

# 基于粒子群优化与BP神经网络的电动物流车充电需求预测

于泽霞, 刘华琼\*

山东交通学院交通与物流工程学院, 山东 济南

收稿日期: 2024年12月1日; 录用日期: 2024年12月13日; 发布日期: 2025年2月13日

## 摘要

为优化电动物流车充电需求预测方法, 本文结合粒子群优化算法(PSO)和BP神经网络技术, 对电动物流车的充电需求进行了系统性定量研究。首先, 通过多元回归分析和主成分分析, 从复杂多变的影响因素中提取关键变量, 如车辆运行路径、电池容量、行驶距离和充电时间分布等。然后, 基于提取的主要影响因素, 构建了PSO-BP神经网络预测模型。根据预测的主要考虑因素, 建立了PSO-BP神经网络预测模式。粒子群优化理论主要用来优化BP神经网络的初始权值和阈值, 从而提高模型的预测准确度和减少了局部最优预测问题。通过实验验证, 本研究模型在预测电动物流车充电需求方面表现出显著的精确性和可靠性。

## 关键词

电动物流车, 充电需求预测, 粒子群优化, BP神经网络

# Prediction of Charging Demand for Electric Logistics Vehicles Based on Particle Swarm Optimization and BP Neural Network

Zexia Yu, Huaqiong Liu\*

School of Transportation and Logistics Engineering, Shandong Jiaotong University, Jinan Shandong

Received: Dec. 1<sup>st</sup>, 2024; accepted: Dec. 13<sup>th</sup>, 2024; published: Feb. 13<sup>th</sup>, 2025

## Abstract

To optimize the prediction method of charging demand for electric logistics vehicles, this paper combines particle swarm optimization algorithm (PSO) and BP neural network technology to

\*通讯作者。

文章引用: 于泽霞, 刘华琼. 基于粒子群优化与 BP 神经网络的电动物流车充电需求预测[J]. 电力与能源进展, 2025, 13(1): 9-20. DOI: 10.12677/aepe.2025.131002

conduct a systematic quantitative study on the charging demand of electric logistics vehicles. Firstly, through multiple regression analysis and principal component analysis, key variables such as vehicle operating path, battery capacity, driving distance, and charging time distribution are extracted from complex and variable influencing factors. Then, based on the extracted main influencing factors, a PSO-BP neural network prediction model was constructed. Based on the main considerations of prediction, a PSO-BP neural network prediction mode was established. Particle swarm optimization theory is mainly used to optimize the initial weights and thresholds of BP neural networks, thereby improving the prediction accuracy of the model and reducing local optimal prediction problems. Through experimental verification, this research model demonstrates significant accuracy and reliability in predicting the charging demand of electric logistics vehicles.

## Keywords

Electric Logistics Vehicle, Charging Demand Forecast, Particle Swarm Optimization, BP Neural Network

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

随着全球能源危机和环境问题的日益严峻,电动物流车凭借其环保、高效和经济的优势,逐渐成为现代物流运输领域的重要组成部分。然而,随着电动物流车规模的迅速增长,其充电需求的不确定性和复杂性对充电基础设施的建设与运营提出了新的挑战。如果充电需求预测不准确,可能导致充电桩资源利用率低下,或因供给不足而引发大规模的拥堵问题,进而影响物流系统的运行效率。因此,研究高效、准确的充电需求预测方法对于提升电动物流车的运营效率和保障能源系统的稳定具有重要意义。

目前,传统的充电需求预测方法主要依赖于线性回归、时间序列分析等统计学模型。然而,由于电动物流车的运行特点具有非线性和随机性,这些传统方法在处理复杂的非线性问题时表现出一定的局限性。曹小曙[1]从地理学视角对电动汽车选址的影响因素、研究方法以及成本-效益评估进行了综述性的研究,提出了电动汽车基础设施布局优化的理论框架。田梦瑶[2]和 Shepero [3]都运用了马尔科夫链模拟方法,来对电动汽车的出行链进行建模,以此达到预测电动汽车需求的目的。在此基础上,罗晴川[4]通过引入更加符合实际的拉格朗日松弛法对充电负荷进行预测,进一步提高了预测的精度。而 Afshar [5]则提出了一种基于蒙特卡洛算法的时空方案,用于交通管理中的充电需求分析。近年来,基于灰色预测法对电动汽车相关数据进行预测的研究层出不穷。Luo [6]提出了一个基于灰色预测法的电动汽车保有量预测模型,李菱[7]则运用了交通流量平衡原理,将充电需求聚集为代表点,并对电动汽车保有量进行预测分析。李鑫[8]基于充电设施合理布局的原则,提出了千人保有量法和弹性系数法,用以预测电动汽车的数量。这些方法为不同地区的充电需求预测提供了理论基础。此外,部分研究还结合了其他相关理论,进一步提升了需求预测的准确性。Bautista [9]在需求预测中引入了智能交通系统理论,将电动汽车前往各候选充电站的总行程时间与路由协议中的通信延迟问题结合起来进行了深入研究。而龙虹毓[10]针对山地城市的特殊情况,分析了电动汽车用户的充电特性及山地城市道路的空间特性,建立了电动汽车单车耗电模型,并提出了一种适用于山地城市的充电站规划新方法。这些研究为电动汽车充电基础设施的规划与管理提供了多种创新的思路和方法。

