

基于 DeepFM 和 XGBoost 融合模型的静脉血栓预测^①



李莉, 谢超, 吴迪

(江苏大学 计算机科学与通信工程学院, 镇江 212013)

通信作者: 谢超, E-mail: 458761443@qq.com

摘要: 外周穿刺置入中心静脉导管 (PICC) 技术被广泛运用于中长期静脉治疗. 在 PICC 置管时会导致各种并发症和不良反应, 如 PICC 相关性血栓. 随着机器学习和深度神经网络的不断发展与完善, 为 PICC 相关性血栓的辅助诊断提供了基于临床医学数据的解决方法. 本文构建了基于 DeepFM 和 XGBoost 的融合模型, 针对稀疏数据进行特征融合并能降低过拟合的情况, 能够对 PICC 相关性血栓提供风险预测. 实验结果表明, 融合模型能够有效地对 PICC 相关性血栓进行特征重要性提取并预测患病概率, 辅助临床在外周穿刺置过程中识别血栓高危风险因素, 及时进行干预从而预防血栓的发生.

关键词: 机器学习; 血栓预测; DeepFM; XGBoost; 模型融合; 预测模型; 深度学习

引用格式: 李莉, 谢超, 吴迪. 基于 DeepFM 和 XGBoost 融合模型的静脉血栓预测. 计算机系统应用, 2022, 31(9): 376-381. <http://www.c-s-a.org.cn/1003-3254/8691.html>

Prediction of Venous Thrombosis Based on Fusion Model of DeepFM and XGBoost

LI Li, XIE Chao, WU Di

(School of Computer Science and Communication Engineering, Jiangsu University, Zhenjiang 212013, China)

Abstract: The peripherally inserted central catheter (PICC) technology is widely used in medium and long-term venous treatment, but it can cause various complications and adverse reactions, such as PICC-related thrombosis. The continuous development of machine learning and deep neural networks provides a solution for the assisted diagnosis of PICC-related thrombosis based on clinical medical data. In this study, a fusion model of DeepFM and XGBoost is constructed to predict the risks of PICC-related thrombosis, which can perform feature fusion for sparse data and reduce over-fitting. The experiment reveals that the fusion model can effectively extract the feature importance of PICC-related thrombosis, predict the probability of disease, assist the clinic in identifying high-risk factors of thrombosis in PICC, and intervene to prevent the occurrence of thrombosis in time.

Key words: machine learning; prediction of thrombosis; DeepFM; XGBoost; fusion model; prediction model; deep learning

1 引言

外周穿刺置入中心静脉导管 (PICC) 技术是一种从周围静脉导入且末端位于中心静脉的深静脉置管技术, 已经广泛用于中长期静脉治疗手段. 随着 PICC 置管技术的广泛使用, 其产生的多种并发症及不良反应被医疗工作者所发现, 例如穿刺点出血或感染、穿刺

形成静脉炎症或血栓、败血症和局部感染. Abdullah 等人^[1]提出 PICC 相关性血栓是 PICC 置管技术产生的常见且严重的并发症之一. PICC 相关性血栓多发生于置管的插入位置^[2]以及插入过程由于穿刺、导管直接损伤血管内膜或者基于患者自身基础性疾病影响. 因此, 在置管前进行及时的发现和干预能够有效预防

^① 基金项目: 江苏省研究生科研与实践创新项目 (SJCX21_1695)

收稿时间: 2021-12-15; 修改时间: 2022-01-24; 采用时间: 2022-01-30; csa 在线出版时间: 2022-06-28

血栓的形成。

机器学习方法被广泛运用于医疗领域。Nafe 等人^[3]使用机器学习方法,建立了一种新型的学习模型 rML 绘制血栓的风险概率,根据风险对患者进行识别和分组,具有重要的临床意义。Ryan 等人^[4]使用梯度增强方法拟合决策树,并用 XGBoost 机器学习方法将多个决策树结果进行组合,从而获得血栓风险预测概率。Liu 等人^[5]通过癌症患者的数据收集,提出了一种基于 LASSO 回归的随机森林方法构建了 LASSO-RF 模型,用于筛选与血栓形成有关的高风险因子,能够对 PICC 相关性血栓进行更精确的评估,以指导早期预防治疗。Sukper 等人^[6]使用逻辑回归、决策树、前馈神经网络、支持向量机和随机森林 5 种机器学习方法,对 573 例患者进行数据进行训练,通过模型效果对比得出支持向量机具有最佳的模型性能,能够进行有效血栓风险预测。实验结果证明,使用多种机器学习方法构建预测模型,能够有效地对血栓风险进行评估,从而辅助临床医学诊断,对于那些具有高 PICC 相关性血栓风险的患者,提前作出判断并尽早干预。

