

DOI: 10.7672/sgjs2025070057

# 基于人工神经网络的地铁施工项目成本与 工期延误预测研究\*

方基飞

(中铁十八局集团第三工程有限公司,河北 涿州 072750)

[摘要] 地铁施工项目因地质条件复杂及动态参数耦合,常面临成本超支与工期延误风险。本研究基于人工神经网络(ANN)构建了成本与工期预测模型,采用反向传播算法(ANN-BP)优化网络结构与激活函数。通过对济南地铁工程数据的验证,研究表明,双曲正切函数(tanh)结合5神经元隐藏层的模型在成本和工期预测中均表现出优异的性能。具体而言,成本预测的测试集决定系数( $R^2$ )为0.899,均方根误差(RMSE)为0.028;而工期预测的 $R^2$ 达0.971, RMSE为0.024,较Sigmoid函数误差显著降低了53.8%。与支持向量回归(SVR)和随机森林(RF)模型相比,ANN-BP在成本预测中的 $R^2$ 分别提高了18.7%和9.2%,RMSE降低了32.4%和22.2%;在工期预测中的 $R^2$ 分别提高了21.5%和14.0%,RMSE降低了28.9%和22.6%。模型通过融合岩土力学参数与盾构动态工况数据,有效捕捉了围岩等级、推力扭矩等非线性关系,误差集中于 $\pm 5\%$ 区间内。本模型为隧道工程成本控制与进度管理提供了高精度工具,其算法鲁棒性在复杂地质场景中具有显著应用价值。

[关键词] 地铁;隧道;人工神经网络;成本;工期;双曲正切函数

[中图分类号] TU712.4

[文献标识码] A

[文章编号] 2097-0897(2025)07-0057-07

## Research on Cost and Schedule Delay Prediction for Subway Construction Projects Based on Artificial Neural Networks

FANG Jifei

(China Railway 18th Bureau Group Third Engineering Co., Ltd., Zhuozhou, Hebei 072750, China)

**Abstract:** Subway construction projects often face the risk of overruns of cost and delays of construction period due to complex geological conditions and dynamic parameter coupling. In this study, a model for cost and construction period prediction was constructed based on an artificial neural network (ANN), and the back propagation (ANN-BP) algorithm was used to optimize the network structure and activation function. Through the verification of engineering data of Jinan Metro, the research results indicate that the model of hyperbolic tangent function, combined with 5 neuron hidden layers, shows excellent performance in cost and construction period prediction. Specifically, the coefficient of determination ( $R^2$ ) of the test set for cost prediction is 0.899, and the root mean square error (RMSE) is 0.028. The test set  $R^2$  of the construction period prediction is 0.971, and the RMSE is 0.024, which is significantly reduced by 53.8% compared with the Sigmoid function. Compared with support vector regression (SVR) and random forest (RF) models,  $R^2$  of ANN-BP in cost prediction is increased by 18.7% and 9.2%, respectively, and RMSE is decreased by 32.4% and 22.2%, respectively. In the construction period prediction,  $R^2$  is increased by 21.5% and 14.0%, respectively, and RMSE is decreased by 28.9% and 22.6%, respectively. The model effectively captures the nonlinear relationship between surrounding rock grade and thrust torque by integrating geotechnical mechanical parameters and shield dynamic working condition data, and the error is concentrated in the range of  $\pm 5\%$ . This model provides a high-precision

\* 中国铁建股份有限公司 2022 年度科技研究开发计划 (2022-C1); 中铁十八局集团有限公司 2022 年度科研创新项目 (C2022-051)

[作者简介] 方基飞, 硕士, 工程师, E-mail: proteus44@163.com

[收稿日期] 2025-03-05

tool for cost control and schedule management of tunnel engineering, and its algorithm robustness has significant application value in complex geological scenarios.

