed doi: 10.5603/CJ.a2020.0079
- 22 Wang B, Yuan Y, Sun L, et al. Optimal cutoff of the abdominal skinfold thickness (AST) to predict hypertension among Chinese children and adolescents. *J Hum Hypertens*. 2022;36(9):860–865. PubMed doi: 10.1038/s41371-021-00573-w
- 23 Tong J, An X, Zhao L, et al. Combining multiaspect factors to predict the risk of childhood hypertension incidence. *J Clin Hypertens (Greenwich)*. 2022;24(8):1015–1025. PubMed doi: 10.1111/jch.14544
- 24 Daley MF, Reifler LM, Johnson ES, et al. Predicting hypertension among children with incident elevated blood pressure. *Acad Pediatr*. 2017;17(3):275–282. PubMed doi: 10.1016/j.acap.2016.09.009
- 25 Hamoen M, Vergouwe Y, Wijga AH, et al. Dynamic prediction of childhood high blood pressure in a population-based birth cohort: a model development study. *BMJ Open*. 2018;8(11):e023912. PubMed doi: 10.1136/bmjopen-2018-023912
- 26 Flynn JT, Urbina EM. Pediatric ambulatory blood pressure monitoring: indications and interpretations. *J Clin Hypertens (Greenwich)*. 2012;14(6):372–382. PubMed doi: 10.1111/j.1751-7176.2012.00655.x
- 27 Sultana A, Afroze S, Sonia SF, et al. Pediatric hypertension: parental perception and knowledge. *Saudi J Kidney Dis Transpl*. 2023;34 (2):196–200. PubMed doi: 10.4103/1319-2442.391900
- 28 Hansen ML, Gunn PW, Kaelber DC. Underdiagnosis of hypertension in children and adolescents. *JAMA*. 2007;298(8):874–879. PubMed doi: 10.1001/jama.298.8.874
- 29 Enrolment forms and related information. Student Health Service, Department of Health, The Government of the Hong Kong Special Administrative Region. Updated January 29, 2021. Accessed June 2022. https://www.studenthealth.gov.hk/english/resources/resources_forms/resources_forms.html
- 30 Liu H, Wu YC, Chau PH, Chung TWH, Fong DYT. Prediction of adolescent weight status by machine learning: a population-based study. *BMC Public Health*. 2024;24(1):1351. PubMed doi: 10.1186/s12889-024-18830-1
- 31 Beretta L, Santaniello A. Nearest neighbor imputation algorithms: a critical evaluation. *BMC Med Inform Decis Mak*. 2016;16 Suppl 3 (Suppl 3):74. doi: 10.1186/s12911-016-0318-z
- 32 Gardner ML, Freitas MA. Multiple imputation approaches applied to the missing value problem in bottom-up proteomics. *Int J Mol Sci*. 2021;22(17):9650. PubMed doi: 10.3390/ijms22179650
- 33 Chawla NV, Bowyer KW, Hall LO, Kegelmeyer WP. SMOTE: synthetic minority over sampling technique. *J Artif Intell Res*. 2002;16: 321–357. doi: 10.1613/jair.953
- 34 Wikipedia contributors. Pareto principle. Wikipedia, The Free Encyclopedia. May 9, 2024. Accessed May 29, 2024. https://en.wikipedia.org/w/index.php?title=Pareto_principle&oldid=1223046488
- 35 Quinlan JR. Induction of decision trees. *Mach Learn*. 1986;1:81–106. doi: <https://doi.org/10.1007/BF00116251>
- 36 Breiman L. Random forests. *Mach Learn*. 2001;45(1):5–32. doi: 10.1023/A:1010933404324
- 37 Steinbach M, Tan PN. kNN: k-nearest neighbors. In: Wu X, Kumar V, eds. *The Top Ten Algorithms in Data Mining*. 1st ed. Chapman and Hall; 2009:165–176.
- 38 Chen T, Guestrin C. XGBoost: a scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'2016)*. Association for Computing Machinery; 2016:785–794. doi: <https://doi.org/10.48550/arXiv.1603.02754>
- 39 Lundberg SM, Lee SI. A unified approach to interpreting model predictions. In *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17)*. Curran Associates; 2017:4768–4777. doi: <https://doi.org/10.48550/arXiv.1705.07874>
- 40 Expert Panel on Integrated Guidelines for Cardiovascular Health and Risk Reduction in Children and Adolescents; National Heart, Lung, and Blood Institute. Expert panel on integrated guidelines for cardiovascular health and risk reduction in children and adolescents: summary report. *Pediatrics*. 2011;128 Suppl 5(Suppl 5):S213–S256. doi: 10.1542/peds.2009-2107C
- 41 StartSmart@school.hk. Accessed March 1, 2024. <https://www.startsmart.gov.hk/en/index.aspx>

- 42 EatSmart@school.hk. Accessed July 18, 2024. <http://www.school.eatsmart.gov.hk/en/template/home.asp>
- 43 Start Smart Parent Guide. StartSmart@school.hk. Accessed July 07, 2024. <https://www.startsmart.gov.hk/en/others.aspx?MenuID=64>
- 44 Soylu A, Kavukçu S, Türkmen M, Cabuk N, Duman M. Effect of socioeconomic status on the blood pressure in children living in a developing country. *Pediatr Int*. 2000;42(1):37–42. PubMed doi: 10.1046/j.1442-200x.2000.01168.x
- 45 Wilson DK, Klier W, Plybon L, Sica DA. Socioeconomic status and blood pressure reactivity in healthy Black adolescents. *Hypertension*. 2000;35(1 Pt 2):496–500. PubMed doi: 10.1161/01.hyp.35.1.496