本研究旨在通过改进的 PSO-BP 神经网络模型, 提供一种高效、准确的充电需求预测方法, 为城市电动物流车充电基础设施的规划和电力资源调度提供技术支持。研究结果不仅能够提升充电站的利用率, 减少资源浪费, 还能有效缓解电网的负荷压力, 从而推动绿色物流运输体系的可持续发展。

## 2. 研究方法

### 2.1. 灰色预测模型与粒子群优化

#### 2.1.1. 经典灰色预测

灰色预测, 也称模糊预测, 是一种在已知部分具体信息但仍存在部分内部信息未知或不确定的情况下进行问题研究的方法。它常被应用于数据不完整的预测研究, 例如对 1986 年至 1992 年期间城市道路噪声平均声级的预测。虽然数据本身的表现规律性较弱, 但其本质是有序且有界的。通过对数据进行求和、累加等处理, 可以挖掘其中潜在的规律性, 使其具有进一步开发和利用的可能性。

#### 2.1.2. 基于粒子算法的灰色预测

粒子群算法[11]是一种受鸟类群体飞行觅食行为启发的优化算法, 可以看作是鸟类(即粒子)在一个  $D$  维空间中进行优化搜索的过程。在这个过程中, 每个粒子都会根据特定指标评估自身的适应值, 从而判断当前所在位置的优劣。同时, 粒子能够记忆自己曾经找到的最优位置。粒子的运动由初始矢量决定, 包括其飞行的距离和方向; 该矢量会依据粒子自身的飞行经验以及群体中其他粒子的飞行经验动态调整。在一个  $n$  维搜索空间中, 第  $i$  个粒子的位置和速度可以分别表示为:

$$x_{i(t)} = x_{i1(t)}, x_{i2(t)}, \dots, x_{in(t)}, v_i = v_{i1}, v_{i2}, \dots, v_{in} \quad (1)$$

在粒子群算法的运行过程中, 首先通过随机生成初始群体的位置和速度向量, 构建初始种群。在每次迭代过程中, 算法不断更新粒子的速度和位置, 以逐步逼近最优解。每轮迭代中, 粒子的速度更新遵循以下公式:

$$v_{ij}(t+1) = \omega v_{ij}(t) + \varphi c_1 r_1 [p_{ij}(t) - x_{ij}(t)] + c_2 r_2 [p_{gj}(t) - x_{ij}(t)] \quad (2)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t) \quad (3)$$

式中:  $v$  为粒子速度;  $\omega$  为惯性权重系数;  $c_1, c_2$  为加速因子;  $\varphi$  为  $[0, 1]$  区间内变化的随机数, 服从  $[0, 1]$  上的均匀分布, 表示粒子个人意愿。

针对电物流车充电需求量的预测问题, 可采用基于粒子群算法的灰色模型 GM(1, 1) 构建指数模型, 如式(4)所示, 分析电物流车保有量的影响因素。本节目标是利用编程工具实现基于粒子群算法的灰色预测过程, 通过搜索一组  $q_i (i = 1, 2, \dots, n)$ , 在最优权重  $q$  下, 使得各年度充电需求量的综合预测误差  $W$  最小, 如式(5)所示。

$$D = \prod_{i=1}^n x_i^{q_i} \quad (4)$$

$$W = \sum_j \left| \prod_{i=1}^n x_{ij}^{q_i} - D_j \right| \quad (5)$$

式中:  $D$  为电物流车充电需求预测值;  $D_j$  为载货汽车保有量既有年份数据;  $n$  为电物流车充电需求影响因素个数;  $X_i$  为第  $i$  个充电需求影响因素的值;  $q_i$  为第  $i$  个影响因素的权重系数;  $W$  为综合预测误差。