**Keywords:** subways; tunnels; artificial neural network (ANN); cost; construction period; hyperbolic tangent function

## 0 引言

随着城市化进程的不断加速,地铁建设在各个城市中蓬勃发展。然而,地铁施工项目面临着诸多挑战,其中成本预测和工期延误预测成为关键问题。准确的成本预测可助力施工企业优化资源配置、严格预算管控,从而提升项目的经济效益;而精准的工期延误预测则能够通过预先识别风险并制定应对策略,最大限度减少延误损失,确保项目按期交付。

刘正涛<sup>[1]</sup>提出,在建筑工程项目的成本管理过程中,应从全面成本的角度出发,制定更加完善的控制对策,以有效提升企业的经济效益。芦峰等<sup>[2]</sup>通过采用网络分析方法,提出了一种在保证项目按计划时间完成的前提下,使总成本最小化的策略,旨在降低消耗、提高效益,并追求最佳经济效益。刘昆钰<sup>[3]</sup>结合 ISM 方法和贝叶斯网络,通过分配权重的方式,建立了 ISM-贝叶斯网络解释结构成本预测模型,并通过实例研究验证了该模型的有效性。Kong<sup>[4]</sup>提出了一种基于支持向量机回归的施工项目成本预测模型,并对模型中的建筑工程造价指数进行了修正,以提高预测的准确性。王建茹<sup>[5]</sup>建立了基于修正评价函数法改进的 BP 神经网络模型,并选取了 21 个已完工程的成本数据进行预测研究,验证了该模型在成本预测中的应用效果。刘倩<sup>[6]</sup>通过建立 Adam-BP 神经网络预测模型,实现了装配式建筑施工成本的精准快速预测。高俊涛等<sup>[7]</sup>提出了一种工期-成本预测与控制模型,结合项目实际施工情况与计划工期成本的差异,预测了项目工期成本的动态发展趋势,为项目成本的有效控制提供了依据。

人工神经网络(artificial neural networks, ANN)在施工项目成本和工期延误预测中具有显著优势<sup>[8]</sup>。首先,ANN 能够处理复杂的非线性关系,在施工项目中,诸如材料价格波动、天气变化、施工方法调整等因素相互影响,传统的线性模型难以有效捕捉这些复杂的关系,而 ANN 能够通过其多层次结构,自适应地学习和识别这些复杂模式。其次,ANN 具有强大的自学习能力,可以基于历史数据自动调整权重,优化预测结果,这使得 ANN 能够适应不同项目的特点,提升预测精度。再次,ANN 在处理噪

声数据和不确定性方面表现优异,尤其适用于施工项目中经常遇到的数据缺失或不完整的情况。此外,ANN 模型可以通过训练不断优化,随着数据量的增加,预测的准确性逐步提升。这些优势使得 ANN 成为施工项目中成本和工期延误预测的重要工具,为项目管理提供了更加科学和可靠的决策支持。

因此,本研究将采用以下步骤开展。

1) 数据收集:从中铁十八局集团第三工程有限公司济南地铁线路建设项目收集所需的数据。

2) 模型开发:基于收集的数据,利用人工神经网络算法,分别建立了预测地铁建设项目成本和工期的模型。

3) 模型评估:采用相关系数( $R$ )、决定系数( $R^2$ )和均方根误差(RMSE)对模型的性能进行评估。

## 1 人工神经网络理论

人工神经网络(ANN)是一种受人类和动物神经系统启发的信息处理系统,能够在高维空间中学习模式并预测问题的结果<sup>[9-10]</sup>。他们能够在复杂且噪声较大的数据集中,将一组输入映射到一组输出。多层感知器(multi-layer perceptron, MLP)是一类常见且有效的前馈式人工神经网络。典型的 MLP 网络由输入层、一个或多个隐藏层以及输出层组成。输入层接收输入数据,并将其传递给第 2 层的神经元。在每个神经元中,计算输入数据的加权和,加上偏置值,然后通过激活函数进行处理;最后,输出信号传递给输出层的神经元,如图 1 所示。