本文提出了一种基于机器学习和深度神经网络方法的 PICC 相关性血栓预测模型,构建了一种基于 DeepFM 和 XGBoost 的融合模型,并使用模型基本评价指标来对模型效果进行验证。本融合模型能够有效地对 PICC 相关性静脉血栓进行风险预测,指导临床识别血栓高危风险因素,提前采取治疗或护理措施对高危患者进行药物或者物理干预,从而降低患者发生血栓的概率。

2 数据预处理和模型方法

2.1 数据集来源

本研究中引入的所有模型均在同一数据集上进行验证。本数据集来自于某临床医学数据,每个实例有 30 个属性。包括有原发肿瘤部位、药物性质、深筋脉血栓史、C 反应蛋白浓度等人体实际测量指标。其中,原发肿瘤部位包含 4 个部位,纵隔上、纵隔下、全身和头颈部,由整数 1-4 表示;药物性质包含其他药物、化疗、血管生长抑制剂、表皮生长受体酪氨酸酶抑制剂、激素和内分泌,由整数 0-5 表示。

2.2 数据预处理

该数据集具有不完整性和维度差异,因此针对缺失值数量对数据进行筛选。将包含大量缺失值的患者

数据进行剔除,包含少量缺失特征的数据以及异常数据进行数据填补。

使用随机森林的方法,通过对原有数据进行训练来进行有误数据的填补。同时进行数据无量纲归一化,能够将不同量纲的数据进行处理,使每个变量指标具有同等表现力。

(1) 缺失值处理

本临床医学数据集在实际收集构建的过程中,会产生部分特征项遗漏的情况,因此需要针对缺失特征数量进行部分删除或者缺失值填补操作。本数据集具有 30 维特征,我们选择直接删除缺失特征数量大于 5 的实例,将缺乏少量特征的数据实例使用随机森林的方法进行缺失值填补,利用随机森林算法进行缺失值填补的流程如下:

Step 1. 首先输入不包含缺失值的 PICC 相关性血栓数据集作为样本集 S :

$$S = \{(x_1, y_1), (x_2, y_2), \dots, (x_M, y_M)\}$$

其中, M 为不包含缺失值的样本数。

Step 2. 将数据划分为训练集和测试集,进行 n 轮训练 ($n \in \{1, 2, \dots, M\}$)。

Step 3. 在训练的过程中进行 n 次 Bootstrap 采样,得到采样后的样本集 S_n 。

Step 4. 将第 n 个随机采样样本集 S_n 输入到第 n 个决策树模型 $G_n(x)$ 中。在训练决策树时,在样本中选取效果较好的作为决策树的左右子树。

Step 5. 将 n 轮训练得到的回归预测结果进行算术平均得到预测输出。

(2) 无量纲归一化处理

本模型是基于 DeepFM 和 XGBoost 的融合模型,首先需要将连续特征按照统一方法缩放至 $[0, 1]$ 区间内,这样能够消除数据之间尺度和单位度量的影响,使得不同量纲之间的数据处于同一量级,加快梯度下降的收敛速度^[7],提高模型学习效率。数据无量纲归一化处理计算公式如式 (1):

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

x' 和 x 分别为归一化前后数值, x_{\min} 和 x_{\max} 分别为同一特征最小值和最大值。部分无量纲化数据如表 1。

3 基于 DeepFM 和 XGBoost 的融合模型

本 PICC 相关性血栓临床医学数据具有较多特征

值为零的情况,部分特征组合属于稀疏数据.部分包含0的特征数据如表2所示.

表1 部分无量纲归一化数据

Id	白细胞	中性粒细胞	血红蛋白	PLT	C反应蛋白
1	0.679581	0.455969	0.134865	0.233010	0.017329
2	0.883484	0.273973	0.012703	0.197411	0.007136
3	0.667929	0.344423	0.348649	0.252427	0.023445
4	0.516458	0.168297	0.018919	0.265372	0.026504
5	0.487329	0.277886	0.067838	0.278317	0.030581
6	0.388290	0.052838	0.005946	0.310680	0.039755
7	0.743664	0.362035	0.034054	0.197411	0.008155
8	0.592193	0.207436	0.025946	0.268608	0.027523