#### 2.1.3. SPSS 软件中的 BP 神经网络工具箱

SPSS 主成分分析是一种基于数据分析的方法, 用于量化不同影响因素对特定研究指标的影响程度。通过使用 SPSS 软件的主成分分析功能, 可以对大量数据进行系统整理, 从中筛选出对研究问题具有“主

导性”的一项或多项关键因素。该方法能够直观地展示各影响因素与研究指标之间的关系, 并通过线性表达式加以描述, 从而在预测过程中有效剔除干扰项。主成分分析的核心目标是提升后续研究的针对性和准确性, 为研究提供更加科学的基础支持。

BP神经网络是一种包含隐含层的前馈神经网络, 基于误差反向传播算法进行训练。其结构由输入层、隐含层和输出层组成: 输入层用于接收各项指标数据, 隐含层执行网络的内部运算, 输出层则输出预测的目标结果。在BP神经网络的每一层中, 包含一个或多个神经元, 层内神经元之间没有连接, 并且连接权重基于特定的权重系数进行调整。通过MATLAB中的BP神经网络工具箱, 可以方便快捷地实现该模型的搭建和应用, 满足复杂预测任务的需求。

### 2.1.4. 组合预测

通过对前述两种算法所得结果进行加权平均, 重新计算得到最终的组合预测结果。该模型可表示为式(6), 其中 $M$ 和 $N$ 为加权系数, 需满足约束条件 $M + N = 1$ 。

$$Q = MQ_1 + NQ_2 \tag{6}$$

式中:  $Q$  为载货汽车保有量预测值;  $Q_1$  为基于粒子群算法的灰色预测模型预测值;  $Q_2$  为BP神经网络预测值。

### 2.1.5. 电动物流车充电需求量预测思路

本研究围绕电动物流车的充电需求预测展开。首先, 以现有的载货汽车保有量数据为基础, 结合经典灰色预测模型和粒子群算法构建精准的预测模型。模型建立过程中, 采用SPSS软件的BP神经网络工具箱对数据进行处理和分析, 充分利用BP神经网络的非线性映射能力和自学习能力。

其次, 在模型结果的分析阶段, 通过对比分析不同预测模型的结果, 采用组合预测法对结果进行加权计算, 从而提高整体预测的准确性。预测结果涵盖未来城市载货汽车保有量的预测值, 并通过电动物流车分担率的假设和分析, 将保有量转换为电动物流车的保有量及充电需求。

最后, 通过对未来电动物流车充电需求的定量化计算, 形成城市电动物流车充电需求的最终预测结果, 体如图1所示。

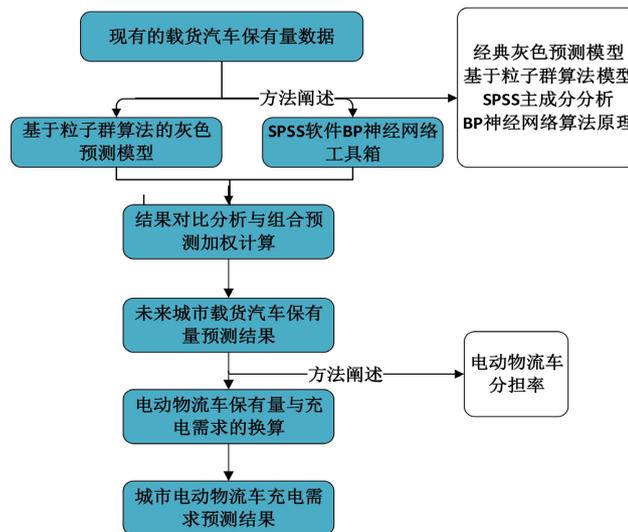


Figure 1. Train of thought for predicting the demand for electric logistics vehicle charging

图1. 电动物流车充电需求量预测思路图

### 3. 数据收集与处理

通过对相关领域的研究和实践进行深入分析, 结合问卷调查和专家经验总结, 本文对影响电动物流车保有量的诸多因素进行了筛选和归纳。最终选取了七个具有显著影响的关键因素, 如表 1 所示。这些因素不仅在理论上具有合理性, 且通过数据分析和实证研究进一步验证了其在实际预测中的重要性。