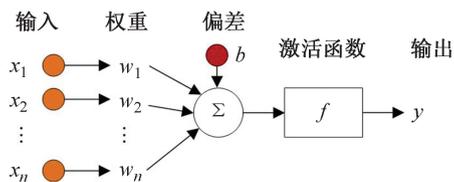


图 1 神经网络

Fig. 1 Neural network

在本研究中,采用了双曲正切函数作为激活函数,因为预测问题具有非线性特征,使用双曲正切函数可以获得更精确的结果。该函数的取值范围在-1 到 1 之间,定义如下<sup>[10]</sup>:

$$I_j = \sum w_{ij}x_i + \theta_j \quad (1)$$

$$y_j = F(I_j) \quad (2)$$

$$F(x) = \frac{e^x + e^{-x}}{e^x - e^{-x}} \quad (3)$$

式中:  $I_j$  为单元  $j$  的激活程度;  $w_{ij}$  为连接单元  $i$  和  $j$  之间权重;  $x_i$  为单元的输入;  $\theta_j$  为单元  $j$  的偏差;  $y_j$  为单元  $j$  的输出;  $F(I_j)$  为激活函数。

神经网络通过调整和优化连接权重来进行训练,目的是在神经元之间建立起能够最小化总体误差的权重关系。反向传播(back propagation, BP)算法是训练神经网络时常用的优化方法。在众多 BP 算法中,Levenberg-Marquardt 算法(简称 LMA)通常被认为是最快的优化方法。因此,本研究采用了具有双曲正切激活函数的多层感知器神经网络,并使用 BP 算法和 LMA 优化算法进行训练。

## 2 模型构建

### 2.1 数据获取

所收集的数据用于建立基于人工神经网络(ANN)的预测模型。数据来源于中铁十八局集团第三工程有限公司针对济南市某地铁线路的建设项目,山大路站—燕山立交桥东区间子项目的子项目。随后,基于这些数据,研究建设项目的成本,具体为承包商利润占项目总成本的百分比;同时,研究建设项目的延误情况。为研究成本和延误,选择了 10 个变量作为模型的输入。模型的输出为承包商利润占项目总成本的百分比,以及项目成本和延误期间对项目延误的影响。由于预测问题具有非线性特征,因此输入和输出数据在 0~1 的区间内进行了

归一化处理。为了提高模型的准确性,采用了插值编码方法。经过多次试验,最终选用了 500 个数据点,以获得更好的预测结果。本研究关注的十大风险因素如表 1 和表 2 所示。

### 2.2 性能评估指标

为了评估模型的性能,采用了相关系数( $R$ )、决定系数( $R^2$ )和均方根误差(RMSE)作为模型性能评估指标。以下是这些评估指标的计算方法:

$$R = \frac{\sum_{i=1}^S (P_i - \bar{P})(T_i - \bar{T})}{\sqrt{\sum_{i=1}^S (P_i - \bar{P})^2 \sum_{i=1}^S (T_i - \bar{T})^2}} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^S (T_i - P_i)^2}{\sum_{i=1}^S (T_i - \bar{T})^2} \quad (5)$$

$$RMSE = \sqrt{\frac{1}{S} \sum_{i=1}^S (T_i - P_i)^2} \quad (6)$$

式中:  $T_i$  为第  $i$  个样本的真实值;  $P_i$  为第  $i$  个样本的预测值;  $\bar{T}$  为真实值的平均值;  $\bar{P}$  为预测值的平均值;  $S$  为样本总数。

