

# 基于宽度学习算法的加权集成成绩预测模型

吴玉凤,冯 军,钱亚冠,金 帆

(浙江科技学院 理学院,杭州 310023)

**摘 要:** 教育数据挖掘技术是当前研究的热点之一。针对学生成绩预测准确率较低的问题,提出以宽度学习(broad learning, BL)算法为个体学习器的加权集成学习算法。首先,使用宽度学习算法来预测学生成绩,由于单个分类器的性能不够稳定,对数据变化比较敏感,故试验采用加权集成方法对宽度学习算法进行改进;然后,将其与采用加权集成的决策树(decision tree, DT)算法和多层感知机神经网络(multi-layer perceptron neural networks, MLP)算法的结果进行对比。结果表明,基于宽度学习算法作为个体学习器的加权集成算法能够进一步提高模型的预测效果,预测准确率在比较的几种算法中最高,达到了91.6%,这有效地提高了成绩预测的准确率。研究结果可为学生成绩预测提供方法参考。

**关键词:** 教育数据挖掘;宽度学习算法;加权集成;成绩预测

**中图分类号:** TP312.8;G424.7      **文献标志码:** A      **文章编号:** 1671-8798(2021)05-0362-07

## Weighted ensemble achievement prediction model based on broad learning algorithm

WU Yufeng, FENG Jun, QIAN Yaguan, JIN Fan

(School of Sciences, Zhejiang University of Science and Technology, Hangzhou 310023, Zhejiang, China)

**Abstract:** Educational data mining technology is one of the hot topics in current research. In response to low accuracy of student achievement prediction, a weighted ensemble learning algorithm was proposed on the basis of broad learning (BL) algorithm. First, the broad learning algorithm was used to predict students' scores. Given the unstable performance and sensitivity to data changes of a single classifier, the weighted ensemble method was adopted to improve the broad learning algorithm. Then, the results were compared with those of weighted ensemble decision tree (DT) algorithm and multi-layer perceptron neural networks (MLP) algorithm. The results show that the weighted ensemble algorithm based on the broad learning algorithm as an individual learner can further boost the prediction effect of the model, and the

**收稿日期:** 2020-10-27

**基金项目:** 浙江省高等教育“十三五”第一批教学改革研究项目(jg20180223)

**通信作者:** 冯 军(1963—),男,浙江省海盐人,研究员,主要从事教育、教学管理的相关研究。E-mail:101006@zust.edu.cn。

prediction accuracy is the highest among the several algorithms compared, reaching 91.6%, which effectively improves the accuracy of achievement prediction. The research results can provide an effective method for students' achievement prediction.

**Keywords:** educational data mining; broad learning algorithm; weighted ensemble learning; achievement prediction

教育数据挖掘(educational data mining, EDM)是一个新兴的跨学科的研究领域。它利用机器学习、统计学和数据挖掘技术对教育数据进行分析 and 处理,从而提高学习者的学习效率,更好地让教师了解学生及其学习环境。对学生成绩预测是教育数据挖掘领域的热门研究课题。常用的数据挖掘分类算法有决策树(decision tree, DT)<sup>[1]</sup>、神经网络(neural network, NN)<sup>[2]</sup>、朴素贝叶斯<sup>[3]</sup>(naive Bayes, NB)、逻辑回归<sup>[4]</sup>(logistic regression, LR)、支持向量机<sup>[5]</sup>(support vector machine, SVM)等算法。Ma 等<sup>[6]</sup>使用支持向量机算法和网格搜索优化的决策树算法来预测学生成绩,并利用信息增益找出对学生成绩影响较大的因素,于是可利用该模型来识别与学生成绩有关的重要特征和学生考试通过率。Rubiano 等<sup>[7]</sup>利用数据挖掘工具 Weka 中的 3 种分类器 J48、PART、RIPOR 对 932 名系统工程专业学生的成绩进行预测,发现 J48 分类器的预测准确率较高。Costa 等<sup>[8]</sup>使用决策树、支持向量机、神经网络和朴素贝叶斯等算法对学生成绩是否合格进行预测,结果表明支持向量机算法的预测结果优于其他算法结果。Yang 等<sup>[9]</sup>通过建立包含成绩相关属性和非相关属性的学生属性矩阵,对学生属性进行量化,应用反向传播神经网络算法来预估学生成绩,并找出了影响学生成绩的关键因素。施俊等<sup>[10]</sup>使用聚类分析和关联方法对学生在线学习过程中的数据进行分析,使用聚类分析对学生进行分类,教师可以根据分类结果对学生采取不同形式的监管,使用关联规则了解学生学习属性和学习成绩之间的关联。在文献[11-14]中,研究者们使用从 Kalboard 360 E-Learning 系统收集的学业成绩数据集,利用决策树、神经网络、朴素贝叶斯等算法验证了:学生学习过程中家长参与度、学生参加课程频次和学生行为特征(举手发言、查看公告、访问课程资源和讨论)对学生成绩有很大的影响。他们使用预测学习成绩的模型评价指标值在 70%~80%之间,其中,文献[14]使用集成学习构建学生成绩预测模型,然后对集成的模型进一步嵌套集成,提升了分类预测模型的性能,但也仅为 79.2%。由此可见,这些模型的效果还有较大的提升空间。