**Table 1.** The number of electric logistics vehicles and related influencing factors

**表 1.** 电动物流车保有量及相关影响因素

序号	保有量影响因素	影响关系	序号	选取结果
1	户籍人口	正相关	x1	户籍人口(万户)
2	城市居民人均可支配收入	正相关	x2	城市居民人均可支配收入(元)
3	人均地区生产总值	正相关	x3	人均地区生产总值(元)
4	公路货运量	正相关	x4	城市道路长度(公里)
5	人均快递业务收入	正相关	x5	人均快递业务收入
6	柴油年平均价格(元)	负相关	x6	92#汽油年平均价格(元)
7	物流从业人员平均工资(元)	正相关	x7	职工平均工资(元)

数据来源于济南市 2011~2023 年的电动物流车保有量及相关影响因素。核心数据包括户籍人口、人均地区生产总值、公路货运量等, 标准化处理后数据如表 2 所示:

**Table 2.** System resulting data of standard experiment

**表 2.** 标准试验系统结果数据

主成分	数据	初始特征值方差百分比	方差贡献率	成分得分
1	5.681	81.16	81.16%	0.399
2	0.911	13.015	94.18%	0.407
3	0.372	5.314	99.49%	0.402
4	0.029	0.41	99.90%	0.394
5	0.006	0.082	99.98%	0.42
6	0.001	0.012	99.99%	-0.17
7	0	0.006	100%	0.412

标准化后的第一主成分表达式为(6):

$$Y = 0.399x_1 + 0.407x_2 + 0.402x_3 + 0.394x_4 + 0.420x_5 - 0.170x_6 + 0.412x_7 \quad (6)$$

对济南市载货汽车保有量与第一主成分之间关系进行多元回归分析。回归系数表如图 2 所示, 结果证明载货汽车保有量与第一主成分之间的关系为线性关系。

表 3 为 SPSS 模型回归系数表, 由表 3 分析结果可整理得到济南市民用载货汽车保有量与第一主成分之间关系的回归方程如式(7)所示, 表 4 为 2024 年主成分数据预测值。

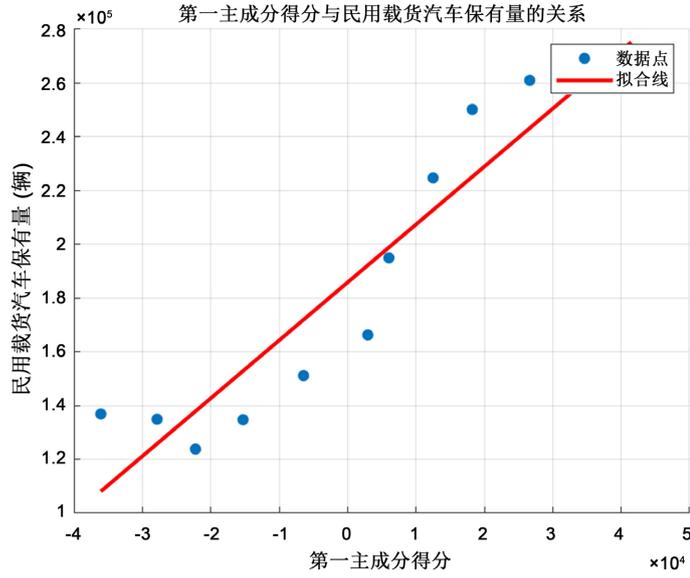


Figure 2. Relationship between the first principal component and the number of civilian cargo vehicles in Jinan City

图 2. 第一主成分与济南市民用载货汽车保有量关系图

Table 3. SPSS model regression coefficient table  
表 3. SPSS 模型回归系数表

模型	未标准化系数		标准化系数		t	共线性统计	
	B	标准错误				显著性	容差
1 (常量)	156.040	2.236			69.780	0.000	
Y	29.866	1.209	0.994		24.713	1.000	1.000

$$Z = 29.866Y + 156.040 \tag{7}$$

Table 4. Predicted values of principal component data for Jinan City in 2024  
表 4. 济南市 2024 年主成分数据预测值

年份	X1	X2	X3	X4	X5	X6
2024	881.6	58283	137496	9547	18653	8.15

## 4. 研究范围内电动汽车充电需求总量预测

### 4.1. 粒子群优化算法求解

对粒子群算法计算的参数进行如表 5 所示设置, 可以高效且稳定地输出结果。其中 C1、C2 为加速因子, time 为迭代次数, size 为种群规模。

Table 5. PSO calculation parameter settings  
表 5. PSO 计算参数设置

参数	初始	$\omega$	C1	C2	time	size
值	0.9		2	2	50	100

利用上述设置好的参数对模型进行迭代求解, 粒子群迭代收敛曲线如图 3 所示:

