

# 建设工程总承包项目概算精细化管控研究

卢毅 于迪尔<sup>(通讯作者)</sup>

南京审计大学工程审计学院 江苏 南京 211815

**【摘要】**：针对工程总承包（EPC）项目前期投资概算不确定性高、传统线性模型精度不足的现状，本研究提出一种基于集成学习算法的工程量指标预测框架。选取 2018 至 2023 年间竣工的 98 个高校宿舍楼 EPC 项目为样本，构建包含 17 项特征指标的体系。对比分析随机森林（RF）、梯度提升决策树（GBDT）与 BP 神经网络在 32 项核心指标上的预测效能。实证显示，三种模型决定系数均突破 0.97。其中 BP 神经网络精度微幅领先，但存在“黑箱”局限；而集成学习模型在保持高精度的同时，能有效揭示总建筑面积、结构类型等因素的驱动作用。研究证明，该模型能为限额设计提供透明决策支撑，具有显著应用价值。

**【关键词】**：工程总承包项目；工程量预测；集成学习；投资概算

DOI:10.12417/3083-5526.25.06.015

## 1 引言

随着《“十四五”建筑业发展规划》的深入实施，中国建筑业正处于从规模扩张向高质量增长的关键转型期。规划明确提出，需通过数字化转型与深化工程造价改革，全面提升行业效益与核心竞争力。工程总承包（EPC）模式凭借其设计、采购、施工深度融合的优势，成为推动行业变革的重要抓手。在 EPC 模式下，打破传统条块分割的管理体制，实现全产业链的一体化协同，对于优化资源配置、缩短工期及降低全过程成本具有重要的战略价值。

尽管 EPC 模式优势显著，但在项目前期决策阶段，往往面临工程信息碎片化、设计深度不足等带来的概算偏差问题<sup>[1]</sup>。研究表明，设计阶段对工程项目投资的影响程度高达 70% 以上，准确的工程量预测是实施限额设计与造价控制的基石。然而，传统预测方法如类比估算法、单方指标法等，往往过度依赖造价工程师的经验判断，难以捕捉建筑特征与分部分项工程量之间复杂的非线性耦合关系，导致概算成果的科学性与客观性受限<sup>[2,3]</sup>。

近年来，机器学习技术为解决复杂非线性预测问题提供了新思路。国内外学者尝试利用 BP 神经网络、支持向量机等算法构建造价预测模型，并取得了一定进展。然而，单一神经网络模型在处理高维小样本数据时，易陷入局部最优解，且由于其内部决策机制不透明，呈现出明显的“黑箱”属性，难以直观解释建筑特征对造价的影响权重。这在工程实践中，往往导致管理人员对模型输出结果的信任度不足。

基于此，本研究提出一种基于集成学习算法的工程量指标预测模型。集成学习通过组合多个弱学习器形成强学习器，具备比单一算法更强的泛化性能与鲁棒性。本文以 98 个典型高校宿舍楼 EPC 项目为样本，构建多维特征评价体系，并在对比

集成学习与 BP 神经网络效能的基础上，重点探究模型的可解释性。研究旨在构建一套精度高、可理解性强的智能概算框架，为 EPC 项目前期的造价精细化管理提供数据支撑与理论依据。

## 2 相关理论基础

### 2.1 集成学习概述

集成学习作为机器学习领域的重要分支，其核心逻辑在于通过构建并结合多个基学习器来完成复杂的预测任务。该理论的根基源于“偏差-方差分解”。在工程造价预测中，泛化误差通常由偏差、方差及噪声三部分组成。根据这一理论，Bagging 类算法如随机森林，主要通过训练样本及特征进行随机扰动，旨在显著减少模型的方差，因此非常适合处理高方差的强学习器。与之相对应，以 GBDT 为代表的 Boosting 类算法则专注于通过逐轮拟合前一轮模型的残差来减小偏差，这种特性使其更适用于优化高偏差的弱学习器。通过这种差异化的组合策略，集成学习能够获得比单一模型更优的泛化能力<sup>[4]</sup>。

### 2.2 随机森林

随机森林是基于 Bagging 策略的典型扩展算法。在实际构建决策树的过程中，它不仅继承了 Bagging 的样本随机性，还进一步引入了随机属性选择机制<sup>[5]</sup>。在基决策树的每个结点点进行划分时，随机森林并非从所有属性中搜寻最优解，而是先随机抽取一个包含 k 个属性的子集，再从中选择最优划分属性。这种双重随机性赋予了模型极强的抗过拟合能力和抗噪性能。对于维度较高且数据特征分布不均的工程量数据，随机森林能够直接处理而无需复杂的预特征选择，同时其输出的特征重要性评价为造价控制提供了必要的可解释性依据。

