

# 基于 GA-BP 神经网络模型的二手载货汽车价值评估方法

闫晟煜<sup>1</sup>, 刘杨<sup>1</sup>, 刘继祥<sup>2</sup>, 陈海峰<sup>3\*</sup>, 郑元旺<sup>4</sup>, 温福华<sup>1</sup>, 王洪瑀<sup>5</sup>

(1.长安大学汽车学院, 陕西 西安 710018; 2.中建八局第一建设有限公司, 山东 济南 250100; 3.中国汽车技术研究中心有限公司, 天津 300300; 4.山东广安车联科技股份有限公司, 山东 济宁 272000; 5.上汽通用五菱汽车股份有限公司, 重庆 401135)

**摘要:**为准确评估二手载货汽车的价值,基于电商平台历史交易数据,提出遗传算法-反向传播神经网络(genetic algorithm-backpropagation neural network, GA-BP)评估方法。结合二手载货汽车的使用特性,选取影响交易价值的11个关键指标并提出指标的量化标准;通过皮尔逊相关系数法对各指标进行一致性检验,验证指标选取的合理性;融合遗传算法和BP神经网络,提出二手载货汽车GA-BP神经网络价值评估模型,利用9 016条交易数据对模型进行训练和验证。相较于未优化过的BP神经网络模型,本文模型的均方误差降低了74.85%。通过平均影响值分析发现,累计行驶里程、累计行驶时间、排放标准、比功率和上装情况5项价值评估指标对二手载货汽车价值评估影响最大,排放标准逐渐成为影响二手载货汽车的重要指标。

**关键词:**汽车价值评估;二手载货汽车;遗传算法;BP神经网络;排放标准

**中图分类号:**TP392;U469.2 **文献标志码:**A

**引用格式:**闫晟煜,刘杨,刘继祥,等.基于GA-BP神经网络模型的二手载货汽车价值评估方法[J].山东大学学报(理学版),2025,60(12):11-20.

## Evaluation method of used truck value based on GA-BP neural network model

YAN Shengyu<sup>1</sup>, LIU Yang<sup>1</sup>, LIU Jixiang<sup>2</sup>, CHEN Haifeng<sup>3\*</sup>, ZHENG Yuanwang<sup>4</sup>, WEN Fuhua<sup>1</sup>, WANG Hongyu<sup>5</sup>

(1. School of Automobile, Chang'an University, Xi'an 710018, Shaanxi, China; 2. The First Company of China Eighth Engineering Bureau Ltd., Jinan 250100, Shandong, China; 3. China Automotive Technology and Research Center Co., Ltd., Tianjin 300300, China; 4. Shandong Guang'an Connected Vehicle Technology Co., Ltd., Jining 272000, Shandong, China; 5. SAIC-GM-Wuling Automobile Co., Ltd., Chongqing 401135, China)

**Abstract:** To accurately evaluate the value of the used trucks, a GA-BP (genetic algorithm-backpropagation) neural network evaluation method is proposed, based on the historical transaction data of e-commerce platform. Considering the use features of the used trucks, 11 key indicators affecting the transaction value are selected and the quantitative standards of the indicators are put forward. The consistency of each index is tested by Pearson correlation coefficient method to verify the rationality of index selection. By compromising Genetic Algorithm and BP neural network, the evaluation model of the used trucks value by GA-BP neural network is proposed, and the model is trained and verified by using 9 016 transaction data. Compared with the unoptimized BP neural network model, the mean square error (MSE) of the model is reduced by 74.85%. Through the analysis of the average impact value, it is found that the cumulative mileage, cumulative driving time, emission standard, specific power and loading situation show the greatest influence on the value evaluation of used trucks, and the emission standard has gradually become an important indicator affecting used trucks.

**Key words:** automobile value evaluation; used truck; genetic algorithm; BP neural network; emission standard

## 0 引言

我国二手载货汽车领域尚无公开、完整的成交数据资源。成交数据只能依赖于人工搜集交易案例的方

收稿日期:2024-07-12; 网络出版时间:2025-07-08 11:51:35

基金项目:国家重点研发计划项目(2023YFB3209803);长安大学中央高校基本科研业务费专项资金资助项目(300102224206);山东省科技型中小企业创新能力提升工程资助项目(2023TSGC0335)

第一作者:闫晟煜(1987—),男,副教授,博士,研究方向为智慧交通工程、公路运输规划。E-mail:Leo9574@163.com

\*通信作者:陈海峰(1980—),男,高级工程师,研究方向为汽车后市场、产业研究。E-mail:chenhaifeng@catarc.ac.cn

式获得,存在效率低、难度大且数据时效性差的问题。现阶段,我国二手载货汽车价值评估方法主要是传统重置成本法和现行市价法<sup>[1]</sup>。重置成本法在交易信息不流通或车型不完整时,难以找到参照车辆。现行市价法因排放标准、车辆类型、归属地等影响,使得车辆价值波动大且具有主观性。这两种方法均无法完全满足当下二手载货汽车价值评估的需求。

