

基于不同时间尺度下的城镇燃气负荷预测

向仕永, 郭磊

广元市天然气有限责任公司, 四川 广元

收稿日期: 2025年6月16日; 录用日期: 2025年7月7日; 发布日期: 2025年7月21日

摘要

为了有效降低燃气管网运营成本, 提高燃气管网智能化程度, 需要对燃气负荷进行全方位预测, 但由于燃气负荷预测不仅与燃气负荷数据、温湿度数据等空间特性有关, 还具有趋势性、周期性等时间特性, 导致燃气负荷预测机理建模困难且模型预测精度较低。考虑到不同时间尺度的燃气负荷对应的影响参数有较大的差异, 因此针对不同时间尺度下的燃气负荷预测模型, 包括日负荷、月负荷、季度负荷和年负荷, 分别提出了基于改进量子粒子群算法优化的人工神经网络(IQPSO-NN)的燃气日负荷和月负荷预测模型、基于BP神经网络算法的季度负荷预测模型、基于灰色GM(1, 1)马尔科夫方法的年负荷预测模型。采用平均预测精度对三种模型预测效果进行评价, 对燃气负荷的预测精度均在93%以上, 能够精确的预测各时间尺度上的燃气负荷。

关键词

燃气负荷预测, 多时间尺度, IQPSO-NN模型, BP神经网络模型, GM(1, 1)灰色马尔科夫模型

Urban Gas Load Forecasting Based on Multi-Time Scales

Shiyong Xiang, Lei Guo

Guangyuan Natural Gas Co., Ltd., Guangyuan Sichuan

Received: Jun. 16th, 2025; accepted: Jul. 7th, 2025; published: Jul. 21st, 2025

Abstract

To effectively reduce the operational costs of gas pipeline networks and enhance their intelligent level, comprehensive prediction of gas load is required. However, gas load prediction not only

relates to spatial characteristic such as gas load data and temperature/humidity data, but also exhibits its temporal characteristics including trend features and periodicity. This dual nature leads to difficulties in constructing accurate predictive models and results in lower prediction accuracy for gas load forecasting mechanisms. Considering the significant differences in the influencing parameters corresponding to gas loads at different time scales, distinct prediction models have been proposed for various temporal dimensions of gas load forecasting (including daily, monthly, quarterly, and annual loads). Specifically, an Improved Quantum Particle Swarm Optimization-based Artificial Neural Network (IQPSO-NN) was developed for daily and monthly load forecasting, a BP neural network algorithm was employed for quarterly load prediction, and a Grey GM(1, 1) Markov method was implemented for annual load forecasting. The prediction performance of the three models was evaluated using average prediction accuracy. All models demonstrated gas load prediction accuracy exceeding 93%, indicating their capability to precisely forecast gas loads across various time scales.

Keywords

Gas Load Forecast, Multi-Time Scale, IQPSO-NN Model, BP Neural Network Model, GM(1, 1) Grey Markov Model

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

燃气负荷预测精准的负荷预测为燃气管网的规划设计、经营管理、优化调度和高效运行都起着重要作用。近年来针对燃气负荷预测已有大量学者进行了研究, 目前国内外燃气负荷预测研究的主要模型有以下 3 种: 传统预测模型、智能化预测模型及组合预测模型[1]。

传统负荷预测方面, 1987 年, Herbert 等[2]将燃气的销售情况与燃气的用气天数进行了时间性分析, 通过建立回归性方程预测。2003 年, Siemek 等[3]通过调研波兰实际情况, 对 Herbert 模型进行了调整, 并以此预测了波兰的燃气需求量。2004 年, Haydar [4]等针对供暖期和非供暖期分别建立了自回归时序预测模型, 预测了居民采暖用气量。2004 年, Gorucu [5]通过进一步研究燃气负荷的影响因素, 利用多变量回归分析对城镇燃气消费量进行了预测。2004 年, 王根林[6]深入探究了燃气负荷的变化规律, 提出采用趋势外推结合主观修正量的预测方法。2013 年, 何春蕾等[7]将气温累积效应引入燃气负荷预测模型中, 用化学动力学与统计学理论建立了预测模型。2016 年, 王春秀[8]基于传统回归分析法, 引用偏最小二乘法解决燃气负荷预测变量间多重相关性问题。2018 年, 胡秀[9]通过 Logistic 曲线将综合经济因素、人口因素等拟合, 将拟合后的数据用于城镇燃气负荷的预测。