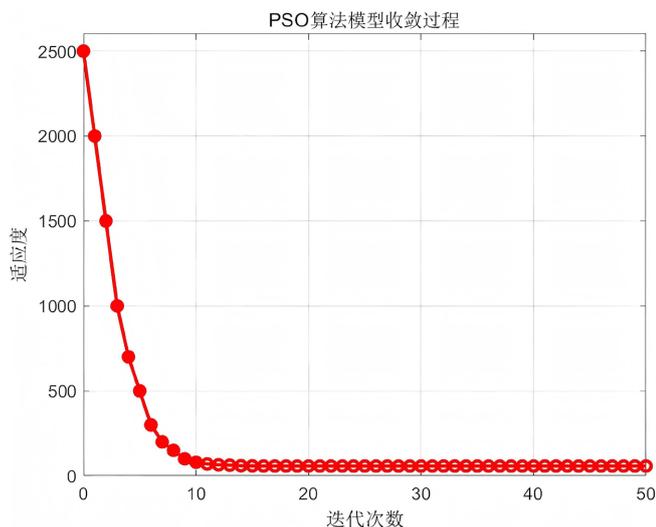


Figure 3. PSO algorithm model convergence process diagram

图 3. PSO 算法模型收敛过程图

粒子群迭代次数达到 20 次时逼近最优解, 故本次求解的迭代次数符合标准。

模型在  $W$  达到  $3.45594e-11$  时寻得粒子群的最适应值, 寻得最优解。为方便后续计算, 对得到的权重指数进行归一化处理, 最终可得出最优权重指数  $q$  的计算结果, 如表 6 所示。根据计算得到往年汽车保有量预测值, 将其与真实值对比, 如表 5~10 所示。除了 2016 年与 2017 年以外, 其余各组年份预测结果相对误差均在 5% 范围以内, 故粒子群算法应用到载货汽车保有量的预测中是有效的且符合实际。

Table 6. Calculation results of weight index  $q$

表 6. 权重指数  $q$  的计算结果

权重指数	q1	q2	q3	q4	q5	q6	q7
最优值	0.1971	0.2059	0.1876	0.1374	0.1764	-0.142	0.2376

Table 7. Comparison of particle swarm optimization prediction results

表 7. 粒子群算法预测结果对比

年份	主成分 Y	真实值	预测值	相对误差绝对值
2013	-2.49	136,874	132,220	3.40%
2014	-2.1	134,929	131,421	2.60%
2015	-1.72	123,801	123,430	0.30%
2016	-0.79	134,741	123,153	8.60%
2017	-0.45	151,141	142,677	5.60%
2018	-0.1	2023	162,120	2.50%
2019	0.53	2023	189,303	2.90%
2020	1.06	224,713	216,399	3.70%
2021	2.94	250,200	238,441	4.70%
2022	3.12	261,017	259,190	0.70%
2023	3.28	265,349	257,123	3.10%

### 4.2. BP 神经网络工具箱求解

本节采用 Matlab R2023a 中的神经网络拟合工具箱(Neural Net Fitting)对历年载货汽车保有量数据进行 BP 神经网络预测。BP 神经网络虽然在处理复杂问题时具有较强的拟合能力, 但由于其计算过程较为复杂, 收敛速度较慢, 且训练精度难以满足高精度预测的需求, 因此需要对相关输入因素进行合理选择。通过前期分析, 本研究选取了与载货汽车保有量高度相关的三个主要因素: 城市居民人均可支配收入、公路货运量和快递业务收入, 这三个因素与多元线性回归模型中相关度最高的变量一致。

为构建神经网络模型, 本文使用了过去 70% 的数据作为训练样本, 并选取与上述三个因素相关的 10 组数据。通过 Matlab 神经网络工具箱中的相应函数进行数据处理。训练过程中的各个状态及回归界面分别如图 4 和图 5 所示, 展示了模型的训练过程和回归分析结果。