2018年,我国二手车电商平台成交量同比增长50.10%,而2019—2021年二手车交易量保持25%的年均增速<sup>[2]</sup>。电商平台大量的交易数据为建立面向大数据应用的二手载货汽车价值评估模型奠定了基础,采用的方法多为数学模型、启发式算法和机器学习算法。传统的评估方法有:胡诣文等<sup>[3]</sup>提出基于Lasso-XGBoost算法的二手车价值预测模型;王传杏等<sup>[4]</sup>依据行驶里程、维修次数、车辆配置、发行年份和市场情况等因素,建立价格特征评估模型;代金辉等<sup>[5]</sup>提出二手车价值轻量级梯度提升机(light gradient boosting machine, LightGBM)评估算法,运用随机森林分析成交周期的重要性;Prieto等<sup>[6]</sup>引入前景理论,提出特征价格模型,分析车辆品质对价值的影响;Syahputra等<sup>[7]</sup>基于模糊逻辑理论和格子玻尔兹曼算法(lattice boltzmann method, LBM)建立二手车价值评估模型;Alexstan等<sup>[8]</sup>考虑买卖双方对二手车价值不知情的特点,提出车辆价格评估模型。典型的机器学习评估方法有:杨致远<sup>[9]</sup>以二手车电商平台交易数据为基础,运用主成分分析-深度神经网络(principal component analysis-deep neural networks, PCA-DNN)和LightGBM算法建立二手车价格预测模型;李富强等<sup>[10]</sup>运用深度学习模型分析影响二手车价值的关键因素;Dedy等<sup>[11]</sup>采用6种数据挖掘方法改进决策模型,提出基于支持向量机的价值评估模型。

已有研究中鲜见利用电商交易数据评估二手商用车价值方法的研究,未见针对载货汽车使用特性开展价值评估的研究。鉴于此,本文通过分析影响二手载货汽车价值的因素,量化排放标准、车辆类型、燃料类型、归属地、上装情况等指标对二手载货汽车价格波动的影响,建立综合价值评估指标体系,引入BP神经网络(backpropagation neural network)和遗传算法,提出二手载货汽车价值评估模型。

## 1 数据基础与指标体系构建

### 1.1 数据来源及指标量化

二手载货汽车电商平台交易数据量大、信息完整,数据受平台监督,可作为评估价值的参考。通过国内3家主流电商平台获得12 251个历史交易数据,经筛选和清洗后得到9 016个有效数据。结合二手载货汽车使用特性,设计11项评价指标,包括排放标准、车辆品牌、发动机品牌、车辆类型、燃料类型、归属地、上装情况、累计行驶里程、累计行驶时间、比功率和驱动类型。

采用汽车运行表征数据作为定量指标,包括累计行驶里程、累计行驶时间和比功率;定性指标通过市场交易量、车型保有量等方式量化。量化标准见表1。

表1 评价指标的量化标准  
Table 1 Quantitative criteria of evaluation indicators

指标类型	序号	评价指标	指标释义与量化	量化标准
定量指标	1	累计行驶里程	车辆仪表盘数字读取	单位:km×10 <sup>4</sup>
	2	累计行驶时间	查阅机动车登记证书	单位:月
	3	比功率	发动机最大功率与总质量之比	单位:kW/kg
定性指标	4	车辆品牌	单位时间各品牌载货汽车交易量	当月二手载货汽车交易排名
	5	排放标准	国I、国II、国III、国IV、国V、国VI	按顺序由低到高依次赋值1,2,⋯,6
	6	发动机品牌	发动机交易量排名	按顺序由高到低赋值1,2,⋯,15
	7	车型	载货汽车车型交易量	按顺序由大到小赋值1,2,⋯,8
	8	车辆归属地	所属地理大区的单位面积交易量	按顺序由高到低赋值1,2,⋯,6
	9	燃料类型	柴油、LNG、汽油、混合燃料	按顺序依次赋值1,2,⋯,4
	10	上装情况	无上装、部分上装、完全上装	按顺序依次赋值1,2,3
	11	驱动类型	4×2、6×2、6×2R、6×4、8×2、8×4	按顺序依次赋值1,2,⋯,6

指标范围不同会引起极差偏大的现象,为使各指标间具有相同的度量尺度,采用归一化方法处理数据:

$$Z_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}, \quad (1)$$

式中,  $i$  为评价指标,  $Z_i$  为归一化指标值,  $X_i$  为原始数据,  $X_{\max}$  为相应原始指标最大值,  $X_{\min}$  为相应原始指标最小值。

### 1.2 指标一致性分析

为确定影响评估价值的关键指标,依据 3 家二手载货汽车电商平台的 9 016 个条交易数据,采用皮尔逊相关系数法判断指标之间的一致性分布,结果见图 1。




图 1 评价指标间相关性分布

Fig.1 Correlation distribution among evaluation indicators

由图 1 可见,除对角线数值外,指标一致性的绝对值均小于 0.596;排放标准、累计行驶时间、累计行驶里程、上装情况、车型、比功率和驱动形式为关键指标;此 7 项指标与车辆交易价值强相关,尤以排放标准与累计行驶时间、上装情况与车型、驱动类型与比功率之间的关联最为密切。