表2 部分稀疏数据

Id	高风险	肿瘤转移	转移部位高危	深静脉血栓史	放疗
1	0	1	0	0	0
2	0	0	0	0	0
3	1	1	0	0	0
4	0	1	0	1	0
5	1	0	0	0	0
6	0	0	0	0	0
7	1	1	0	0	1
8	0	1	0	0	1

针对这种稀疏数据,采用基于深度神经网络的DeepFM模型. DeepFM是一种集成了深度神经网络和FM模型的方法,能够进行稀疏数据的特征组合^[8],避免过拟合情况. XGBoost模型同为线性分类器,能够在目标函数的定义中添加正则化项^[9],具有较好的稀疏感知能力,适用于本PICC相关性血栓临床医学数据. 通过将DeepFM和XGBoost进行模型融合,不仅能够对本数据集具有可解释性,还能够具有更好的模型效果,融合模型能够保持较高准确性的情况下指导临床识别血栓高危风险因素,及时对血栓风险进行干预,起到辅助诊断作用.

3.1 DeepFM模型

DeepFM模型是一种继承了深度神经网络和FM模型的方法,能够有效地结合低阶和高阶的数据特征. 通过将同一数据分别输入FM模型和DNN中,并使用Sigmoid进行组合得到预测输出.

$$y = \text{Sigmoid}(y_{\text{fm}}(x) + y_{\text{Dnn}}) \quad (2)$$

其中, $y_{\text{fm}}(x)$ 是FM层的输出, y_{Dnn} 是神经网络层的输出.

FM即因子分解机,于2010年由Rendle^[10]提出,它融合了SVM模型和因子分解法,能够学习到特征之间的相互关系. 特别是处理稀疏数据时, SVM等模型会产生过拟合现象,此时FM能够筛选出合适的特征

组合. FM模型的思想是基于线性回归模型^[11],一般的线性模型可表示为:

$$y = w_0 + \sum_i^n w_i x_i \quad (3)$$

而基于FM的特征融合模型在线性模型上考虑到了特征之间的关联性. 以二阶度量为例,此时FM线性模型可表示为:

$$y_{\text{fm}}(x) = w_0 + \sum_i^n w_i x_i + \sum_i^{n-1} w' x_i x_{i+1} \quad (4)$$

其中, n 表示总项数, w_0 表示偏置参数, w_i 表示第 i 项的权重, x_i 表示第 i 项的值, w' 表示第 i 项与第 $i+1$ 项之间的关系进行建模.

$$w' = \sum_{f=1}^k V_{i,f} \cdot V_{i+1,f} \quad (5)$$

其中, f 表示 $[1, k]$ 个变量参数, $V_{i,f} \cdot V_{i+1,f}$ 表示系数矩阵 V 中第 i 和第 $i+1$ 维向量的点积.

Deep组件是一种深度神经网络,能够发挥深度神经网络的特性进行高阶稀疏数据的学习^[12].

嵌入层 e_1 的结构如图1所示,假设其神经元数目 $k=3$, $V_{i,f}$ 为FM层中潜在的特征向量,将其作为网络训练权重,则每个输入只有一个神经元有效,其值为1. 通过结合FM层的特征向量 $V_{i,f}$ 作为网络权重输入至深度神经网络,实现了一个端到端的模型. 嵌入层的输出表示为:

$$\text{Output} = a^l = [e_1, e_2, \dots, e_m] \quad (6)$$




图1 嵌入层结构

然后将其输入到深度神经网络,可表示为:

$$a^{l+1} = \sigma(w^l \times a^l + b^l) \quad (7)$$

其中, a^{l+1} 为下一层的输出值, σ 为激活函数, w^l 、 a^l 和 b^l 分别为层数为 l 的权重、输出和偏差项. 则最终预测输出 y_{Dnn} 为:

$$y_{Dnn} = \sigma(w^{L+1} \times a^{L+1} + b^{L+1}) \quad (8)$$

3.2 XGBoost 模型

XGBoost 是基于梯度下降树 GBDT 的机器学习方法, XGBoost 是具有回归树结构^[13], 其决策规则与决策树相同, 内部节点代表着预测的贡献值, 叶子结点代表着预测分数, 最终的预测结果是所有树的预测之和。