通过文献分析,我们发现有很多研究者建立了学生成绩预测模型,但是大多数研究是从理论层面分析来建立学业成绩评估模型,所建立的模型预测准确率不够高,推测其可能的原因如下:一是使用的算法不同,不同的算法对学生数据的训练效果是不同的,即使使用同一份数据也可能由于研究者的偏好或模型参数的不同而导致模型的效果不同;二是特征选择不同,选择不同的属性子集会对学生成绩预测产生不同的结果,应该尽量选择与学生成绩有关的特征,并且特征之间最好不要相互影响。针对上述研究存在的不足,本试验首先采用数据驱动的建模方法,在包含 16 名学生属性的数据集中以模型的预测准确率作为特征子集选择的标准,采用排列组合的方式找出影响学生成绩的因素,充分利用了学生数据的有效信息。然后,针对这些有效属性,采用宽度学习(broad learning, BL)算法进行成绩预测。该算法具有步骤少、结构简单和学习速度比较快等优点,弥补了深度学习算法由于需要计算大量隐层权值所造成的训练时间过长的缺陷,与深度神经网络算法相比容易获得全局最优解,具有良好的泛化性能<sup>[15-16]</sup>。最后,在训练好的算法上进行加权集成来构建学生成绩预测模型,以克服单个分类器性能不够稳定,对数据变化比较敏感的缺点。

## 1 数据来源及数据预处理

### 1.1 数据来源和数据特征

本研究使用从 Kalboard 360 E-Learning 系统收集的约旦大学学生成绩数据集<sup>[17]</sup>。它是通过电子管理系统收集的学习者活动数据,该数据集的属性及其类别特征见表 1。

表 1 学业成绩数据集的属性及其类别特征

Table 1 Attributes of academic achievement data set and its category characteristics

属性	属性描述	类别特征
性别①	男,女	人口统计学特征
国籍②	科威特,黎巴嫩,埃及,沙特阿拉伯,美国,约旦等	
出生地③	科威特,黎巴嫩,埃及,沙特阿拉伯,美国,约旦等	
学习主要由谁负责④	父亲,母亲	
受教育水平⑤	小学,初中,高中	学术背景特征
年级⑥	1~12 年级	
教室编号⑦	A,B,C	
学期⑧	F(第 1 学期),S(第 2 学期)	
学习科目⑨	英语,西班牙语,法语,信息技术,数学,化学,生物等	
学生缺课数/d⑩	≤7,>7	
父母是否完成调查问卷⑪	是,否	学习者父母参与特征
父母对学校的满意程度⑫	好,差	
参与讨论组次数⑬	0~100	行为特征
浏览教学资源次数⑭	0~100	
课堂举手次数⑮	0~100	
查看通知次数⑯	0~100	