### 2.3 梯度提升决策树

梯度提升决策树（GBDT）则遵循 Boosting 策略，采用加法模型与前向分步算法进行训练。其核心思想是让每一棵新生

成的树都致力于拟合之前所有树预测结果与真实值之间的残差<sup>[6]</sup>。在处理回归问题时，GBDT 利用损失函数的负梯度作为残差的近似值，通过不断迭代使模型逼近真实分布。这种循序渐进的优化方式使 GBDT 在面对各种异构数据时均能保持极高的预测精度，且由于其对损失函数选择的灵活性，模型在应对工程数据中的异常值时也表现出较强的鲁棒性。

### 2.4 BP 神经网络

BP 神经网络是一种经典的前馈式人工神经网络，其核心机制在于利用误差反向传播法对网络参数进行持续优化<sup>[7]</sup>。该结构通常由输入层、隐含层及输出层构成，神经元之间通过权重连接传递信息。在实际应用中，BP 网络通过前向传播计算误差，再根据梯度下降原则反向调整权重，展现出强大的非线性映射能力。然而，在工程实践中，BP 网络也暴露出易陷入局部最优、收敛缓慢以及因“黑箱效应”导致解释性不足等短板，这在一定程度上限制了其在需要明确决策依据的 EPC 项目概算中的深度应用<sup>[8]</sup>。

## 3 预测指标体系构建与数据预处理

### 3.1 预测指标的选取

本研究的数据样本来源于某指标网工程造价数据库。为了确保实证分析的代表性与可比性，我们筛选了 2018 至 2023 年间竣工的 98 个典型高校宿舍楼 EPC 项目作为研究对象。这些项目均为政府投资的公共建筑，结构形式以框架及剪力墙结构为主，这种高度的相似性为模型训练奠定了良好的数据基础。在指标体系构建方面，我们严格参照《建设工程工程量清单计价规范》（GB50500-2013），从建筑特征、空间尺度及结构性能三个维度提取了 17 项关键输入变量。

表 1 输入变量参数

编号	建筑特征类	编号	空间尺度类	编号	结构性能类
S1	总建筑面积	S7	首层层高	S13	结构类型
S2	地上建筑面积	S8	标准层层高	S14	基础形式
S3	地下建筑面积	S9	顶层层高	S15	抗震等级
S4	人防建筑面积	S10	檐口高度	S16	设防烈度
S5	基底面积	S11	室内外高差	S17	绿色建筑星级
S6	地上层数	S12	基础埋置深度		

输出变量设定为包括混凝土、钢筋、模板等在内的 32 项核心分部分项工程量指标。

### 3.2 变量量化与标准化处理

为了使定性指标能够进入数学模型运算，我们对“结构类型”与“基础形式”等变量采用了数值编码法。例如，将框架结构、剪力墙结构、框架剪力墙结构分别赋值为 1、2、3，具

体编码方式见表 2。

表 2 指标量化方式

抗震等级	取值	设防烈度	取值	结构类型	取值	基础形式	取值	绿建星级	取值
一级	1	六级	6	框架结构	1	独立基础	1	基本级	1
二级	2	七级	7	剪力墙结构	2	筏板基础	2	二星级	2
三级	3	八级	8	框架剪力墙结构	3	条形基础	3		
四级	4					筏板基础和独立基础	4		

由于各项输入输出变量的数量级存在较大差异，直接输入模型会导致网络收敛困难或学习效率降低。为消除量纲对模型准确度的影响，采用 Z-score 标准化方法对所有变量进行无量纲处理。标准化处理后，各变量服从均值为 0、标准差为 1 的标准正态分布，从而提升模型训练的稳定性与泛化能力。具体标准化过程如式（2）、（3）和（4）所示。