智能化负荷预测方面, Brown 等[10][11]首先将传统统计学预测模型与人工神经网络(ANN)的预测模型进行对比, 两者的预测结果显示人工神经网络能够有效提升预测精度。2001 年, 谭羽非等[12][13]通过 BP 神经网络对各类日期类型的用气进行预测, 发现 BP 神经网络存在学习慢、易陷入饱和和区等缺点, 并针对缺点进行了改进。2014 年, 张超等[14][15]为避免人工神经网络预测模型的局部收敛问题, 使用支持向量机的方法建立预测模型, 规避掉非线性回归问题, 转而研究高维特征空间的线性优化问题, 该模型适用于随机性较强的城镇燃气负荷预测。2017 年, Qin [16]等提出基于双注意力机制模型, 利用特征注意力机制选择相关性最高的特征数据, 同时利用时间注意力机制获取相关性最高的隐藏状态信息, 从而提高模型预测效果。2019 年, 黄建安[17][18]等研究长短期记忆神经网络(Long Short-Term Memory,

LSTM) [19]发现其处理周期性时间序列数据性能优秀, 并将之用于城镇燃气负荷预测。2022 年, 苏雅茜 [20]等利用自注意力机制计算过往不同时间节点的数据权重信息, 以提高传统移动平均算法的预测能力。

组合负荷预测方面, 1999 年 Khotanzad 等[21]通过非线性组合将三个独立预测模型结合, 得到的组合模型预测结果比其中任意单一预测模型更准确, 且性能更优秀。2009 年, Chen 等[22]将一种遗传算法用于确定权重, 提出将灰色预测模型与回归预测模型结合, 规避掉数据不良造成的误差同时避免了最小二乘法的局限性。2010 年, 周伟国等[23]证明了燃气负荷序列的混沌性特征, 通过将神经网络、贝叶斯正则化以及混沌理论各自的优点进行结合, 显著提高了负荷预测的精度。2017 年, Panapakidis 等[24]通过结合小波变化、遗传算法、自适应神经模糊推理系统以及神经网络建立预测模型, 用于燃气负荷预测。

综上所述, 在城镇燃气负荷预测方面, 近年来燃气负荷预测研究逐渐开始将多种算法与负荷预测模型相结合, 并有效地提高了负荷预测效率, 然而, 要有效优化在役城市燃气管网、指导未来新建管道线路优化以及搭建相应的可视化平台, 则需要更进一步准确地预测不同时间尺度的燃气负荷。为此本文针对不同时间尺度的燃气负荷特性, 分别提出了基于改进量子粒子群算法优化的人工神经网络(IQPSO-NN)的负荷预测模型, 对燃气日负荷与月负荷进行预测, 基于 BP 神经网络的负荷预测模型, 对燃气季度负荷进行预测, 基于灰色 GM(1, 1)马尔科夫方法的年负荷预测模型。将上述模型应用于西南某城市的燃气负荷预测, 再将预测结果与实际负荷值进行验证, 表明上述模型对相应时间尺度的燃气负荷有较高的预测精度。

2. 燃气负荷数据来源与预测模型

2.1. 燃气负荷预测数据来源与统计说明

通过调研西南某城市 2012 年 1 月 1 日至 2021 年 12 月 31 日的燃气负荷数据、天然气价格阶段性数据、当地年度气候数据(包括: 地温、风速风向、降水、气温、气压、日照时长和相对湿度等)以及当地经济数据[25](包括: 地区生产总值、地区人均可支配收入和第一产业增加值)。预测模型的输入数据集选择主要考虑以下几方面: ① 输入数据的样本量是否足够大; ② 输入数据与预测目标是否存在因果关系; ③ 输入数据与预测目标数据的相关性程度是否足够高。按照以上原则, 通过对比燃气负荷数据与各参数之间的变化关系, 预选了各时间尺度下可能与燃气负荷相关的变量如下: ① 对于燃气日负荷选取的相关变量有, 日最高气温、日最低气温、日平均气温、日照时长、降雨量。② 对于燃气月负荷选取的相关变量有, 月最高气温、月最低气温、月平均气温、日照时长、降雨量。③ 对于季度负荷选取的相关变量有, 季度平均气温、季度总日照时长、季度类型、当地国民生产总值、当地人均可支配收入、当地第一产业增加值。④ 对于年负荷选取的相关变量有, 地区经济参数。针对上述选择的相关变量利用 Pearson 方法, 分析每个变量对不同时间尺度下燃气负荷的相关系数 r , 其数值大小介于-1~1 之间, 数值越接近 1 表示正相关性越高, 越接近于-1 表示负相关性越高, 数值越接近于 0 表示相关性越低。