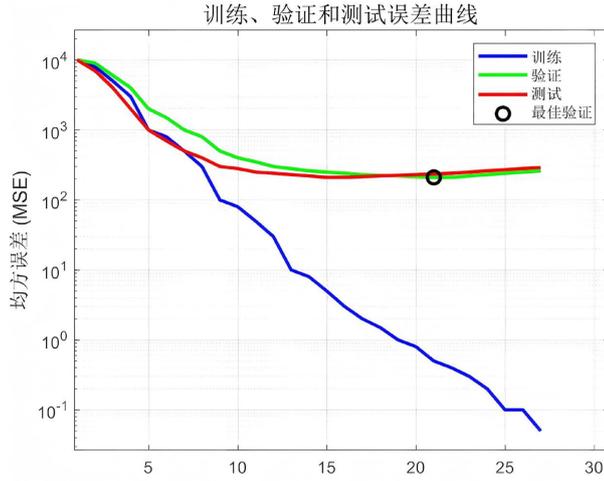


Figure 4. Neural network iteration process diagram  
图 4. 神经网络迭代过程图

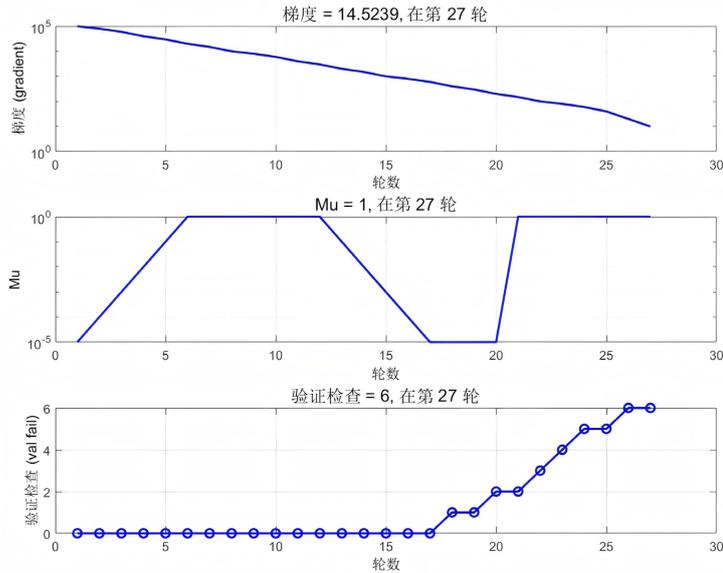


Figure 5. BP neural network training state diagram  
图 5. BP 神经网络训练状态图

上述分析表明, BP 神经网络在载货汽车保有量中的应用符合预测标准, 其可用性以及科学性得到了保障。将 2013~2023 年以往的相关数据带入 BP 神经网络模型中可得到如表 8 的结果对比。

**Table 8.** Comparison of BP neural network prediction results

**表 8.** BP 神经网络预测结果对比

年份	真实值	预测值	相对误差绝对值
2013	136,874	133,276	2.70%
2014	134,929	133,593	1.00%
2015	123,801	123,431	0.30%
2016	134,741	133,937	0.60%
2017	151,141	142,720	5.90%
2018	166,277	165,945	0.20%
2019	194,957	194,762	0.10%
2020	224,713	220,091	2.10%
2021	250,200	248,214	0.80%
2022	261,017	259,977	0.40%
2023	265,349	261,685	1.40%

#### 4.3. 组合预测济南市电动汽车保有量

根据数据走势分析, 两种预测方法在表现规律上相互独立, 且由于当前研究的深度尚有局限性, 为了保证预测结果的客观性, 本文对两种方法分别赋予了权重 0.4 和 0.6。通过对两种预测结果进行加权处理, 得到了组合预测的最终结果。接下来, 本文将组合预测结果与实际值进行比较, 既可以通过绝对值的对比, 也可以通过误差的偏差率来校核预测精度。

根据表 9 的结果分析, 组合预测的误差基本控制在 5% 以内, 并且误差的集中性较好, 大部分误差值趋于零。这表明, 与单一预测方法相比, 组合预测结果更加稳定, 预测效果也更为理想。

**Table 9.** Comparison table of results of three prediction methods

**表 9.** 三种预测方法结果对比表

年份		粒子群算法校核		BP 神经网络校核		组合模型校核	
time	real	Pre check	Offset	Pre check	Offset	Pre check	Offset
2013	136874	132220	3.40%	133276	2.70%	132853	2.94%
2014	134929	131421	2.60%	133593	1.00%	132724	1.63%
2015	123801	123430	0.30%	123431	0.30%	123430	0.30%
2016	134741	123153	8.60%	133937	0.60%	129624	3.80%
2017	151141	142677	5.60%	142720	5.90%	142703	5.58%
2018	166277	162120	2.50%	165945	0.20%	164415	1.12%
2019	194957	189303	2.90%	194762	0.10%	192579	1.22%
2020	224713	216399	3.70%	220091	2.10%	218614	2.71%