$$\mu = \frac{1}{98} \sum_{i=1}^{98} x_i \quad (i = 1, 2, \dots, 98) \quad (2)$$

$$\sigma = \sqrt{\frac{1}{98-1} \sum_{i=1}^{98} (x_i - \mu)^2} \quad (3)$$

$$x' = \frac{x - \mu}{\sigma} \quad (4)$$

式中， $x_i$  代表第  $i$  个样本的某一预测指标的数值， $\mu$  为均值， $\sigma$  为标准差。

## 4 基于集成学习的工程量预测模型构建

### 4.1 实验环境与工具

本研究的仿真实验基于 MATLAB R2023a 计算平台展开，分别调用了 Statistics and Machine Learning Toolbox 以及 Deep Learning Toolbox 实现不同算法的建模。为了科学验证各预测模型的泛化性能并有效规避过拟合风险，实验采用 cvpartition 函数将 98 个样本集划分为训练集与测试集。其中，训练集包含 78 个样本（占比 80%），用于模型参数的拟合与学习；测试集包含 20 个样本（占比 20%），用于评估模型在未知数据上的预测精度。为确保实验过程的可追溯性与结果的可复现性，全局随机种子统一设定为 42。

### 4.2 评价指标体系

为了多维度衡量模型的预测效能，本研究选取均方误差（MSE）、平均绝对误差（MAE）以及决定系数（ $R^2$ ）作为核心评价指标。其中， $R^2$  反映了模型对原始数据波动的解释能力，其值越接近 1，表明模型拟合优度越高；MSE 与 MAE 则

分别从平方误差和绝对误差的角度量化预测值与实际值之间的偏离程度，指标值越小，代表预测精度越高。

### 4.3 算法配置与参数调优

在模型训练阶段，通过多轮交叉验证对各算法的关键超参数进行了优化配置。针对随机森林模型，将基决策树的数量设定为220棵，并规定最小叶子节点数为2。这一配置在保证模型具备足够非线性拟合能力的同时，利用其特有的 Bagging 机制有效控制了泛化误差。对于梯度提升决策树模型，采用前向分步算法进行迭代，将基学习器数量设定为200棵，学习率设定为0.1。实验观测到，在此参数组合下，模型能够精准捕捉工程量数据中的残差分布。在BP神经网络的构建上，采用17-32-16-32的四层拓扑结构。输入层神经元对应17项建筑特征，输出层对应工程量指标。隐含层选用 tansig 切向 Sigmoid 传递函数以处理复杂的非线性映射，输出层则采用 purelin 线性传递函数，从而确保预测结果的连续性与准确性。

### 4.4 预测流程实现

整个预测流程遵循“数据输入—特征处理—模型训练—预测输出”的标准化路径。首先将预处理后的训练集输入模型，通过迭代优化损失函数，锁定各模型的内部权值或分段回归规则。随后，将测试集特征代入训练完毕的模型中，获取32项核心分部分项工程量的预测值，并将其与实际结算数据进行对比分析。这种严谨的实证流程为后续分析不同算法在EPC项目概算中的适用性提供了可靠依据。

## 5 实证分析与结果讨论

### 5.1 描述性统计分析

对选出的98个样本工程量数据做进一步的统计特征分析，得出各个项目工程量有明显的差别。例如样本总建筑面积在1254.4-32486平方米之间。数据离散度体现的是项目复杂程度，同时也会给模型泛化带来很大的困难。

### 5.2 模型预测结果对比

用训练好的RF、GBDT、BP神经网络模型对测试集进行预测，得到各个工程量指标的预测值。根据实测数据，各模型的核心评估指标如下：

**BP神经网络：**在本次测试中表现出最优的泛化性能。其测试集均方差(MSE)为1.0284，平均绝对误差(MAE)为0.2728，决定系数( $R^2$ )为0.9892。通过实验可知，BP神经网络对于这类工程造价数据的非线性映射有明显优势。

**随机森林(RF)与梯度提升树(GBDT)：**两种集成学习模型的表现高度一致。其32项因变量的平均MAE为0.411，测试集MSE为1.9024，测试集整体MAE为0.4110，决定系数( $R^2$ )均为0.9767。

训练与测试不同，RF、GBDT在训练集上MSE很低

(0.001409)，比测试集MSE高很多(1.9024)，说明集成学习算法拟合能力强但是容易出现过拟合问题。BP神经网络训练MSE为1.5406、测试MSE为1.0284，相较于另外两组小得多，更稳定。

### 5.3 指标预测分析

虽然BP神经网络在所有指标上都比不过RF、GBDT，但是当 $R^2$ 大于等于0.97的时候，已经可以达到工程估算的精度要求了。

三种模型对于重要指标，例如“地下一次钢筋”的预测结果和真实值(136.18)相差很小，BP模型预测值为127.85、RF模型预测值为131.59、GBDT模型预测值为136.13，误差都小于0.4%。