1.2 数据预处理

数据预处理是研究过程的重要步骤,通过预处理可以提高数据集的质量。数据预处理包含数据清理、数据集成、数据规约和数据变换。数据清理主要处理数据的各种异常情况,包括删除重复信息与纠正错误信息。数据集最初收集了 500 条数据,在删除重复数据和缺失数据并清理异常数据后,数据变成了 480 条。数据归约是通过精简数据尽可能多地保留原数据中的有效信息,即对数据进行特征选择,其理想方法是将数据集中所有可能的属性子集作为算法的输入,然后选择能使算法预测准确率最高的子集作为特征选择的结果<sup>[14]</sup>。本试验对数据属性所有可能的子集进行遍历,分别使用决策树、多层感知机神经网络和宽度学习算法等模型进行训练,每种模型经过训练得到 3 个效果最好的基分类器。其中,以宽度学习算法训练得到的 3 个基分类器属性子集标号分别为:①②③⑤⑧⑨⑩⑪⑬⑮,①②⑤⑥⑩⑪⑬⑭,①②③⑤⑥⑩⑪⑫⑭⑮⑯。数据变换是通过改变数据的特征以方便计算和发现新的信息,主要是对数据进行标准化和离散化。标准化处理的是连续型变量,使处理后的数据在[0,1]区间,服从正态分布。对非数值型数据进行标准化是指对分类型特征进行编码,即对不连续的数值进行编码,如将教育水平属性值小学、初中、高中分别标准化为 1、2、3。离散化主要是根据学生的分数,将学生成绩分为 3 个等级:低级(L),0~69;中级(M),70~89;高级(H),90~100。通过数据预处理得到了标准化的数据,然后利用处理好的数据进行训练。

2 预测算法与试验设计

2.1 预测算法

本研究主要根据学生成绩数据集对学生学期结束时的成绩进行预测,通过标记的类别数据对处理好的数据集进行训练,并将宽度学习算法和集成学习算法相结合,建立了学生成绩预测模型。

2.1.1 宽度学习算法

宽度学习算法<sup>[18]</sup>最开始是作为深度学习算法的替代方法提出的,是一种基于随机向量函数的算法。宽度学习算法首先将输入数据映射成特征节点矩阵,经过增强变换形成增强节点矩阵,由特征映射节点和增强节点共同作为隐含层的输入,利用伪逆求解隐含层与输出层之间的权重矩阵。当特征映射节点和增强节点的数目无法满足任务需求时,宽度学习算法使用增量学习的方式动态调整网络结构,实现快速

重新训练。假设算法的训练集输入为  $\mathbf{X}$ , 包含  $A$  个训练样本, 每个样本有  $B$  个属性, 训练集的标签类别为  $M$  种, 则算法的具体过程如下:

首先, 将输入数据  $\mathbf{X}$  映射成特征节点矩阵。训练集  $\mathbf{X}$  经过第  $i$  组特征映射得到第  $i$  组特征节点矩阵

$$\mathbf{Z}_i = \varphi_i(\mathbf{X}_{AB} \mathbf{W}_{e_i} + \boldsymbol{\beta}_{e_i}). \quad (1)$$

式(1)中:  $\mathbf{W}_{e_i}$  为第  $i$  组特征映射权重矩阵;  $\boldsymbol{\beta}_{e_i}$  为第  $i$  组特征映射偏置矩阵。

然后, 根据特征节点矩阵得到增强节点矩阵。前  $i$  组特征节点矩阵  $\mathbf{Z}_i$  经过第  $j$  组增强映射得到第  $j$  组增强节点矩阵

$$\mathbf{H}_j = \xi_j(\mathbf{Z}^i \mathbf{W}_{h_j} + \boldsymbol{\beta}_{h_j}). \quad (2)$$

式(2)中:  $\mathbf{W}_{h_j}$  为第  $j$  组增强映射权重矩阵;  $\boldsymbol{\beta}_{h_j}$  为第  $j$  组增强映射偏置矩阵;  $\mathbf{Z}^i = [\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_i]$  表示前  $i$  组特征节点矩阵的连接;  $\mathbf{W}_{e_i}$ 、 $\boldsymbol{\beta}_{e_i}$ 、 $\mathbf{W}_{h_j}$ 、 $\boldsymbol{\beta}_{h_j}$  均为随机初始矩阵, 且当  $\mathbf{W}_{h_j}$  中的  $j$  取不同值时  $\mathbf{W}_{h_j}$  相互正交。

于是, 宽度学习算法可表示为:

$$\begin{aligned} \mathbf{Y} &= [\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_n | \xi_1(\mathbf{Z}^n \mathbf{W}_{h_1} + \boldsymbol{\beta}_{h_1}), \dots, \xi_j(\mathbf{Z}^n \mathbf{W}_{h_m} + \boldsymbol{\beta}_{h_m})] \mathbf{W}^m = \\ &[\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_n | \mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_m] \mathbf{W}^m = [\mathbf{Z}^n | \mathbf{H}^m] \mathbf{W}^m. \end{aligned} \quad (3)$$