## 2 GA-BP 神经网络模型建立

针对传统回归方法(如线性回归、多项式拟合等)在基于多变量参数进行建模时,若自变量之间存在高度相关性,会使得模型稳定性和准确性受到影响。遗传算法(genetic algorithm, GA)的全局寻优能力能够优化神经网络的初始参数,可减少陷入局部最小值的风险,BP 神经网络模型在多参数建模时有更好的泛化能力,二者结合后的 GA-BP 神经网络(genetic algorithm-backpropagation neural network)模型能够提升多变量建模时的精度、鲁棒性,更适合解决本文提出的问题。

### 2.1 GA-BP 模型处理流程及原理

BP 神经网络模型在二手载货汽车价值评估过程中能够快速且准确地评估价值<sup>[12]</sup>。当 BP 神经网络模型寻找的权值或阈值不是全局最优时,评估价值仍需优化。GA 全局搜寻最优能力强,GA-BP 神经网络模型通过调用遗传算法可加快搜寻模型全局最优权值和阈值的速度并提高精度<sup>[13-15]</sup>,再通过 BP 神经网络进行自适应计算,获得误差更小的评估价值,计算流程见图 2。

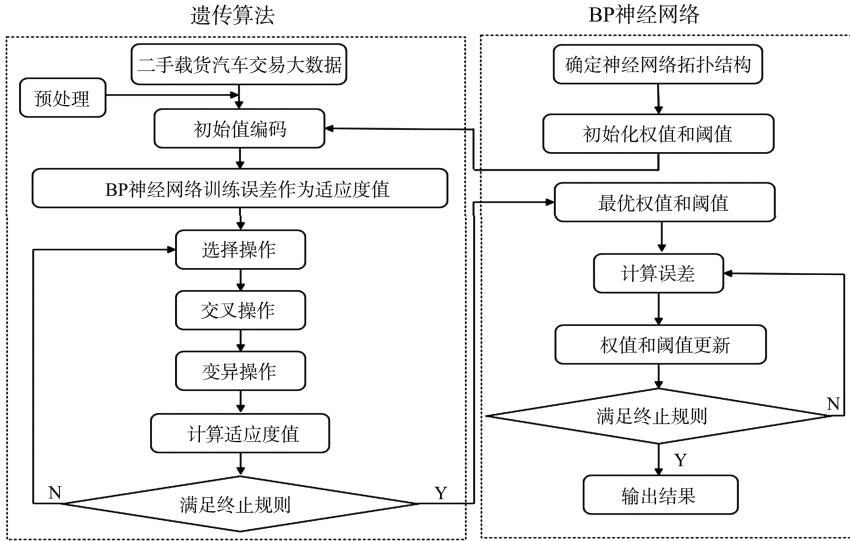


图2 GA-BP神经网络模型流程图

Fig.2 Flow chart of GA-BP neural network model

GA-BP模型结合了遗传算法和反向传播神经网络的优势,用于优化神经网络的权重和结构。假设输入层  $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ , 共有  $n$  个输入特征

### (1) 前向传播

输入计算:

$$\mathbf{z}^{(l)} = \mathbf{W}^{(l)} \mathbf{a}^{(l-1)} + \mathbf{b}^{(l)}, \quad (2)$$

式中,第  $l$  层的输入为  $\mathbf{a}^{(l-1)}$  ( $\mathbf{a}^{(0)} = \mathbf{X}$ ), 第  $l-1$  层到第  $l$  层的权重矩阵为  $\mathbf{W}^{(l)}$ , 偏置为  $\mathbf{b}^{(l)}$ 。

激活计算:

$$\mathbf{a}^{(l)} = \sigma(\mathbf{z}^{(l)}), \quad (3)$$

$$\sigma(\mathbf{z}) = \frac{1}{1 + e^{-z}}, \quad (4)$$

式中,  $\sigma(\mathbf{z}^{(l)})$  是激活函数,  $e$  为自然对数函数的底数。

输出层计算:

$$\mathbf{y}_{\text{pred}} = \mathbf{a}^{(L)}, \quad (5)$$

式中,  $L$  表示神经网络的输出层。

误差计算:

$$\mathbf{E} = \text{MSE}. \quad (6)$$

MSE (mean square error) 表示均方误差。

### (2) 反向传播

计算每一层的梯度, 并通过梯度下降更新权重和偏置。

计算输出层的误差, 每个输出神经元的误差项  $\delta^{(l)}$  为

$$\delta^{(L)} = (\mathbf{a}^{(L)} - \mathbf{Y}) \cdot \sigma'(\mathbf{z}^{(L)}), \quad (7)$$

式中,  $\mathbf{Y}$  是实际值,  $\sigma'(\mathbf{z}^{(L)})$  是激活函数对  $\mathbf{z}^{(L)}$  的导数。

对于每一层的误差项  $\delta^{(l)}$ , 从输出层向输入层逐层反向传播:

$$\delta^{(l)} = ((\mathbf{W}^{(l+1)})^T \delta^{(l+1)}) \cdot \sigma'(\mathbf{z}^{(l)}), \quad (8)$$

式中,  $\mathbf{W}^{(l+1)}$  是第  $l+1$  层的权重矩阵,  $\delta^{(l+1)}$  是第  $l+1$  层的误差。

### (3) 权重更新

$$\mathbf{W}^{(l)} = \mathbf{W}^{(l)} - \eta \frac{\partial \mathbf{E}}{\partial \mathbf{W}^{(l)}}, \quad (9)$$