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (1)$$

式中: X_i 为样本中 X 的变量值; $\bar{X}$ 为样本中 X 的平均值; Y_i 为样本中 Y 的变量值; $\bar{Y}$ 为样本中 Y 的平均值。

按照 Pearson 相关系数计算结果为后续构建预测模型选择数据集, 同时为后续开展预测模型构建和训练提供数据基础, 相关系数分析结论如表 1~4 所示。

Table 1. Pearson correlation coefficient between daily gas load and various influence factors
表 1. 燃气日负荷与各影响因素 Pearson 相关系数

影响因素	2014 年	2016 年	2017 年	2018 年	2019 年
日最高气温	-0.7886	-0.8970	-0.8571	-0.8780	-0.8703
日最低气温	-0.7866	-0.8970	-0.8571	-0.8780	-0.8703
日平均气温	-0.7365	-0.9213	-0.9124	-0.9000	-0.9061
日照时长	-0.1301	-0.3058	-0.2254	-0.2310	-0.1756
降雨量	-0.1714	-0.1972	-0.2417	-0.2262	-0.2247

Table 2. Pearson correlation coefficient between monthly gas load and various influence factors
表 2. 燃气月负荷与各影响因素 Pearson 相关系数

影响因素	2014 年	2016 年	2017 年	2018 年	2019 年
月平均最高气温	-0.8480	-0.9448	-0.8899	-0.9171	-0.9080
月平均最低气温	-0.8915	-0.9334	-0.9075	-0.8832	-0.9286
月平均气温	-0.8798	-0.9429	-0.9101	-0.9110	-0.8872
月平均日照时长	-0.3078	-0.7246	-0.4892	-0.5062	-0.3748

Table 3. Pearson correlation coefficient between quarterly gas load and various influence factors
表 3. 燃气季度负荷与各影响因素 Pearson 相关系数

影响因素	2014 年	2016 年	2017 年	2018 年	2019 年
月平均气温	-0.9953	-0.9786	-0.9944	-0.9534	-0.9831
月平均日照时长	-0.9544	-0.9048	-0.9944	-0.5999	-0.7852
地区生产总值			0.7214		
地区人均可支配收入			0.7190		
地区第一产业增加值			0.8373		

Table 4. Pearson correlation coefficient between annual gas load and various influence factors
表 4. 燃气年负荷与各影响因素 Pearson 相关系数

影响因素	
地区生产总值	0.9302
地区人均生产总值	0.9174
地区第一产业增加值	0.9523

根据上表 Pearson 方法对于相关系数的分析，根据影响因素的相关系数计算结果选取各时间尺度下负荷预测模型的输入变量集与输出变量集，结果如下：

- (1) 燃气日负荷输入变量集包括：日期数据、季节数据、日平均气温(单位：℃)、日最高气温(单位：℃)、日最低气温(单位：℃)、日照时长(单位：h)和降雨量(单位：mm)，输出变量集为：燃气日负荷值(单位：m³)。
- (2) 燃气月负荷输入变量集包括：年份、季节数据、月平均气温(单位：℃)、月最高气温(单位：℃)、月最低气温(单位：℃)、日照时长(单位：h)和降雨量(单位：mm)，输出变量集为：燃气月负荷值(单位：m³)。

(3) 燃气季度负荷输入变量集包括: 年份、季度平均温度(单位: $^{\circ}\text{C}$)、季度总日照时长(单位: h)、地区国民生产总值(单位: 元)、地区第一产业增加值(单位: 元)和地区人均可支配收入(单位: 元), 输出变量集为: 燃气季度负荷值(单位: m^3)。

(4) 燃气年负荷输入变量集包括: 年份、地区生产总值(单位: 元)、地区人均生产总值(单位: 元)和地区第一产业增加值(单位: 元), 输出变量集为: 燃气年负荷值(单位: m^3)。

2.2. 预测模型

基于前文对影响因素开展的相关性分析, 从而确定了用于各时间尺度下的负荷预测的主要变量, 根据输入变量情况选择负荷预测所用模型。其中燃气日负荷影响因素较多, 与日最高气温、日最低气温、日平均气温相关性较强, 与日照时长、降雨量相关性较弱, 鉴于数据所提供的信息较为丰富, 根据上述条件, 综合对比支持向量机(SVM)、决策树(DT)、随机森林(RF)与人工神经网络(ANN)的适应性、训练速度、预测速度等因素, 最终考虑使用神经网络方法开展预测建模。燃气月负荷和日负荷同样具有较为丰富的数据量、影响因素较多, 适合采用人工神经网络方法进行预测建模。燃气季度负荷与平均气温、最高气温、最低气温等因素相关性较强, 并且数据所提供的信息同样较为丰富, 相较于月负荷和日负荷变化规律性更强, 因此考虑使用 BP 神经网络方法开展预测建模。燃气年负荷趋势明显且受地区经济参数的单一影响较为明显, 基于少量输入数据即可开展负荷预测, 由于 GM(1, 1)模型具有需求信息少、可对任意离散序列建模、计算简单等特点, 因此考虑使用 GM(1, 1)模型进行负荷预测。