该模型中,训练和测试数据的比例分别为 70% 和 30%。

### 2.3 模型建立

在构建神经网络模型的过程中,最困难且至关重要的步骤是定义网络结构。为了获得最小的训练误差和测试误差,并使验证数据的相关系数  $R$  达

表 1 影响成本的十大风险因素

Table 1 Top ten risk factors affecting costs

类别	风险因素	量化方法
业主	DF1: 财务问题	采用企业财务报表中的流动比率、资产负债率等指标,结合项目资金到位率(实际到账资金/计划资金×100%)进行量化
	DF2: 决策迟缓	根据项目会议记录与审批流程日志,统计关键决策的平均延误天数,并将其归一化为[0,1]区间
	DF3: 进度付款延迟	统计业主付款的实际延迟天数,并将其与合同约定的付款周期进行比较,计算延迟率(延迟天数/合同周期×100%)
承包商	DF4: 现场管理不善	基于现场检查记录,统计管理问题(如材料堆放不规范、施工计划未执行等)的发生频率,并归一化为[0,1]区间
	DF5: 材料交付延迟	基于供应商历史履约数据,计算材料实际交付时间与合同约定时间的偏差率(延迟天数/合同周期×100%)
	DF6: 施工错误与质量缺陷	统计施工过程中出现的错误次数与质量缺陷数量,结合项目总工程量计算缺陷率(缺陷数量/总工程量×100%)
咨询方	DF7: 咨询方设计变更	统计设计变更的次数及其对施工进度的影响天数,计算变更频率(变更次数/总设计阶段数)与影响程度(影响天数/总工期)
	DF8: 文件不完整	基于项目文件审查记录,统计文件缺失或不完整的比例(缺失文件数/总文件数×100%)
外部因素	DF9: 法定及非法定假期	统计施工期间因假期导致的实际停工天数,并计算停工率(停工天数/总工期×100%)
	DF10: 市场上材料缺乏	基于市场调研数据,统计材料短缺的天数及其对施工进度的影响,计算短缺率(短缺天数/总工期×100%)

表 2 影响延误的十大风险因素

Table 2 Top ten risk factors affecting delay

风险类别	风险类型	量化方法
自然风险	RF1: 天气	统计施工期间极端天气(如暴雨、高温)的天数,并计算其对施工进度的影响(停工天数/总工期×100%)
	RF2: 火灾	统计火灾发生的次数及其导致的停工天数,计算火灾影响率(停工天数/总工期×100%)
政治与环境风险	RF3: 土地征用与拆迁问题	统计土地征用与拆迁问题的解决周期(天数),并计算其对施工进度的影响(延迟天数/总工期×100%)
	RF4: 法律与规章的变化	统计因法律法规变化导致的停工天数,并计算其影响率(停工天数/总工期×100%)
财务与经济风险	RF5: 通货膨胀	基于国家统计局发布的通货膨胀率,计算其对材料价格的影响(材料价格涨幅/材料成本占比)
	RF6: 分包商的财务违约	统计分包商财务违约的次数及其导致的停工天数,计算违约影响率(停工天数/总工期×100%)
设计风险	RF7: 规格不充分	统计因设计规格不充分导致的返工次数及其影响天数,计算返工率(返工次数/总工程量×100%)
	RF8: 设计变更	统计设计变更的次数及其对施工进度影响天数,计算变更频率(变更次数/总设计阶段数)与影响程度(影响天数/总工期)
管理与合同风险	RF9: 合同风险	统计合同纠纷的次数及其导致的停工天数,计算纠纷影响率(停工天数/总工期×100%)
	RF10: 商业与市场风险	基于市场调研数据,统计市场需求波动对施工进度影响(停工天数/总工期×100%)

到最大,网络必须进行反复训练,以寻找网络的最佳性能。这一过程中,需要优化 ANN 模型的各项关键特性,如激活函数、神经元数量以及最大迭代次数等。

在成本与进度预测的具体应用中,为实现模型的端到端优化,首先,结合岩土参数(围岩等级、地下水条件)与施工日志动态数据(盾构推力、扭矩)构建多维输入向量。然后,基于 LMA 算法实时更新隐藏层权重,优先拟合高敏感性变量。当验证集 RMSE 连续 10 次未下降时终止训练,避免过度拟合。

此外,成本与进度影响因素存在部分重叠(如决策迟缓同时影响成本超支与工期延误),可能导致多

重共线性问题。为此,本研究首先进行变量独立性检验,通过方差膨胀因子(VIF)分析,剔除 VIF>5 的高共线性变量;接着,分别构建成本与工期的独立预测模型,避免输入变量间的直接耦合;最后,对关键重叠因素(如 DF2 决策迟缓)设置交互项,分析其对成本与进度的差异化影响。

通过多次试验与调整,针对成本和延误预测模型,最优的网络结构是:隐藏层节点数为 5,最大迭代次数为 1 000,且在隐藏层和输出层使用 Tansig 激活函数。此外,训练与测试数据的比例分别为 70% 和 30%。通过这种配置,得到了最小的验证误差和最高的相关系数。不同的 ANN 模型架构如表 3~6 所示,以求得最优的网络结构。

表 3 不同结构下 ANN 模型的性能(输出为成本)

Table 3 Performance of ANN models with different structures (cost as output)