式中,  $\eta$  是学习率, 梯度

$$\frac{\partial \mathbf{E}}{\partial \mathbf{W}^{(l)}} = \mathbf{a}^{(l-1)} (\delta^{(l)})^T, \quad (10)$$

$a^{(l-1)}$  是第  $l-1$  层的输出。

(4) 偏置更新

$$b^{(l)} = b^{(l)} - \eta \frac{\partial E}{\partial b^{(l)}} = b^{(l)} - \eta \delta^{(l)} \quad (11)$$

### 2.2 BP 模型参数设定

设置输入层节点数为 11, 输出层节点数为 1。单隐含层的 BP 模型即可完成高准确度评估<sup>[16-17]</sup>, 设置 1 个隐含层, 确定隐含层节点数的范围, 经不断调试来确定最佳节点数, 进而确定第一层节点数  $l$  的公式为

$$q = \sqrt{gt}, \quad (12)$$

式中,  $g$  为输入层节点数,  $t$  为输出层节点数。

经计算, BP 模型隐含层的节点数范围为 4~13 个, 通过模型训练试验, 发现当隐含层节点数为 10 个时, 模型表现最佳。学习速率的取值范围在 0.01~0.10 之间, 当学习速率较大时, 模型评估结果更接近全局最优解, 导致无法收敛; 当学习速率较小时, 模型的迭代次数增多, 收敛速度变慢。经多次训练发现模型的学习速率为 0.01 时效果最好, BP 模型拓扑结构见图 3。

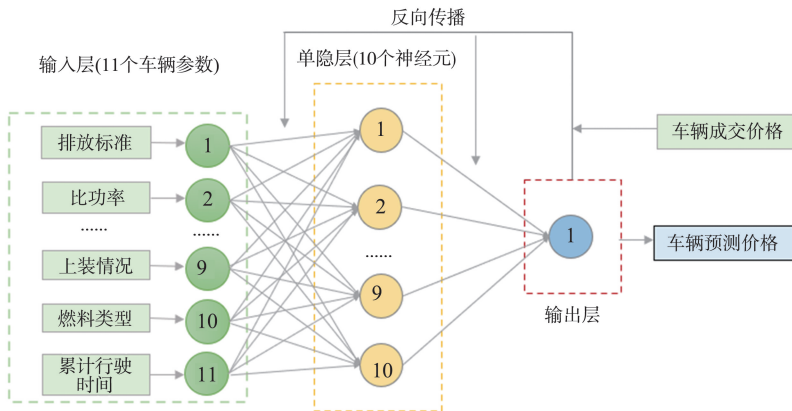


图 3 二手载货汽车评估价值的 BP 神经网络拓扑结构

Fig.3 BP neural network topology structure of used truck evaluation value

模型选取的训练目标是均方误差最小, 即模型评估价值与实际交易价值之间的误差最小, 计算公式<sup>[18]</sup>为

$$MSE = \frac{1}{n} \sum_{k=1}^n (y_k - \bar{y}_k)^2, \quad (13)$$

式中,  $n$  为训练样本数,  $y_k$  为模型的输出值,  $\bar{y}_k$  为模型的期望输出值。

均方误差值越小, 模型价值评估精度则越高, MSE 设定为  $1 \times 10^{-3}$ 。通过设置最大训练次数能够避免模型在无法达到训练目标时一直运行的现象, 模型的训练次数上限设置为 1 000 次。

### 2.3 遗传算法的设定

由于模型的输入层、隐含层和输出层的节点数分别为 11、10、1, 且 GA-BP 模型的输入层节点与隐含层节点、隐含层节点与输出层节点之间都存在连接, 因而模型输入层与隐含层之间的权值数量为 110 个, 隐含层与输出层之间的权值数量为 10 个。GA-BP 模型隐含层存在 10 个阈值和输出层的 1 个阈值, 模型整体需要优化的权值与阈值总数为 131 个, 求解步骤如下。

**步骤 1** 种群初始化。确定初始种群的范围和规模, 随机编码生成 1 组初始解作为初始种群, 每个个体代表 1 组 BP 神经网络的权值和阈值, 个体由 3 条染色体组成, 见图 4。




图 4 种群中个体的染色体结构

Fig.4 Chromosome structure of individuals in the population

步骤 2 适应度计算。将 BP 神经网络训练得到的均方误差倒数作为适应度。

步骤 3 选择操作。依据适应度和轮盘赌规则选择一定数量的个体进入下一代。

步骤 4 交叉操作。从选定的个体中按交叉概率随机选择 2 个个体进行交叉操作,生成新的子代。

步骤 5 变异操作。对新生成的后代依据变异率进行变异操作,用新生成的子代替换原种群中的一些个体,形成新一代种群。

步骤 6 若子代满足设置的终止条件,则结束迭代进程;若不满足终止条件,则重新计算二手载货汽车交易数据个体的适应度,重复进行选择、交叉和变异操作。

### 3 实例验证分析

二手载货汽车价值评估模型的训练和测试在 MATLAB R2020a 上实现。将预先量化好的 9 016 个交易数据导入 GA-BP 模型中进行训练分析,其中 8 000 个数据用于模型训练,1 016 个数据用于模型的测试。为评估模型准确度,采用相关系数分析和均方误差分析评估 GA-BP 神经网络模型精度,并与 BP 模型进行对比,通过平均影响值(mean impact value, MIV)重要性法分析确定影响二手车价值的关键指标。