式(3)中:  $\mathbf{W}^m$  为特征节点和增强节点到输出层的权重矩阵, 即我们要求的权值矩阵, 它是由  $[\mathbf{Z}^n | \mathbf{H}^m]$  的伪逆推导出来的, 即  $\mathbf{W}^m = [\mathbf{Z}^n | \mathbf{H}^m]^+ \mathbf{Y}$ , 其中  $[\mathbf{Z}^n | \mathbf{H}^m]^+$  可以使用伪逆岭回归近似算法求得:

$$[\mathbf{Z}^n | \mathbf{H}^m]^+ = \lim_{\lambda \rightarrow 0} (\lambda \mathbf{I} + [\mathbf{Z}^n | \mathbf{H}^m][\mathbf{Z}^n | \mathbf{H}^m]^T)^{-1} [\mathbf{Z}^n | \mathbf{H}^m]^T. \quad (4)$$

式(4)中:  $\lambda$  是常规的  $L_2$  范数正则化;  $\mathbf{I}$  为单位矩阵。训练好  $\mathbf{W}^m$  之后, 测试集的测试值可由式(5)得到:

$$\mathbf{Y} = [\mathbf{Z}^n | \mathbf{H}^m] \mathbf{W}^m. \quad (5)$$

由于初始设计的模型拟合能力不足, 需要增加增强节点数量来减小损失函数。我们把增加一组增强节点之后的特征节点和增强节点到输出层的权重矩阵记为  $\mathbf{W}^{m+1}$ , 令  $\mathbf{A}^m = [\mathbf{Z}^n | \mathbf{H}^m]$ , 新的权重可通过式(6)计算得到:

$$\mathbf{W}^{m+1} = \begin{bmatrix} \mathbf{W}^m - \mathbf{B} \mathbf{D}^T \mathbf{Y} \\ \mathbf{B}^T \mathbf{Y} \end{bmatrix}. \quad (6)$$

式(6)中:

$$\mathbf{D} = (\mathbf{A}^m)^+ \xi(\mathbf{Z}^n \mathbf{W}_{h_{m+1}} + \boldsymbol{\beta}_{h_{m+1}}); \quad (7)$$

$$\mathbf{B}^T = \begin{cases} \mathbf{C}^+, \mathbf{C} = 0; \\ (1 + \mathbf{D}^T \mathbf{D})^{-1} \mathbf{B}^T (\mathbf{A}^m)^+, \mathbf{C} \neq 0; \end{cases} \quad (8)$$

$$\mathbf{C} = \xi(\mathbf{Z}^n \mathbf{W}_{h_{m+1}} + \boldsymbol{\beta}_{h_{m+1}}) - \mathbf{A}^m \mathbf{D}. \quad (9)$$

由式(6)可以看出, 宽度学习算法在增加节点时, 仅通过计算相应节点的伪逆就可以求出新的输出权重; 换言之, 即只需计算新插入的增强节点的伪逆即可, 如此可实现快速增量学习。宽度学习算法的更新结构如图1所示。




图1 宽度学习更新结构示意图

Fig. 1 Broad learning update structure diagram

由宽度学习理论可知,宽度学习算法比神经网络结构更简单,可直接通过增加增强节点的方式提升模型性能,不需要重新训练网络。将其引入教育数据挖掘中,有助于在教育大数据提取中获得有意义的规律与模式<sup>[19]</sup>。

### 2.1.2 集成学习

集成学习通过将多个分类器组合来完成学习任务。加权集成学习是一种集成学习方法,本研究中加权集成学习首先使用单个分类器决策树算法、多层感知机神经网络算法和宽度学习算法来建立模型,然后将每种分类器进行训练后得到 3 个模型,最后对 3 个模型的结果进行投票得出模型最终的判定类别。这种投票的方式能够获得比单一分类模型泛化性能更强的模型。

## 2.2 试验设计

我们将数据分为两部分,其中,70%的数据作为训练集,30%的数据作为测试集。数据预处理过程结束之后,分别使用决策树、多层感知机神经网络、宽度学习算法训练模型,并且对模型进行调优,得到具有较高预测准确率的模型;然后分别对选出的模型使用加权集成学习构建成绩预测模型。试验环境如下:处理器为 Intel(R) Core(TM) i7-9700,处理器主频为 3.00 GHz,内存为 16.0 GB。试验的软件环境为 Python3.7。在基于宽度学习算法的加权集成模型中,设每个窗口的特征节点数为 20,特征节点窗口数为 20,增强节点数为 300,正则化系数  $C$  取值分别为 32、32、256。