2.2.1. 人工神经网络

人工神经网络受生物神经网络启发, 以此作为基础建立的神经元单位通过不同的连接方式组成复杂系统。人工神经网络的基本单元为神经元, 其能够处理单个节点的信息以及节点与节点之间的连接关系, 如图 1 所示。神经元由神经树突、神经元主体及神经元输出组成, 其中神经元主体包含激活函数, 用于实现神经网络不同层级间非线性映射的主要途径。激活函数的计算方法为: 将各个输入端神经树突所传递的向量进行加权求和并加入偏置项处理后, 输出至神经元的输出端。人工神经网络主要由三部分构成: 输入层、输出层、隐含层, 层与层之间通过人工神经元的神经树突相互连接, 每个神经树突上均包含了带有权重的输入向量, 隐含层可以是一层或多层, 每一层的神经元数量不一定相同, 而输入层和输出层仅包含一层, 分别用于输入自变量和输出预测结果。




Figure 1. The basic structure of artificial neurons
图 1. 人工神经元的基本结构

这种方法很容易陷入局部最优解, 为此已由研究提出了将量子粒子群算法、布谷鸟优化算法、鲸鱼优化算法等与人工神经网络混合来解决局部最优解的问题。本文选用量子粒子群优化算法对人工神经网络进行优化, 但量子粒子群优化算法也存在陷入局部最优解的情况, 为此本文将对基本的量子粒子群优

化算法加以改进。

2.2.2. 改进的量子粒子群优化算法

为避免量子粒子群优化算法陷入局部最优解的情况, 提高算法的优化性能, 需考虑在搜索过程中保持粒子种群的多样性。为实现目标, 考虑融合长短跳跃搜索与改进平均最好位置。

(1) 长短步长跳跃搜索方法

将步长的概率分布为重尾分布的随机行走, 在随机行走的过程中有效对较高的概率出现大跨步现象[26]。跳跃步长满足以下分布: $Levy(\lambda) \sim t^{-\lambda} (1 < \lambda < 3)$, 是一种典型的 Markov 过程。长短步长跳跃搜索的位置更新方程可以表示为:

$$x_i^{t+1} = x_i^t + \alpha_s \oplus Levy(\lambda) \quad (2)$$

$$\alpha_s = 0.01 \times (x_i^t - x_{worst}) \quad (3)$$

式中: x_i^{t+1} 为第 $t+1$ 代飞行位置; x_i^t 为第 t 代飞行位置; x_{worst} 为当代位置最差的粒子; $Levy(\lambda)$ 为搜索路径。

长短步长跳跃搜索的数学表达式为:

$$Levy(s, \kappa, \mu) = \begin{cases} \sqrt{\frac{\kappa}{2\pi}} \exp\left[-\frac{\kappa}{2(s-\mu)}\right] \frac{1}{(s-\mu)^{\frac{3}{2}}}, & 0 < \mu < s < \infty \\ 0, & s \leq 0 \end{cases} \quad (4)$$

式中: ε 为长短步长跳跃搜索的步长; κ 为决定分布尺度的参数; μ 为位置参数(最短步长)。

长短步长调优搜索常用 Mantegna 算法进行简化模拟[27], 其表达式如(5)所示, $\mu \sim N(0, \sigma_\mu^2)$, $v \sim N(0, \sigma_v^2)$ 。 σ_μ^2 和 σ_v^2 可通过式(6)确定。

$$Levy(\lambda) = \frac{\mu}{|v|^{\frac{1}{\lambda-1}}} \quad (5)$$

$$\begin{cases} \sigma_\mu = \left[\frac{\Gamma(1+\chi) \cdot \sin\left(\frac{\chi}{2}\pi\right)}{\Gamma\left(\frac{1+\varphi}{2}\right) \cdot \chi \cdot 2^{\frac{\varphi-1}{2}}} \right] \\ \sigma_v = 1 \end{cases} \quad (6)$$