#### 3.1 皮尔逊相关系数分析

采用皮尔逊相关系数衡量价值评估模型输入数据与输出结果之间的关联度。相关系数的取值范围从 -1~1,值越接近 1 或-1,表示模型的预测值与真实数据之间的关系越紧密,数学表达式为

$$R = \frac{\sum_{k=1}^n (x_k - \bar{x})(y_k - \bar{y})}{\sqrt{\sum_{k=1}^n (x_k - \bar{x})^2 \sum_{k=1}^n (y_k - \bar{y})^2}}, \tag{14}$$

式中,  $x_k$  和  $y_k$  分别表示对应变量的第  $k$  个值,  $\bar{x}$  和  $\bar{y}$  表示样本均值。

GA-BP 模型的相关系数预测结果见图 5。

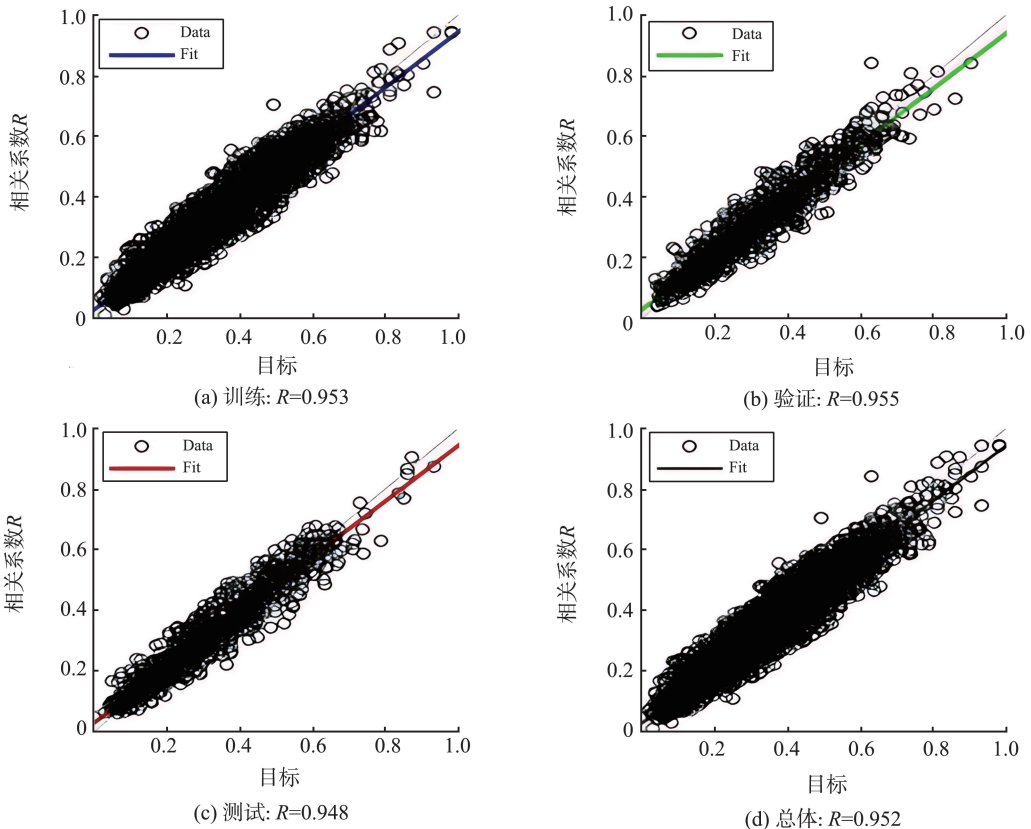


图 5 GA-BP 模型的相关系数  
Fig.5 Correlation coefficient of GA-BP model

由图 5 可见,GA-BP 模型的训练集相关系数为 0.952,验证集相关系数为 0.955,测试集相关系数为 0.948,总体相关系数为 0.952。这表明模型的输入数据与输出结果之间具有强相关性,验证了模型指标选取和神经网络参数设定的合理性。