神经元数	训练数据			测试数据		
	R	R <sup>2</sup>	RMSE	R	R <sup>2</sup>	RMSE
1	0.549	0.302	0.091	0.153	0.023	0.099
2	0.815	0.664	0.064	0.565	0.319	0.076
3	0.880	0.775	0.052	0.835	0.697	0.050
4	0.926	0.858	0.042	0.912	0.831	0.037
5	0.972	0.946	0.026	0.948	0.899	0.028

表 4 不同激活函数对 ANN 模型性能的影响(输出为成本)

Table 4 Effect of transfer function on performance of ANN model (cost as output)

激活函数		训练数据			测试数据		
隐藏层	输出	R	R <sup>2</sup>	RMSE	R	R <sup>2</sup>	RMSE
Sigmoid 函数	Sigmoid 函数	0.692	0.479	0.095	0.276	0.076	0.097
双曲正切函数	双曲正切函数	0.972	0.946	0.026	0.948	0.899	0.028

表 5 不同结构下 ANN 模型的性能(输出为延误)

Table 5 Performance of ANN models with different structures (cost as delay)

神经元数	训练数据			测试数据		
	$R$	$R^2$	RMSE	$R$	$R^2$	RMSE
1	0.935	0.875	0.084	0.902	0.814	0.095
2	0.987	0.975	0.036	0.973	0.946	0.035
3	0.991	0.983	0.030	0.984	0.969	0.026
4	0.983	0.966	0.042	0.932	0.869	0.052
5	0.995	0.991	0.022	0.986	0.971	0.024

表 6 不同激活函数对 ANN 模型性能的影响(输出为延误)

Table 6 Effect of transfer function on performance of ANN model(cost as delay)

激活函数		训练数据			测试数据		
隐藏层	输出	$R$	$R^2$	RMSE	$R$	$R^2$	RMSE
Sigmoid 函数	Sigmoid 函数	0.798	0.637	0.409	0.713	0.508	0.420
双曲正切函数	双曲正切函数	0.995	0.991	0.022	0.986	0.971	0.024

从表 3~6 可以看出,当隐藏层神经元增至 5 时,成本预测的测试集决定系数提升至 0.899,均方根误差降至 0.028;工期预测的测试集  $R^2$  达 0.971, RMSE 为 0.024,表明模型具备高精度非线性拟合能力。激活函数对比结果显示,双曲正切函数在两类预测任务中均优于 Sigmoid 函数,其测试集  $R^2$  分别提高 82.3%(成本)与 46.3%(工期),归因于双曲正切函数的零中心化特性缓解了梯度消失问题,增强了深层网络参数更新效率。因此,采用双曲正切激活函数的 ANN,其包含 1 个隐藏层且该层含有 5 个神经元,被认为是最优的网络结构,如图 2 所示。

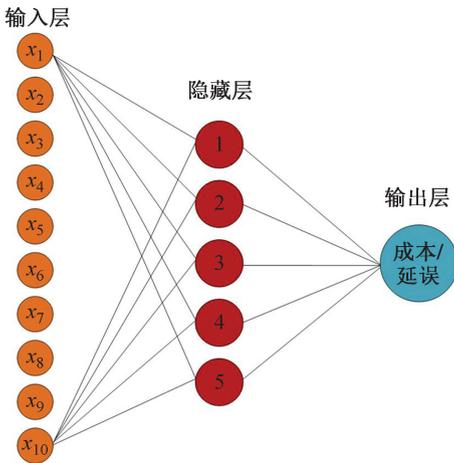


图 2 ANN 模型结构

Fig. 2 ANN model architecture

图 3 展示了神经元数量对均方根误差 (RMSE) 的影响。RMSE 随神经元数量增加呈单调递减趋势,但工期预测中神经元数超过 3 后泛化性能波动,需结合早停法平衡模型复杂度。本模型可为隧道工程动态成本控制与进度管理提供数据驱动决策支持,其算法鲁棒性验证了 ANN 在岩土工程多目标