在“地上模板”等指标上，BP、RF和GBDT的预测稳定度差不多，都可以较好地把握住数据的变化趋势。

尽管BP神经网络在精度上略占优势，但是它具有黑箱性质，不能够解释造价差异的原因。而RF、GBDT模型可以给出特征重要性，给造价控制提供直观的依据。

例如，可以看出总建筑面积(S1)仍然是决定工程量的主要因素，它的贡献率最高。

结构类型(S13)和地上层数(S6)对于混凝土和钢筋含量有一定影响。这样一种可解释性使集成学习模型在辅助决策(限额设计指标的确定等)上比BP网络有更大的优势。

表3 不同模型对关键指标预测值与实际值对比

	BP神经网络	随机森林	梯度提升树
指标含量(实际值)	指标含量	指标含量	指标含量
136.18	127.85	131.59	136.13
4.61	4.31	4.13	4.58
2.39	2.66	2.72	2.39
51.23	52.14	51.89	51.2
...	...	...	...
4.2	2.74	4.04	4.2
1.05	1.05	1.05	1.05
4.2	5.07	4.27	4.19

## 6 结论

### 6.1 研究结论

本文主要研究工程总承包项目的前期投资概算问题，提出用随机森林、GBDT建立工程量指标预测模型的方法，然后和传统BP神经网络模型进行比较。通过98个实际工程项目进行

实证研究，得到如下几个主要结论。

模型精度均达到标准，BP 稍好于其他两种模型，从实证数据可知，三种模型的测试集  $R^2$  都大于 0.97，说明这三种模型都可以满足工程总承包项目前期投资估算的要求。其中，BP 神经网络以  $R^2=0.9892$ 、 $MAE=0.2728$  的优异表现，在精度上略胜一筹。

集成学习有强拟合、强解释性，随机森林、GBDT 模型在训练集中误差很小 ( $MSE=0.0014$ )，说明这两种方法具有很强的数据拟合能力。更重要的是可以给出特征的重要性排序，对总建筑面积、结构类型等主要影响造价的因素进行定量分析，较好地克服了神经网络不可解释性的缺点。

## 6.2 局限与展望

尽管本文取得了初步的研究成果，但是由于客观条件的限制，还存在很多不足之处，在今后的工作中还需要继续努力来改善。

由于数据获取困难，本次研究所用样本只有 98 例。未来还会继续扩大样本量，在包含更多的不同类型的建筑工程项目上做研究，即住宅、办公、医院等，提高模型的普适性。

特征维度需要扩大，只取了 17 个定量、定性指标。未来可以增加一些其他的指标，比如施工方案、地理环境以及市场价格的变化等等来构成更完整的一个预测指标系统。

算法优化，尽管 GBDT 表现很好，但是参数的调优过程比较费时。可以利用 XGBoost、LightGBM 这些更加高效梯度提升的算法或者采用智能优化的方法，比如遗传算法、粒子群算法等来自动找到最优的模型参数，从而提高预测的速度以及准确性。

综上所述，基于集成学习的工程量预测方法为工程总承包项目的造价管理提供了新的视角和工具，具有广阔的应用前景。

## 参考文献：

- [1] 高小喆. 建筑工程造价全过程管控技术分析. 中国招标. 2025(11):156-8.
- [2] 胥筱娅. 大数据背景下工程造价数据挖掘与成本预测方法探析. 城市建设. 2025(28):23-5.
- [3] 付龙洋. 基于大数据分析的房建工程造价精准预测方法探讨. 数字经济. 2026(Z1):84-5.
- [4] 陆军. 基于 XGBoost 的居住建筑投资估算模型的构建和应用研究 [硕士]: 新疆大学; 2023.
- [5] 周梦蝶, 王嘉君, 王欣悦. 基于机器学习算法的市政工程造价预测与效果研究. 工程机械与维修. 2025(06):52-4.
- [6] 冀心成, 汪衍凯, 张迎, 许彦杰. 贝叶斯优化梯度提升树的室内日光照度分布预测. 计算机与现代化. 2023(09):44-50.
- [7] 尚首良. 基于 BP 神经网络模型的住宅工程造价预测模型研究 [硕士]: 华南理工大学; 2023.
- [8] 郭春溪. 基于 PSO-BP 神经网络的装配式建筑造价预测模型研究. 江西建材. 2025(12):382-4+8.