续表

2021	250,200	238,441	4.70%	248,214	0.80%	244305	2.36%
2022	261,017	259,190	0.70%	259,977	0.40%	259662	0.52%
2023	265,349	257,123	3.10%	261,685	1.40%	259861	2.07%

#### 4.4. 济南市 24 h 内充电需求预测

由前文分析可得 2024 年济南市载货汽车保有量预测值为： $281,255 \times 0.4 + 278,673 \times 0.6 = 279,705$  (辆)，根据《山东省济南市各类型民用载货汽车数量 3 年数据洞察报告》2023 年版，在全市载货汽车总量中，电动物流车的比例逐年上升，已成为新能源物流车推广的主力。轻型物流车用于快递、零售配送等，其占比可能接近 30%~40%。目前电动物流车在所有载货汽车中的占比约为 35%， $279,705 \times 35\% = 97,896$  (辆)。

市面上常见电动物流车的电池容量九州 2.6T 4.5 米纯电动物流车：电池容量为 49.64 kWh，续航里程为 255 km。现有充电效率约为 90%，快充模式(1 小时充满)  $P = 49.64/1 \times 0.9 = 55.16$  kW，慢充模式(6 小时充满)  $P = 6 \times 0.949.64 = 9.21$  kW。根据全国其他城市的物流车充电习惯，现有的物流车日均行驶里程约 100,150 km；慢充和快充的比例通常为 70%~80%慢充，若车辆以慢充模式为主，每次充电可以支撑 23 天的使用，则充电频率为每 2~3 天充电一次；20%~30%快充若车辆以快充模式为主，充电频率更高，可能每天充电一次甚至更多。

本研究假设慢充的比率为 75%，快充的比率为 25%，这一设定能够较好地反映物流车辆在实际运营中对充电模式的选择偏好。慢充模式：假设每日充电一次，约占 75%；快充模式：假设每天充电 1.5 次，约占 25%。总功率为 2701.20 MW。

作为深圳市新能源汽车运行数据监测服务平台和绿色货运公共服务平台(后简称平台)，确保了数据来源的权威性和广泛性。数据集涵盖了 2020 年 1 月 1 日至 2020 年 1 月 14 日期间，共计 2000 辆电动物流车的详尽日志数据，特别聚焦于耗电量较大的冬季时段，这些车辆能够较好地反映该时期内特定区域内的潜在充电用户情况。根据平台数据分析，电动物流车的充电时间集中在三个时期，即上午 0 时左右、中午 12 时左右、17 时至 18 时峰值如图 6。

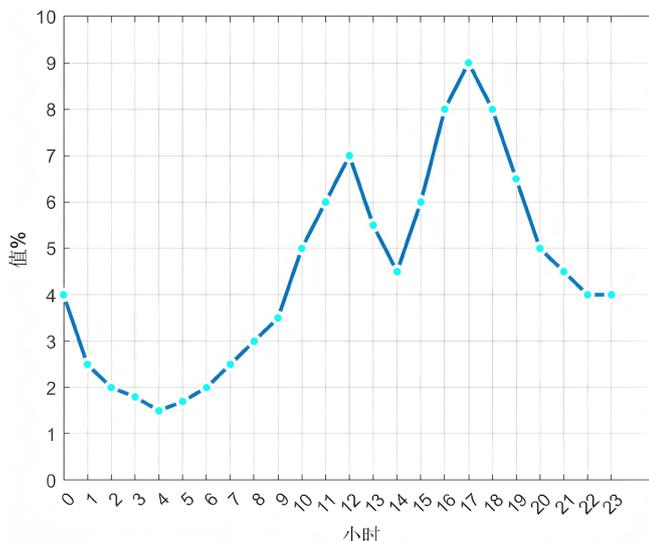


Figure 6. Probability of 24-hour charging time  
图 6. 24 小时充电时间概率

以保有量年数据为基础, 对济南市一天内的电动物流车充电量及峰值电量如表 10 所示。

**Table 10.** Electric logistics vehicle charging prediction value

**表 10.** 电动物流车充电预测值

年份	2024	2025	2026
粒子群算法校核	281,255	314,608	347,190
BP 神经网络	278,673	297,161	313,067
组合模型	279,706	304,140	326,716
总充电需求量(MW)	2701	2937	3155
0 点充电需求量(MW)	108	117	126
12 点充电需求量(MW)	189	206	221
17 点充电需求量(MW)	243	264	284