- 46 Campbell TS, Séguin JR, Vitaro F, Tremblay RE, Ditto B. Childhood socioeconomic position and blood pressure dipping in early adulthood: a longitudinal study. *Ann Behav Med*. 2013;46(2):227–231. PubMed doi: 10.1007/s12160-013-9496-4
- 47 Kupersmidt JB, Griesler PC, DeRosier ME, Patterson CJ, Davis PW. Childhood aggression and peer relations in the context of family and neighborhood factors. *Child Dev*. 1995;66(2):360–375. PubMed doi: 10.2307/1131583
- 48 Heatherton TF, Baumeister RF. Binge eating as escape from self-awareness. *Psychol Bull*. 1991;110(1):86–108. PubMed doi: 10.1037/0033-2909.110.1.86
- 49 Ternouth A, Collier D, Maughan B. Childhood emotional problems and self-perceptions predict weight gain in a longitudinal regression model. *BMC Med*. 2009;7(1):46. PubMed doi: 10.1186/1741-7015-7-46
- 50 Kiessling SG, McClanahan KK, Omar HA. Obesity, hypertension, and mental health evaluation in adolescents: a comprehensive approach. *Int J Adolesc Med Health*. 2008;20(1):5–15. PubMed doi: 10.1515/IJAMH.2008.20.1.5
- 51 Campbell MK. Biological, environmental, and social influences on childhood obesity. *Pediatr Res*. 2016;79(1-2):205–211. PubMed doi: 10.1038/pr.2015.208
- 52 Hanson MA, Gluckman PD. Early developmental conditioning of later health and disease: physiology or pathophysiology? *Physiol Rev*. 2014;94(4):1027–1076. PubMed doi: 10.1152/physrev.00029.2013
- 53 Kwok MK, Leung GM, Chung TWH, Lee KKY, Schooling CM. Divergent secular trends in blood pressure and body mass index in children and adolescents in Hong Kong. *Sci Rep*. 2017;7(1):4763. PubMed doi: 10.1038/s41598-017-05133-2
- 54 Non-Communicable Diseases Watch May 2023. Department of Health Centre for Health Protection. Accessed May 17, 2023. https://www.chp.gov.hk/files/pdf/ncd_watch_may_2023_eng.pdf
- 55 Schooling CM, Leung GM. A socio-biological explanation for social disparities in non-communicable chronic diseases: the product of history? *J Epidemiol Community Health*. 2010;64(11):941–949. PubMed doi: 10.1136/jech.2008.086553
- 56 Hong Kong's Gini Coefficient. World Economics. Accessed August 21, 2024. <https://www.world-economics.com/Inequality/Gini-Coefficient/Hong%20Kong.aspx#:~:text=Hong%20Kong's%20Gini%20Coefficient%20Index%20is%2051.8%20and%20was%20most,easy%20comparison%20with%20other%20countries>
- 57 Marmot M, Castedo A, Allen J, et al. The environment and health inequalities in Hong Kong. Institute of Health Equity; 2024. Accessed August 21, 2024. https://www.ihe.cuhk.edu.hk/wp-content/uploads/The-Environment-and-Health-Inequalities-in-Hong-Kong-report_final-digital-v2.pdf
- 58 Wikipedia contributors. Foreign domestic helpers in Hong Kong. Wikipedia, The Free Encyclopedia. May 2, 2024. Accessed August 21, 2024. https://en.wikipedia.org/w/index.php?title=Foreign_domestic_helpers_in_Hong_Kong&oldid=1221832794
- 59 Leung C, Leung S, Lee F, Lo SK. Socioeconomic difference in development among preschool children. *HK J Paediatr*. 2020;25:98–106. New Series.
- 60 The Demographics: Ethnic Groups. Race Relations Unit, Home Affairs Department, The Government of the Hong Kong Special Administrative Region. Accessed June 21, 2024. <https://www.had.gov.hk/rru/english/info/demographics.htm>
- 61 Bentéjac C, Csörgő A, Martínez-Muñoz G. A comparative analysis of gradient boosting algorithms. *Artif Intell Rev*. 2021;54(3):1937–1967. doi: 10.1007/s10462-020-09896-5
- 62 Khan AA, Chaudhari O, Chandra R. A review of ensemble learning and data augmentation models for class imbalanced problems: combination, implementation and evaluation. *Expert Systems with Applications*. 2023;244:122778. doi: <https://doi.org/10.48550/arXiv.2304.02858>
- 63 Austin DE, Lee DS, Wang CX, et al. Comparison of machine learning and the regression-based EHMRG model for predicting early mortality in acute heart failure. *Int J Cardiol*. 2022;365:78–84. PubMed doi: 10.1016/j.ijcard.2022.07.035
- 64 Lolak S, Attia J, McKay GJ, Thakkinstian A. Comparing explainable machine learning approaches with traditional statistical methods for evaluating stroke risk models: retrospective cohort study. *JMIR Cardio*. 2023;7:e47736. PubMed doi: 10.2196/47736
- 65 Ayus I, Natarajan N, Gupta D. Comparison of machine learning and deep learning techniques for the prediction of air pollution: a case study from China. *Asian J Atmos*. 2023;17:4. doi: <https://doi.org/10.1007/s44273-023-00005-w>
- 66 Kuang J, Yang H, Liu J, Yan Z. Dynamic prediction of cardiovascular disease using improved LSTM. *International J Crowd Sci*. 2019;3(1):14–25. doi: 10.1108/IJCS-01-2019-0002

【英文原件请参阅 *PEDIATRICS* 2025;155(3):e2024066675】