### 3.2 均方误差分析

测试集中,BP 模型与 GA-BP 模型的均方误差结果见图 6。

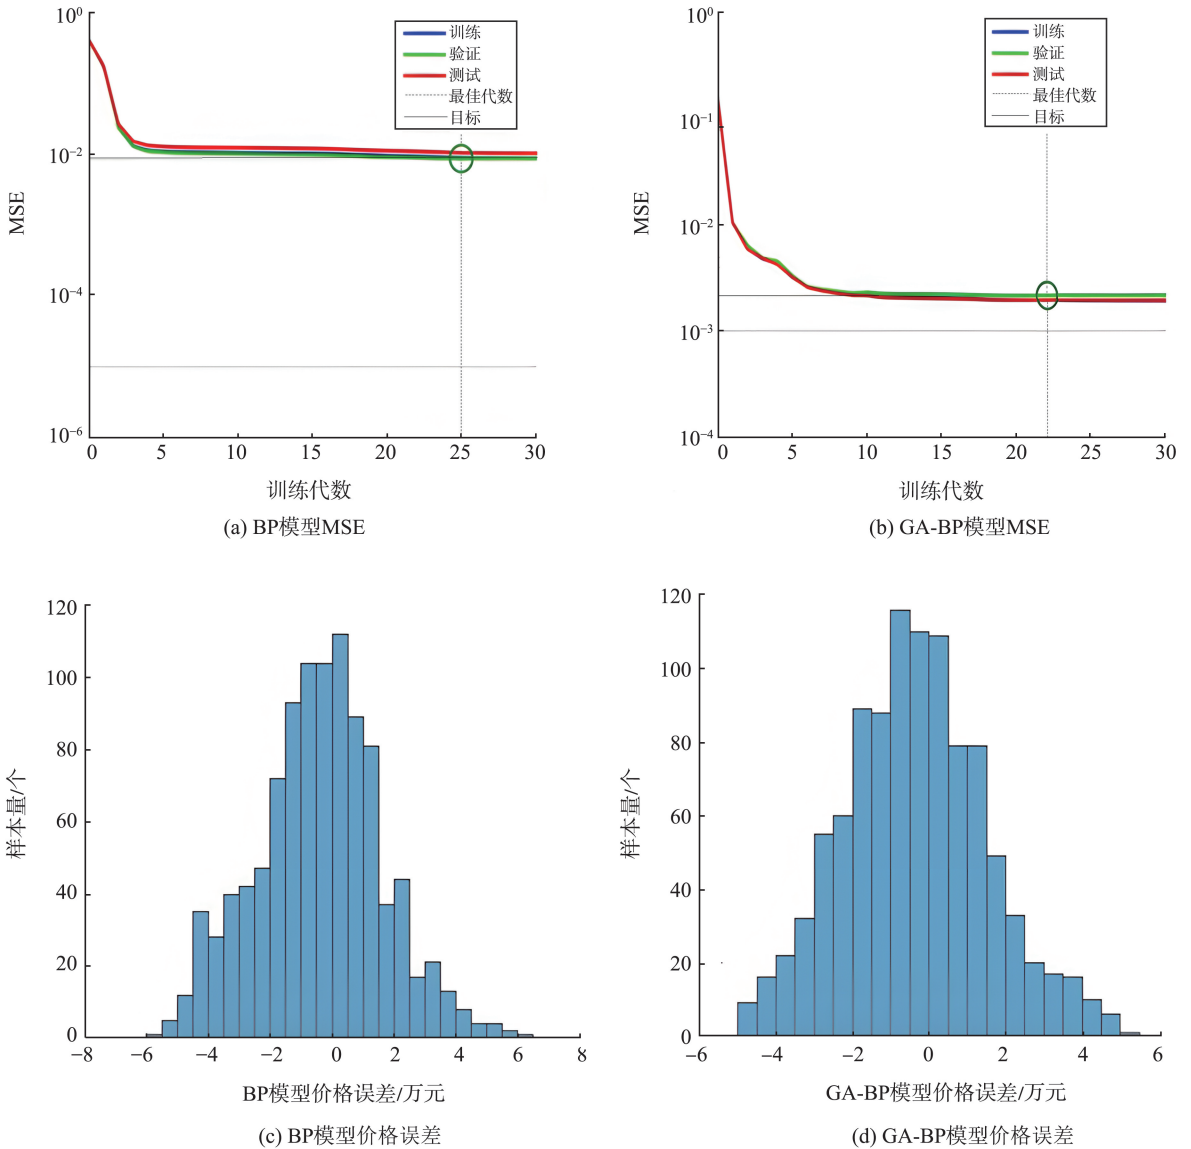


图 6 BP 与 GA-BP 神经网络模型评估效果对比

Fig.6 Comparison of evaluation effects between BP and GA-BP neural network models

由图 6 可见,GA-BP 模型最佳验证表现出现在第 22 代,  $\varepsilon_1 = 0.0022$ , 相对于 BP 模型的  $\varepsilon_0 = 0.0086$ , 整体预测误差降低了 18.18%。GA-BP 模型的评估价值误差均在 6 万元以内,70.85%集中在 2 万元以内,4~6 万元的误差占比仅为 4.82%。相比于 BP 模型,GA-BP 模型的评估价值误差范围更小,分布更加集中。

### 3.3 指标重要性分析

在神经网络中,平均影响值通过评估输入自变量对输出变量的影响程度,可筛选出对神经网络输出影响较大的输入变量。其中 MIV 的正负表示影响方向,绝对值大小表示影响程度。具体计算方法是对自变量特征指标值进行加减 10%,构建新的训练样本,计算对输出的影响变化值(impact value, IV),并取平均值得到 MIV,最终根据 MIV 的绝对值大小对各自变量的影响程度进行排序,可以帮助识别和选择对模型输出影响最大的输入变量。MIV 的数学表达式为

$$MIV = \frac{1}{n} \sum_{k=1}^n (y_{up}^{(k)} - y_{down}^{(k)}), \quad (15)$$

式中,  $y_{up}^{(s)}$  表示第  $k$  个样本中变量提升 10% 后的预测值,  $y_{down}^{(k)}$  表示第  $k$  个样本中变量下降 10% 后的预测值。运用 MATLAB R2020a 对各指标变量分别增加或减少 10%, 预测模型运算后的 MIV 值。重复多次 MIV 的求取过程, 将同一价值评估指标的多个结果取平均值后获得 MIV, 见图 7。