首先定义目标函数 Obj , 目标函数 Obj 由损失函数和正则项组成。

$$Obj = Loss + \sum_{n=1}^t \Omega(f_n) \quad (9)$$

其中, $Loss$ 是真实值 y_i 与预测值 \hat{y}_i 之间的损失函数, m 为样本数量, 其计算公式如式 (10):

$$Loss = - \sum_{n=1}^m y_i \log \hat{y}_i \quad (10)$$

$\Omega(f_n)$ 是抑制每棵树复杂度的正则项, 其计算公式如下:

$$\Omega(f_n) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (11)$$

其中, γ 和 λ 为常数项系数, T 为总叶子结点的数目, w_j 为每个叶子结点预测的分数, 则最终预测输出 \hat{y} :

$$\hat{y} = \sum_{n=1}^m f_n(x_i) \quad (12)$$

其中, x_i 是第 i 次训练的样本, $f_m(x_i)$ 是第 n 棵树的训练分数。

3.3 模型融合

本 PICC 血栓预测模型是基于 DeepFM 和 XGBoost 的融合模型, 首先构建 DeepFM 模型, 利用模型对线性模型的记忆能力和对深度神经网络的学习泛化能力的特点对数据进行训练并预测。在训练过程中通过优化其学习率、神经元保留比率等参数使得模型效果达到最优; 然后构建 XGBoost 模型, 通过调整正则化项等参数优化模型效果; 最后进行模型融合, 使用单一模型 DeepFM 和 XGBoost 在测试集上进行血栓概率预测得到 P_d 和 P_x , 将两个模型预测血栓概率值进行加权求和获得融合模型血栓预测概率 P_{new} 。

$$P_{new,i} = 0.6 \times P_{d,i} + 0.4 \times P_{x,i} \quad (13)$$

其中, $P_{new,i}$ 为融合模型获得的第 i 个测试样本的血栓预测概率, $P_{d,i}$ 和 $P_{x,i}$ 表示分别使用 DeepFM 和 XGBoost 对第 i 个测试样本的血栓预测概率。结合判定指标和预

先设定的概率阈值判断血栓发生情况。

$$\begin{cases} \text{血栓} = 1, P_{new} \geq P_{set} \\ \text{血栓} = 0, P_{new} < P_{set} \end{cases} \quad (14)$$

其中, P_{set} 为试验后确定的血栓患病概率阈值。

使用上述判定指标获得模型融合后的患者血栓预测情况, 将其与训练真实值进行对比获得模型评价指标。实验结果表明, 融合模型相比较 DeepFM 和 XGBoost 单一模型在效果上均获得有效提升。

4 模型实现流程

对采集的数据集进行预处理, 填补缺失值和统一量纲, 在处理后的数据样本中随机抽取 80% 作为训练集, 20% 作为测试集, 分别输入 DeepFM 和 XGBoost 并进行模型融合。

4.1 模型评价

融合模型目的是预测 PICC 相关性血栓的发生风险概率。选取精确率、F1 指标和 AUC 来评价模型效果。在一个二分类问题中, 如果一个实例是正类, 且被预测为正类, 就是真正类 (TP); 如果是负类, 被预测为正类, 为假正类 (FP); 如果一个类是真负类被预测成负类, 称为真负类 (TN); 如果一个真正类被预测为负类, 称为假负类 (FN)。

精确率 (Acc) 为预测的正例的总数和总样本之比, 计算公式为:

$$Acc = \frac{TP + TN}{TP + FN + FP + TN} \quad (15)$$

F1 是一种综合评价模型指标, 能够有效地展示精确率和召回率的情况, 计算公式为:

$$F1 = \frac{2TP}{2TP + FN + FP} \quad (16)$$

ROC 针对的是二分类模型^[14], 即输出结果只有两类。ROC 曲线的 x 轴和 y 轴分别为假正类 (FP) 的概率和真正类 (TP) 的概率。AUC 是 ROC 曲线与 x 轴围成的面积^[15], 随机挑选一个正样本以及一个负样本, AUC 的值则为分类器判定正样本的值高于负样本的概率。能够有效地评价模型的预测性能, 其取值范围一般在 [0.1, 1]。

4.2 模型对比

将 PICC 相关性血栓临床医学数据输入 DNN、DeepFM、XGBoost 以及其融合模型进行训练。经过训练得出 DNN、DeepFM、XGBoost 以及其融合模型的 ROC 曲线如图 2-图 5 所示。