## 3 试验结果与对比分析

### 3.1 单一分类模型之间及其与集成模型之间的性能比较

试验使用决策树、多层感知机神经网络和宽度学习算法,经过特征选择和参数调整得到了 3 种分类器,采用加权集成方法对 3 种分类器分别进行训练和测试,得到模型的预测准确率如图 2 所示。为了评估学生成绩预测模型的性能,本研究使用了 3 个评价指标:准确率  $P$ 、召回率  $R$ 、 $F_1$  值。

由图 2 可知,经过数据预处理和模型调优,决策树算法预测准确率为 76.6%;多层感知机神经网络算法的预测准确率较高,为 85.8%;宽度学习算法的预测准确率最高,达到了 89.1%。加权集成学习之后,模型的预测准确率有所提升,其中,决策树模型的性能提升最明显,预测准确率提高了 10 个百分点;多层感知机神经网络模型的预测准确率没有提高,其原因可能是训练




图 2 模型预测准确率对比

Fig. 2 Comparison of model prediction accuracy

的多层感知机神经网络模型具有相似性;宽度学习模型的预测准确率提高了 2.5 个百分点,达到了 91.6%。因此,我们可以看出加权集成学习可以有效提高模型的性能。之后,本试验使用加权集成学习对成绩类别为 H、M、L 的数据分别进行训练,得到的模型效果如图 3 所示。

使用加权集成学习之后对学生成绩各个类别进行测试,得到宽度学习算法集成之后的  $F_1$  最高,分别为 88.5%、90.3%、96.9%,表明基于宽度学习算法的加权集成成绩预测模型效果较好,而且该模型对学生成绩类别为低的学生精确率、召回率、 $F_1$  值最高,均为 96.9%。这符合模型的设计初衷,即找出哪些学生最可能不及格,从而对这类学生进行学习预警,并采取有针对性的措施来帮助学业成绩差的学生提高考试通过率。




图3 加权集成模型效果

Fig. 3 Diagram of weighted ensemble model effects

### 3.2 与前人研究性能对比

我们从准确率  $P$ 、召回率  $R$ 、 $F_1$  值三方面与其他研究者的试验结果进行对比,结果见表2。

从表2可以很明显地看出,在使用同一份学生数据集的情况下,本研究建立的模型预测效果比之前其他研究者的模型高出十几个百分点。之前研究者采用传统的机器学习算法或集成学习的方法,模型的评价指标值大致在70%~80%之间。本试验由于采用数据驱动的方法,在挑出最优属性子集的前提下,使用具有网络结构且善于进行参数更新的宽度学习算法进行集成学习,预测准确率达到91.6%,这验证了模型的有效性。

表2 模型效果对比

Table 2 Comparison of model effects %

模型	$P$	$R$	$F_1$
Sana 等 <sup>[11]</sup>	78.6	78.9	78.7
Amrieh 等 <sup>[12]</sup>	73.9	73.8	73.2
Amrieh 等 <sup>[13]</sup>	79.1	79.2	79.1
陈子健等 <sup>[14]</sup>	79.2	79.2	79.2
本试验模型	91.6	91.6	91.6

## 4 结 语

本研究将宽度学习算法和集成学习算法相结合,建立了学生成绩预测模型。为了验证模型的有效性,我们采用两种对比方式,一方面使用同样的数据处理方式建立了基于决策树、神经网络、宽度学习算法的集成学习算法,试验结果表明后者效果最好;另一方面,在使用相同数据集和相同模型的情况下,本文建立的模型预测效果也比之前研究者的模型效果好。这表明本研究提出的基于宽度学习算法的加权投票成绩预测模型,能够有效逼近学生特征属性与学生成绩之间的非线性关系。本研究可供教育工作者利用这一模型了解学生,以帮助学生改善学习过程,降低学习失败率,同时也可以帮助管理者提高管理效率。

### 参考文献:

- [1] KEORGIOS G, LIPITAKIS A D, KOTSIANTIS S, et al. Predicting student performance in distance higher education using active learning[C]//International Conference on Engineering Applications of Neural Networks. Cham: Springer, 2017: 75.
- [2] KAUR P, SINGH M, JOSAN G S. Classification and prediction based data mining algorithms to predict slow learners in education sector[J]. Procedia Computer Science, 2015, 57: 500.
- [3] HAN J, KAMBER M. Data mining: concepts and techniques[M]. Netherlands: Elsevier, 2011.
- [4] NG A Y, JORDAN M I. On discriminative vs. generative classifiers: a comparison of logistic regression and naive bayes[C]//Advances in Neural Information Processing Systems. San Mateo, CA: Morgan Kaufmann Publishers Inc, 2002: 841.