图 7 二手载货汽车价值评估指标的 MIV 值

Fig.7 MIV value of used truck value evaluation index

由图 7 可见, 累计行驶里程、累计行驶时间是评价车辆实体性贬值的关键指标, 对应的 MIV 分别为 -1.392、-1.169, 二者 MIV 的绝对值均超过 1.000; 排放标准的 MIV 值为 1.018, 在节能减排和环境保护的要求下, 排放标准为国 III、国 IV 的车辆在道路限行、过户迁入等方面均受限制, 购车者更倾向于排放标准为国 V、国 VI 的车辆; 比功率的 MIV 为 0.752, 仅次于排放标准, 这与载货汽车的使用特性相关, 与乘用车不同, 载货汽车价值主要体现在货物运输能力方面, 比功率大的载货汽车, 运输货物的能力越强。上装情况的 MIV 为 0.644, 对二手载货汽车的价值贡献度较大, 因为车厢上装越复杂的载货汽车更适应运输价值密度高的货物。其他指标的贡献度相对较小, 但为了全面评估二手载货汽车的价值, 仍然是不可忽略的要素。综上, 累计行驶里程、累计行驶时间、排放标准、比功率和上装情况 5 项价值评估指标与二手载货汽车价值关系最为密切, 其他指标所占的权重偏小。

### 3.4 模型对比实验分析

为评估 GA-BP 模型的拟合优度, 选择 BP、GA 和随机森林 3 种模型对比分析, 选用决定系数  $R^2$ 、平均绝对误差 (mean absolute error, MAE)、均方误差和均方根误差 (root mean square error, RMSE) 作为评判模型性能优劣的标准。各评估误差指标的计算公式如下:

$$R^2 = 1 - \sum_{k=1}^n \left( \frac{y_k - \hat{y}_k}{y_k - \bar{y}} \right)^2, \quad (16)$$

$$MAE = \frac{1}{n} \sum_{k=1}^n |\hat{y}_k - y_k|, \quad (17)$$

$$MSE = \frac{1}{n} \sum_{k=1}^n (\hat{y}_k - y_k)^2, \quad (18)$$

$$RMSE = \frac{1}{n} \sum_{k=1}^n (\hat{y}_k - y_k)^2, \quad (19)$$

式中,  $y_k$  分别表示第  $k$  个样本值,  $\hat{y}_k$  表示第  $k$  个样本的预测值。

GA-BP 模型与 3 种其他模型精度对比结果见表 2。

表 2 GA-BP 模型与 3 种模型精度对比  
Table 2 Comparison of the accuracy of the GA-BP model and the other three models

评价指标	GA-BP 模型	BP 模型	GA	随机森林
$R^2$	0.983 0	0.762 6	0.783 1	0.834 5
MAE	0.081 0	0.137 8	0.153 2	0.125 7
MSE	0.000 1	0.005 8	0.006 9	0.003 2
RMSE	0.010 9	0.076 4	0.083 2	0.056 6

由表 2 可见,GA-BP 神经网络模型的测试数据线性回归系数  $R^2$  达到了 0.983 0,高于 BP 模型 0.220 4、GA 算法 0.199 9 和随机森林 0.148 5,表明 GA-BP 模型在评估二手商用车价值时能更准确地逼近真实成交价格;GA-BP 模型的 3 类误差指标均低于 BP 模型、GA 算法和随机森林模型,具有 0.000 1 的最低 MSE;GA-BP 模型收敛快,能快速达到最优效果,迭代效率高于其他 3 种模型。

为验证 GA-BP 模型预测值的准确性,采集 10 辆二手载货汽车的真实交易价格,对比 4 种模型的预测值与真实交易价格的预测偏差率,结果见图 8。




图 8 4 种模型预测值与真实价格对比

Fig.8 Comparison of 4 model predictions with actual prices

由图 8 可见,采用 GA-BP 模型、BP 模型、GA 算法和随机森林预测 10 辆二手载货汽车价值的误差范围分别为[2.30%, 6.20%]、[5.86%, 12.04%]、[6.07%, 13.41%]和[5.06%, 10.10%];GA-BP 模型的预测价格较 BP 模型、GA 算法和随机森林更接近于真实价格,其预测价格与真实成交价格的偏差率在 6.20% 以内。

## 4 结语

基于我国二手载货汽车电商平台发展现状及其历史交易大数据,从多角度进行全面分析,选择评价指标及提出指标量化标准,论证了依据二手载货汽车交易大数据建立 GA-BP 二手载货汽车价值评估模型的可行性,为运用交易大数据实现车辆价值评估的方法研究提供了依据。在建立价值评估指标体系和评估指标量化时,由于是人为选择和量化,难以避免存在一定主观性,可能在一定程度上影响价值评估的结果。在未来的实际应用中,需制定规范、细致的评估和量化标准,避免主观性对评估结果造成干扰。

### 参考文献:

- [1] 中华人民共和国商务部. 二手车鉴定评估技术规范:GB/T 30323—2013[S]. 北京: 中国标准出版社, 2013:1.  
Ministry of Commerce of the People's Republic of China. Technical specification for appraisal of used cars; GB/T 30323—2013[S]. Beijing: China standard Press, 2013:1.
- [2] 王乾,冯强. 2019 年中国二手车电商行业研究报告[J]. 互联网经济, 2019, 50(6): 62-67.  
WAN Qian, FENG Qiang. China used car e-commerce industry research report in 2019[J]. Digital Economy, 2019, 50(6): 62-67.
- [3] 胡诣文,张天佑,张旭,等. 基于机器学习的二手车价格预测算法研究[J]. 信息技术与信息化, 2022, 271(10): 52-55.