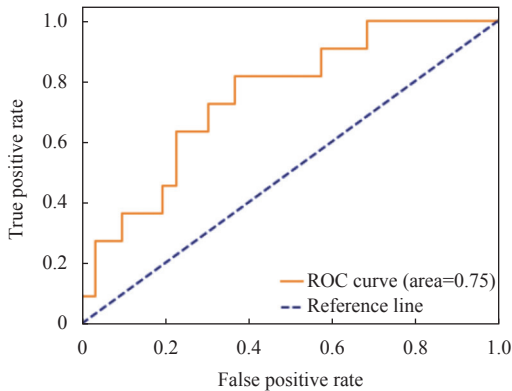


图2 DNN 的 ROC 曲线




图3 DeepFM 的 ROC 曲线

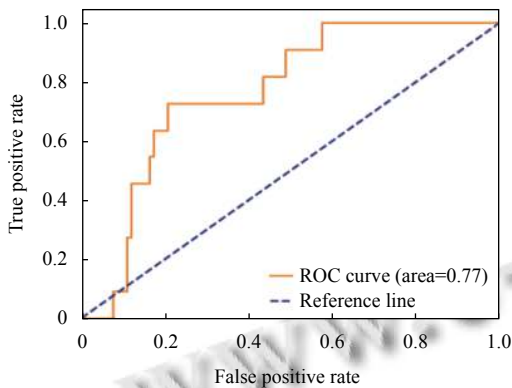


图4 XGBoost 的 ROC 曲线

根据图2和图3对比可以看出单一的深度神经网络DNN在ROC的取值上低于融入深度神经网络和FM模型方法的DeepFM模型,因此证明DeepFM模型能够有效地解决过拟合问题。

根据ROC曲线可得,基于DeepFM和XGBoost的融合模型在利用PICC相关性血栓临床医学数据对血栓进行预测能够在20%的假阳率下准确预测出83%的PICC相关性血栓数据,能够为临床置管前提供有效的辅助诊断。

基于DeepFM和XGBoost的融合模型得出的重要性特征图如图6所示。重要性特征图能够展示与PICC相关性血栓有关的特征重要程度^[16],从而辅助临床医护人员判断哪些特征对PICC相关性血栓产生更显著的影响。如图6所示,其中尖端是否最佳位置、转移部位高危、深静脉血栓史、急性感染等影响因素为模型所得重要特征,与医学先验资料相符。由于影响PICC相关性血栓的特征较多,导致临床医护人员很难从众多病人数据中找到重要的影响因素,因此可以结合本融合模型所得的特征重要性,更加关注病人重要信息来提前采取预防措施和干预手段,降低血栓对患者的影响。




图5 DeepFM 和 XGBoost 融合模型 ROC 曲线




图6 特征重要性

根据实验结果和ROC曲线得出模型精确率、F1指标和AUC对比如表4所示。

表3 模型精确率、F1和AUC指标对比

模型	精确率	F1	AUC
DeepFM	0.88362	0.80583	0.80
XGBoost	0.88349	0.76670	0.77
DeepFM+XGBoost	0.90291	0.82524	0.82

从表4可以看出,针对PICC血栓预测融合模型,其精确率、F1指标和AUC均高于单个机器学习和深度神经网络模型。融合模型在精确率上比DeepFM和XGBoost分别高出了1.929%和1.942%,在F1指标上

比 DeepFM 和 XGBoost 分别高出了 1.941% 和 5.854%，在 AUC 上比 DeepFM 和 XGBoost 分别高出了 3% 和 5%，在模型效果上均有显著提升。

由上述模型评价指标可知，基于 DeepFM 和 XGBoost 的融合模型相比较单一模型得到了最优的效果，证明模型融合的合理性和有效性，因此可以使用基于 DeepFM 和 XGBoost 的融合模型进行 PICC 相关血栓风险的预测与评估，有利于医护人员对血栓高风险患者进行及时干预，最大化降低患者由于置管血栓所造成的影响。

5 结论

本文是一种基于 DeepFM 和 XGBoost 的融合模型，使用了机器学习和深度神经网络结合的方法对外周穿刺置入中心静脉导管 (PICC) 置管血栓进行风险预测。通过从患者入院检查数据中进行选取有效特征，分别输入 DeepFM 和 XGBoost 模型进行训练，然后使用模型融合方法对模型效果进行优化。

实验结果表明，基于 DeepFM 和 XGBoost 的融合模型在模型评价指标和效果上均优于单一模型，证明了融合模型的可行性。本 PICC 血栓预测模型能够帮助临床在置管前对患者进行血栓风险预测，对较大血栓风险的患者提早进行药物或者物理干预，最大化减小血栓对患者本身所带来的影响，在 PICC 置管血栓领域具有重要意义。