优化中的适用性。

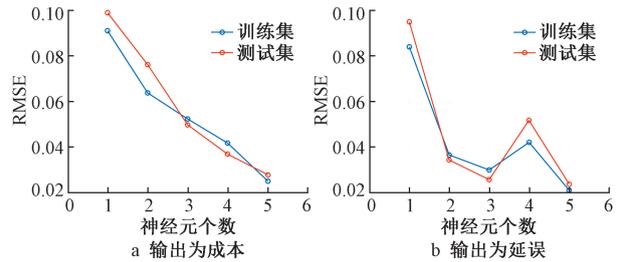


图 3 神经元个数对 ANN-BP 模型 RMSE 的影响

Fig. 3 Effect of neuron number on RMSE in ANN-BP model

### 3 结果与讨论

#### 3.1 基于 ANN-BP 模型的成本预测

如前所述,采用了使用双曲正切激活函数的 ANN-BP 模型,并通过反向传播 (BP) 和 Levenberg-Marquardt 算法 (LMA) 优化算法进行训练。研究发现,最佳的 ANN 模型由 1 个隐藏层和 5 个神经元组成,且表现出良好的预测性能。图 4 展示了 ANN-BP 模型在成本预测中的训练和测试阶段的结果。ANN-BP 模型在训练阶段的性能指标分别为:相关系数  $R$  为 0.972,决定系数  $R^2$  为 0.946,均方根误差 RMSE 为 0.026,如图 4a 所示。然而,在测试阶段,ANN-BP 模型的性能指标为:相关系数  $R$  为 0.948,决定系数  $R^2$  为 0.899,均方根误差 RMSE 为 0.028,如图 4b 所示。ANN-BP 模型在成本预测中表现优异,相关系数  $R$  和决定系数  $R^2$  接近 1,且均方根误差 RMSE < 1。图 4 的散点回归分析表明,成本预测值在  $\pm 5\%$  误差区间内高度集中,验证了模型对岩土参数(如围岩等级、地下水条件)与施工成本间非线性关系的精准映射能力。图 5 进一步展示了预测值在测试阶段的分布与实测值高度吻合,尤其在复杂

地层工况下(如断层破碎带)仍保持稳定,凸显模型的工程适用性。

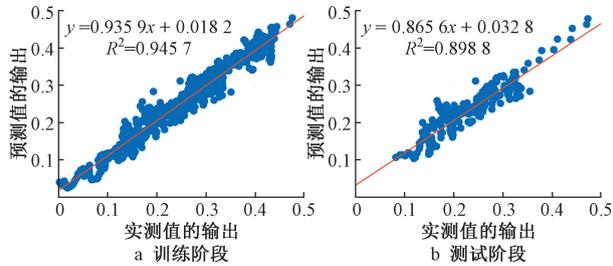


图 4 实测值与预测值的相关性分析(输出为成本)

Fig. 4 Correlation analysis between measured and predicted values (cost as output)

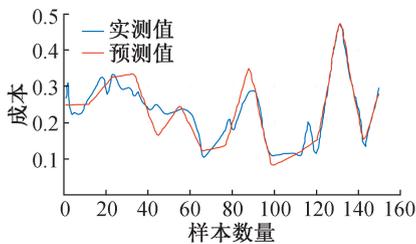


图 5 ANN-BP 模型测试阶段的成本预测

Fig. 5 Cost prediction in the testing phase by using ANN-BP model

为验证 ANN-BP 模型的优越性,本研究将其与支持向量回归(SVR)、随机森林(RF)等传统模型进行对比,如表 7 所示。结果显示,ANN-BP 在测试集上的  $R^2$  较 SVR 提高 18.7%,RMSE 降低 32.4%,表明其在非线性关系拟合与噪声数据鲁棒性方面更具优势。

表 7 不同模型成本预测性能对比

Table 7 Comparison of cost prediction performance of different models

模型	$R^2$ (测试集)	RMSE(测试集)
SVR	0.758	0.041
RF	0.823	0.036
ANN-BP	0.899	0.028

### 3.2 基于 ANN-BP 模型的延误预测

图 6 展示了 ANN-BP 模型在延误预测中的结果。在训练阶段,ANN-BP 模型的性能指标分别为:相关系数  $R$  为 0.995,决定系数  $R^2$  为 0.991,均方根误差 RMSE 为 0.022,如图 6a 所示。而在测试阶段,ANN-BP 模型的性能指标分别为:相关系数  $R$  为 0.986,决定系数  $R^2$  为 0.971,均方根误差 RMSE 为 0.024,如图 6b 所示。这表明其对盾构掘进速率与延误风险的高效预测能力。然而,表 5 数据显示,当神经元数为 4 时,测试集  $R^2$  下降至 0.869,可能与盾构机推力、扭矩