- HU Yiwen, ZHANG Tianyou, ZHANG Xu, et al. Research on used car price forecasting algorithm based on machine learning [J]. *Information Technology and Informatization*, 2022, 271(10):52-55.
- [4] 王传杏,郑艳,沈易晨. 基于特征价格理论的二手车价值估计模型研究[J]. *时代汽车*, 2020, 345(21):170-172.  
WANG Chuanxing, ZHENG Yan, SHEN Yichen. Research on value estimation model of used cars based on feature price theory[J]. *Auto Time*, 2020, 345(21):170-172.
- [5] 代金辉,仲璇,王梦恩. 基于 LightGBM 和随机森林算法的二手车估价[J]. *高师理科学刊*, 2022, 42(12):15-22.  
DAI Jinhui, ZHONG Xuan, WANG Meng'en. Second-hand car valuation based on LightGBM and random forest algorithm[J]. *Journal of Science of Teachers' College and University*, 2022, 42(12):15-22.
- [6] PRIETO M, CAEMMERER B, BALTAS G. Using a hedonic price model to test prospect theory assertions: the asymmetrical and nonlinear effect of reliability on used car prices[J]. *Journal of Retailing and Consumer Services*, 2015, 22(1):206-212.
- [7] SYAHPUTRA I, ZARLIS M, SUTARMAN. Analysis of the application of fuzzy logic and Levenbergmarquardt in the calculation of used car prices[J]. *Journal of Physics Conference Series*, 2020, 1566(1):012106.
- [8] ALEXSTAN A S J, MONESH K M, POONKODI M, et al. Used car price prediction using machine learning[J]. *Advances in Science and Technology*, 2023, 6630(3):512-517.
- [9] 杨致远. 基于 PCA-DNN 和 LightGBM 的二手车价格预测[J]. *信息与电脑*, 2022, 34(21):73-75.  
YANG Zhiyuan. Prediction of the transaction price of used car based on PCA-DNN and LightGBM [J]. *Information & Computer*, 2022, 34(21):73-75.
- [10] 李富强,彭海丽,杨熙,等. 基于深度学习的二手车价格预测模型及影响分析[J]. *汽车工程学报*, 2021, 11(5):379-385.  
LI Fuqiang, PENG Haili, YANG Xi, et al. Prediction modelling of second-hand car price based on deep learning and influence factors analysis[J]. *Chinese Journal of Automotive Engineering*, 2021, 11(5):379-385.
- [11] DEDY S, ALFIAN T, DONNY B. A data mining approach to predicting the inventory day of used cars [J]. *International Journal of Knowledge Engineering and Data Mining*, 2021, 7(1-2):127-144.
- [12] 张远森. 基于神经网络的二手车价格评估模型[D]. 天津:天津大学, 2019:46-47.  
ZHANG Yuansen. A used cars' price forecasting model based on artificial neural network[D]. Tianjin: Tianjin University, 2019.
- [13] FU Yuan, CHEN Xiang, LIU Yu, et al. Multi-sensor GA-BP Algorithm based gearbox fault diagnosis[J]. *Applied Sciences*, 2022, 12(15):7535.
- [14] LIU J, ASHRAF M A. Face recognition method based on GA-BP neural network algorithm [J]. *Open Physics*, 2018, 16(1):1056-1065.
- [15] ZOU Meng, XUE Long, GAI Hongjian, et al. Identification of the shear parameters for lunar regolith based on a GA-BP neural network[J]. *Journal of Terramechanics*, 2020, 89(2):21-29.
- [16] 曹镓玺,王鑫,雷光春. 基于遗传算法优化 BP 神经网络的青藏高原海北高寒湿地 CO<sub>2</sub> 通量模拟及其影响因子[J]. *山东大学学报(理学版)*, 2021, 56(5):33-41.  
CAO Jiayi, WANG Xin, LEI Guangchun. Simulation of alpine wetlands CO<sub>2</sub> flux and its influencing factors based on BP neural network optimized by genetic algorithm in Qinghai-Tibet Plateau [J]. *Journal of Shandong University (Natural Science)*, 2021, 56(5):33-41.
- [17] LIU Junbiao, JIN Xinyu, DONG Fang, et al. Fading channel modelling using single-hidden layer feedforward neural networks [J]. *Multidimensional Systems and Signal Processing*, 2016, 28(1):885-903.
- [18] 王静红,吴芝冰,黄鹏,等. 基于元路径属性融合的异质网络表示学习[J]. *山东大学学报(理学版)*, 2024, 59(3):1-13.  
WANG Jinghong, WU Zhibing, HUANG Peng, et al. Heterogeneous network representation learning based on metapath attribute fusion[J]. *Journal of Shandong University (Natural Science)*, 2024, 59(3):1-13.

(编辑:唐秋)