参考文献

- 1 Abdullah BJJ, Mohammad N, Sangkar JV, *et al.* Incidence of upper limb venous thrombosis associated with peripherally inserted central catheters (PICC). *The British Journal of Radiology*, 2005, 78(931): 581–676. [doi: [10.1259/bjr/37038966](https://doi.org/10.1259/bjr/37038966)]
- 2 Loewenthal MR, Dobson PM, Starkey RE, *et al.* The peripherally inserted central catheter (PICC): A prospective study of its natural history after cubital fossa insertion. *Anaesthesia and Intensive Care*, 2002, 30(1): 21–24. [doi: [10.1177/0310057X0203000103](https://doi.org/10.1177/0310057X0203000103)]
- 3 Nafee T, Gibson CM, Travis R, *et al.* Machine learning to predict venous thrombosis in acutely ill medical patients. *Research and Practice in Thrombosis and Haemostasis*, 2020, 4(2): 230–237. [doi: [10.1002/rth2.12292](https://doi.org/10.1002/rth2.12292)]
- 4 Ryan L, Mataraso S, Siefkas A, *et al.* A machine learning approach to predict deep venous thrombosis among hospitalized patients. *Clinical and Applied Thrombosis/Hemostasis*, 2021, 27: 1–4.
- 5 Liu SS, Zhang FY, Xie LL, *et al.* Machine learning approaches for risk assessment of peripherally inserted central catheter-related vein thrombosis in hospitalized patients with cancer. *International Journal of Medical Informatics*, 2019, 129: 175–183. [doi: [10.1016/j.ijmedinf.2019.06.001](https://doi.org/10.1016/j.ijmedinf.2019.06.001)]
- 6 Sukperm A, Rojnuckarin P, Akkawatt B, *et al.* Automatic diagnosis of venous thromboembolism risk based on machine learning. *Proceedings of 2021 IEEE International IoT, Electronics and Mechatronics Conference (IEMTRONICS)*. Toronto: IEEE, 2021. 1–4.
- 7 Jo JM. Effectiveness of normalization pre-processing of big data to the machine learning performance. *The Journal of the Korea Institute of Electronic Communication Sciences*, 2019, 14(3): 547–552.
- 8 Guo HF, Tang RM, Ye YM, *et al.* DeepFM: A factorization-machine based neural network for CTR prediction. *Proceedings of the 26th International Joint Conference on Artificial Intelligence*. Melbourne: AAAI Press, 2017. 1725–1731.
- 9 Luckner M, Topolski B, Mazurek M. Application of XGBoost algorithm in fingerprinting localisation task. *Proceedings of the 16th IFIP TC8 International Conference on Computer Information Systems and Industrial Management*. Bialystok: Springer, 2017. 661–671.
- 10 Rendle S. Factorization machines. *Proceedings of 2010 IEEE International Conference on Data Mining*. Sydney: IEEE, 2010. 995–1000.
- 11 罗逸伦. 基于 FM&ResNet 模型的点击率预测研究. *数字技术与应用*, 2021, 39(3): 226–228.
- 12 Yu ZC, Amin SU, Alhussein M, *et al.* Research on disease prediction based on improved DeepFM and IoMT. *IEEE Access*, 2021, 9: 39043–39054. [doi: [10.1109/ACCESS.2021.3062687](https://doi.org/10.1109/ACCESS.2021.3062687)]
- 13 Pan BY. Application of XGBoost algorithm in hourly PM_{2.5} concentration prediction. *IOP Conference Series: Earth and Environmental Science*, 2018, 113(1): 012127.
- 14 Fawcett T. An introduction to ROC analysis. *Pattern Recognition Letters*, 2006, 27(8): 861–874. [doi: [10.1016/j.patrec.2005.10.010](https://doi.org/10.1016/j.patrec.2005.10.010)]
- 15 Florkowski CM. Sensitivity, specificity, receiver-operating characteristic (ROC) curves and likelihood ratios: Communicating the performance of diagnostic tests. *The Clinical Biochemist Reviews*, 2008, 29(S1): S83–S87.
- 16 周彤彤, 俞凯, 袁贞明, 等. 基于 LSTM 与 XGBoost 混合模型的孕妇产后出血预测. *计算机系统应用*, 2020, 29(3): 148–154. [doi: [10.15888/j.cnki.csa.007316](https://doi.org/10.15888/j.cnki.csa.007316)]

(校对责编: 牛欣悦)