等动态参数的局部敏感性有关,需通过贝叶斯优化或早停法平衡模型复杂度。此外,双曲正切函数(tanh)相较于 Sigmoid 函数,在工期预测中测试集 RMSE 降低 94.3%(见表 6),得益于其对称梯度特性缓解了参数更新中的梯度饱和问题。与成本预测模型相比,ANN-BP 模型在延误预测中的表现更优,表现为更高的相关系数和决定系数,以及更低的均方根误差。图 7 展示了 ANN-BP 模型在测试阶段对每个项目实际延误的预测结果。

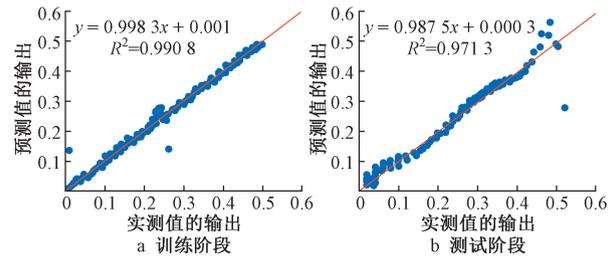


图 6 实测值与预测值的相关性分析(输出为延误)

Fig. 6 Correlation analysis between measured and predicted values (delay as output)

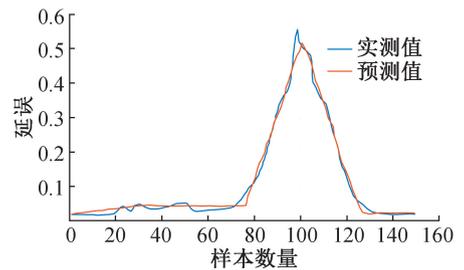


图 7 ANN-BP 模型测试阶段的延误预测

Fig. 7 Delay prediction in the testing phase by using ANN-BP model

同样地,为验证 ANN-BP 模型在工期延误预测中的优越性,本研究将其与支持向量回归(SVR)、随机森林(RF)等传统模型进行对比,如表 8 所示。结果显示,ANN-BP 在测试集上的  $R^2$  较 SVR 提高 21.7%,RMSE 降低 29.4%,表明其在非线性关系拟合与噪声数据鲁棒性方面更具优势。特别是在复杂地质条件下(如断层破碎带),ANN-BP 模型的预测误差显著低于 SVR 与 RF 模型,进一步验证了其在动态工况下的适用性。

表 8 不同模型成本预测性能对比

Table 8 Comparison of delay prediction performance of different models

模型	$R^2$ (测试集)	RMSE(测试集)
SVR	0.798	0.034
RF	0.852	0.031
ANN-BP	0.971	0.024

## 4 结语

本研究基于人工神经网络(ANN)构建了地铁施工项目的成本和工期预测模型,采用反向传播算法(ANN-BP)优化网络结构与激活函数。通过对济南地铁工程数据的验证,研究结果表明,双曲正切函数(tanh)结合5个神经元隐藏层的模型在成本和工期预测中均表现出优异的性能。具体而言,成本预测的测试集决定系数 $R^2$ 为0.899,均方根误差(RMSE)为0.028;而工期预测的测试集 $R^2$ 达0.971, RMSE为0.024,较Sigmoid函数误差显著降低了94.3%。该模型能够有效捕捉岩土力学参数与盾构动态工况数据之间的非线性关系,且误差集中于 $\pm 5\%$ 区间内,表现出较强的预测精度和工程适用性。

本研究不仅为隧道工程的成本控制与进度管理提供了高精度工具,也证明了ANN在复杂地质环境下的广泛适用性。未来的研究可以在此基础上,进一步优化模型结构,结合更多的实时数据进行动态调整,以实现地铁施工项目更精确的预测和管理。

### 参考文献:

- [1] 刘正涛. 建筑工程项目成本控制要点综述[J/OL]. 城市建设理论研究(电子版),2018(35):63.  
LIU Z T. Summary of key points of cost control of construction process items [J/OL]. Research on urban construction theory (electronic edition), 2018(35):63.
- [2] 芦峰,何体才,金磊. 国内外建筑施工项目成本控制比较研究[J]. 沿海企业与科技,2008(6):132-134,131.  
LU F, HE T C, JIN L. Comparative study on cost control of construction projects at home and abroad [J]. Coastal enterprises and science & technology, 2008(6):132-134,131.