- [5] SUYKENS J, VANDEWALLE J. Least squares support vector machine classifiers[M]. Netherlands: Kluwer Academic Publishers,1999.
- [6] MA X F, ZHOU Z R. Student pass rates prediction using optimized support vector machine and decision tree[C]//2018 IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC). Nevada: IEEE,2018:209.
- [7] RUBIANO S, GARCIA J. Analysis of data mining techniques for constructing a predictive model for academic performance[J]. IEEE Latin America Transactions,2016,14(6):2783.
- [8] COSTA E, FONSECA B, SANTANA M, et al. Evaluating the effectiveness of educational data mining techniques for early prediction of students' academic failure in introductory programming courses[J]. Computers in Human Behavior,2017,73:247.
- [9] YANG F, LI F W B. Study on student performance estimation, student progress analysis, and student potential prediction based on data mining[J]. Computers and Education,2018,123:97.
- [10] 施伦,钱源,孙玲. 基于教育数据挖掘的网络学习过程监管研究[J]. 现代教育技术,2016,26(6):87.
- [11] SANA B, SIDDIQUI I F, ARAIN Q A. Analyzing students' academic performance through educational data mining[J]. Open Journal Systems,2019:402.
- [12] AMRIEH E A, HAMTINI T, ALJARAHI I. Preprocessing and analyzing educational data set using X-API for improving student's performance [C]//2015 IEEE Jordan Conference on Applied Electrical Engineering and Computing Technologies (AEECT). Amman: IEEE,2015:1.
- [13] AMRIEH E A, HAMTINI T, ALJARAHI I. Mining educational data to predict student's academic performance using ensemble methods[J]. International Journal of Database Theory and Application,2016,9(8):119.
- [14] 陈子健,朱晓亮. 基于教育数据挖掘的在线学习者学业成绩预测建模研究[J]. 中国电化教育,2017(12):75.
- [15] 郑云飞,陈霸东. 基于最小 $p$ -范数的宽度学习系统[J]. 模式识别与人工智能,2019,32(1):51.
- [16] CHEN C L P, LIU Z L. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture[J]. IEEE Transactions on Neural Networks and Learning Systems,2017,29(1):10.
- [17] IBRAHIM A. Kalboard360-E-learning system[EB/OL]. (2016-02-28)[2021-09-27]. <https://www.kaggle.com/aljarah>.
- [18] CHEN C L P, LIU Z L. Broad learning system: structural extensions on single-layer and multi-layer neural networks[C]//2017 International Conference on Security, Pattern Analysis, and Cybernetics (SPAC). New York: IEEE,2018.
- [19] 袁利平,陈川南. 宽度学习的教育价值及其意义[J]. 中国电化教育,2019(5):34.

~~~~~

(上接第 361 页)

- [18] 颜康康,淮明生. 灰色 GM(1,1)模型在我国医疗费用预测研究中的应用[J]. 医学与社会,2018,31(8):37.
- [19] 刘思峰,党耀国,方志耕,等. 灰色系统理论及其应用[M]. 3 版. 北京:科学出版社,2004.
- [20] 高洪洋,胡小平,王彦方. 中国农村居民医疗保健支出的影响因素[J]. 财经科学,2016(2):82.
- [21] 郑焱. 我国城镇居民医疗保健支出的影响因素分析[J]. 现代经济信息,2019(9):10.
- [22] 唐齐鸣,项乐. 中国居民医疗保健支出的影响因素及区域差异性研究[J]. 金融研究,2014(1):85.
- [23] 饶晓辉,栾佳蓉. 老龄化形势下我国农民医疗保健支出的影响因素研究[J]. 江西社会科学,2015,35(2):197.
- [24] 阜阳市统计局. 统计年鉴[EB/OL]. [2020-09-17]. <http://tjj.fy.gov.cn/content/channel/5c37f7bdc9a5286c0a89697c/>.