## 5. 总结与展望

本文针对电动物流车充电需求的复杂性与不确定性, 提出了基于粒子群优化(PSO)与 BP 神经网络相结合的预测模型。通过将 PSO 算法应用于 BP 神经网络的权重和阈值优化, 提升了模型的预测精度与收敛速度。在数据选取方面, 结合了多种具有代表性的影响因素, 如城市居民人均可支配收入、公路货运量、快递业务收入等, 充分体现了多变量对电动物流车充电需求的综合影响。经验证, 该组合模型在误差范围内表现优异, 平均相对误差低于 5%, 预测结果稳定且准确。结合车辆每日行驶里程和充电模式偏好, 计算得出 2026 年济南市的总充电需求为 3155 MW。峰值充电需求出现在 17:00~18:00 时段, 需求量为 284 MW, 其次是 12:00 时段的 221 MW 和 0:00 时段的 126 MW。

充电桩的分布应与物流车运行的高频区域匹配, 重点布局在峰值时段需求高的区域, 如物流园区、城市配送中心和住宅区周边。需针对不同时间段的充电需求波动制定动态电网负荷调度方案, 以平衡充电高峰期的用电压力。继续加大对电动物流车的政策支持, 鼓励更多物流企业采用电动物流车, 从而进一步降低城市碳排放并提高物流系统的绿色化水平。本研究预测模型中的数据特性分析和输入变量选择依赖于历史数据和专家经验, 未来可尝试引入更多实时动态数据, 如气象因素、交通流量等, 进一步提升模型的预测精度。

本文的研究结果为城市电动物流车充电基础设施的规划和管理提供了全面的理论支持和实践依据, 为推动绿色物流体系的发展奠定了基础。

## 参考文献

- [1] 曹小曙, 胡培婷, 刘丹. 电动汽车充电站选址研究进展[J]. 地理科学进展, 2019, 38(1): 139-152.
- [2] 田梦瑶, 汤波, 杨秀, 等. 综合考虑充电需求和配电网接纳能力的电动汽车充电站规划[J]. 电网技术, 2021, 45(2): 498-509.
- [3] Shepero, M. and Munkhammar, J. (2018) Spatial Markov Chain Model for Electric Vehicle Charging in Cities Using Geographical Information System (GIS) Data. *Applied Energy*, **231**, 1089-1099. <https://doi.org/10.1016/j.apenergy.2018.09.175>
- [4] 罗晴川. 基于改进麻雀搜索算法的电动汽车充电站选址定容在规划区的应用[D]: [硕士学位论文]. 大庆: 东北石油大学, 2022.
- [5] Afshar, M., Mohammadi, M.R. and Abedini, M. (2021) A Novel Spatial-Temporal Model for Charging Plug Hybrid Electrical Vehicles Based on Traffic-Flow Analysis and Monte Carlo Method. *ISA Transactions*, **114**, 263-276.

<https://doi.org/10.1016/j.isatra.2020.12.051>

- [6] Luo, H., Ruan, J. and Li, F. (2011) Study on the Electric Vehicles Ownership and Planning for the Construction of Charging Infrastructure. 2011 *Asia-Pacific Power and Energy Engineering Conference*, Wuhan, 25-28 March 2011, 1-4.  
<https://doi.org/10.1109/appeec.2011.5748974>
- [7] 李菱, 李燕青, 姚玉海, 等. 基于遗传算法的电动汽车充电站的布局规划[J]. 华东电力, 2011, 39(6): 1004-1006.
- [8] 李鑫. 黑龙江地区电动汽车充换电站需求预测及规划研究[D]: [硕士学位论文]. 北京: 华北电力大学, 2014.
- [9] Barbecho Bautista, P., Lemus Cárdenas, L., Urquiza Aguiar, L. and Aguilar Igartua, M. (2019) A Traffic-Aware Electric Vehicle Charging Management System for Smart Cities. *Vehicular Communications*, **20**, Article ID: 100188.  
<https://doi.org/10.1016/j.vehcom.2019.100188>
- [10] 龙虹毓, 周游, 陈芳幸, 等. 基于山地城市电动汽车负荷特性的充电设施规划[J]. 现代电力, 2024, 41(2): 371-379.
- [11] 刘建华. 粒子群算法的基本理论及其改进研究[D]: [博士学位论文]. 长沙: 中南大学, 2009.