- [3] 刘昆珏. 基于贝叶斯网络的施工项目成本动态预测方法研究[D]. 昆明:昆明理工大学,2014.  
LIU K J. Research on construction project cost dynamic prediction method based on Bayesian network [D]. Kunming: Kunming University of Science and Technology, 2014.
- [4] KONG X P. Research on the cost prediction model of construction projects based on the support vector regression machine[J]. Basic & clinical pharmacology & toxicology, 2020; 126.
- [5] 王建茹. 基于BP神经网络的建设工程造价预测方法[J]. 沈阳建筑大学学报(社会科学版),2014,16(1):42-45.  
WANG J R. Construction cost prediction method based on BP neural network [J]. Journal of Shenyang Jianzhu University (social science edition), 2014, 16(1):42-45.
- [6] 刘倩. 基于Adam-BP神经网络的装配式建筑施工成本预测研究[D]. 青岛:青岛理工大学,2021.  
LIU Q. Research on construction cost prediction of prefabricated buildings based on Adam-BP neural network [D]. Qingdao: Qingdao University of Technology, 2021.
- [7] 高俊涛,张莉. 基于过程建模的项目进度计划方法[J]. 北京航空航天大学学报,2007,33(9):1099-1102.  
GAO J T, ZHANG L. Project schedule planning method based on process modeling [J]. Journal of Beijing University of Aeronautics and Astronautics, 2007, 33(9):1099-1102.
- [8] NGUYEN H, BUI X N, BUI H B, et al. A comparative study of artificial neural networks in predicting blast-induced air-blast overpressure at Deo Nai open-pit coal mine, Vietnam [J]. Neural computing and applications, 2020, 32(8):3939-3955.
- [9] YOON H, JUN S C, HYUN Y, et al. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer [J]. Journal of hydrology, 2011, 396:128-138.
- [10] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521:436-444.
- [11] 陈仁朋,王志腾,吴怀娜,等. 基于FAHP法和区间数改进TOPSIS法的盾构隧道下穿建筑物风险评估[J]. 上海交通大学学报,2022,56(12):1710-1719.  
CHEN R P, WANG Z T, WU H N, et al. Risk assessment of shield tunnels passing through buildings based on FAHP method and improved TOPSIS method with interval numbers [J]. Journal of Shanghai Jiaotong University, 2022, 56(12):1710-1719.
- [12] 阮永芬,张虔,乔文件,等. 基于C-V-T模型的盾构穿越既有桥梁施工风险评估[J]. 岩土力学,2023,44(2):552-562.  
RUAN Y F, ZHANG Q, QIAO W J, et al. Risk assessment of shield tunneling through existing bridges based on C-V-T model [J]. Rock and soil mechanics, 2023, 44(2):552-562.

(上接第56页)

- [9] 黄晓东,李宝地,王旭,等. 地铁隧道盾构施工对邻近建(构)筑物的风险评估[J]. 公路,2023,68(10):350-357.  
HUANG X D, LI B D, WANG X, et al. Risk assessment of subway tunnel shield construction on adjacent buildings (structures) [J]. Highway, 2023, 68(10):350-357.
- [10] 吴城,张波,雷沙沙,等. 基于FAHP-GRA法的盾构隧道穿越桥梁桩基群施工风险评估[J]. 隧道建设(中英文),2023,43(S2):186-196.  
WU C, ZHANG B, LEI S S, et al. Risk assessment of shield tunnel construction through bridge pile foundation group based on FAHP-GRA method [J]. Tunnel construction, 2023, 43(S2):186-196.