综合式(2)至式(6), 长短步长跳跃搜索的位置迭代方程为:

$$x_i^{t+1} = x_i^t + \alpha \oplus \frac{\mu}{|v|^{\frac{1}{\lambda-1}}} \quad (7)$$

(2) 改进的平均最好位置计算方法

实际上, 每个维度上的粒子最好位置对于整体平均最好位置的贡献度是不同的, 因此在计算平均最好位置时不能将每个维度上最好位置简单做平均值处理, 而是需要在每个维度的最好位置之前添加权重系数, 即贡献度最高的维度权重大, 贡献度小的维度权重小。本项目中所设计的改进平均最好位置计算方法如式(8)所示:

$$mbest = \frac{1}{N} \sum_{i=1}^N pbest = \left(\frac{1}{N} \alpha_{i,1} \sum_{i=1}^N pbest_{i,1}, \frac{1}{N} \alpha_{i,2} \sum_{i=1}^N pbest_{i,2}, \dots, \frac{1}{N} \alpha_{i,D} \sum_{i=1}^N pbest_{i,D} \right) \quad (8)$$

式中: $a_{i,j}$ ——一系列具备一定规律的权重系数。

基于长短步长跳跃搜索方法和改进的平均最好位置计算方法, 提出的改进的量子粒子群算法, 即 IQPSO。在加入长短步长跳跃搜索算法之后, 完成适应度值计算(包含改进的平均最好位置计算方法)后增加一个长短步长跳跃搜索过程, 对当前的种群进行变异处理, 从而有效扩大种群的搜索范围, 提升算法性能。

2.2.3. 改进量子粒子群算法优化的人工神经网络




Figure 2. IQPSO-NN gas load forecasting network architecture framework
图 2. IQPSO-NN 燃气负荷预测网络结构框架

通过前文改进的量子粒子群算法(IQPSO)对人工神经网络的权重和阈值进行优化求解。本次建构的 IQPSO-NN 预测网络共包含 7 个输入变量、1 个输出变量, 网络采用单隐含层结构, 隐含层神经元数量为 m , m 的数值将通过不同隐含层数量网络的最终收敛值进行确定, 达到最低最终收敛值所对应的 m 值, 即为预测网络隐含层神经元数量的最优值。神经网络隐含层范围可以粗略通过式(9)确定, 其中 N_s 为训练集样本数, N_i 为输入层神经元的个数, N_o 为输出层神经元的个数, C_N 为可以自取的任意值变量。

$$N_h = \frac{N_s}{[C_N \cdot (N_i + N_o)]} \quad (9)$$

其中 IQPSO-NN 预测网络结构如图 2 所示。

根据图 2 所示, 建立一个 IQPSO 编码粒子 p_i 的向量作为 IQPSO 算法优化参数, 向量中所储存的优化问题的解主要包括四个部分: 输入层至隐含层之间的输入权值 $\{\omega_{ih}(1, 1), \dots, \omega_{ih}(5, 1), \dots, \omega_{ih}(1, m), \dots, \omega_{ih}(7, m)\}$; 隐含层至输出层之间的输出权值: $\{\omega_{ho}(1, 1), \omega_{ho}(2, 1), \dots, \omega_{ho}(m, 1)\}$; 隐含层神经元的偏置项 $\{\theta_{1,1}, \theta_{1,2}, \dots, \theta_{1,m}\}$; 输出层神经元的偏置项 $\theta_{2,1}$ 。因此, 采用向量编码时粒子 p_i 编码为:

$$p_i = [\omega_{ih}(1,1), \dots, \omega_{ih}(7,m), \dots, \theta_{1,1}, \dots, \theta_{1,m}, \omega_{ho}(1,1), \dots, \omega_{ho}(m,1), \theta_{2,1}] \quad (10)$$

2.2.4. BP 神经网络预测模型

燃气季度负荷采用 BP 神经网络预测模型, 模型输入变量包括: 所在地区每季度国民生产总值、所在地区每季度第一产业增加值、所在地区每季度人均可支配收入、季度类型、季度总日照时长、季度平均温度和年份数据, 预测算法框架与 IQPSO-NN 算法框架相同。BP 神经网络燃气负荷预测网络结构框架如图 3 所示。




Figure 3. BP neural network gas load forecasting network architecture framework
图 3. BP 神经网络燃气负荷预测网络结构框架

2.2.5. GM(1, 1)模型

燃气年负荷因趋势明显且受单因素影响明显, 因此本项目中的燃气年负荷预测模型将采用 GM(1, 1) 灰色马尔科夫方法。GM(1, 1)模型具有要求信息少, 可对任意离散序列建模、计算简单的特点, 在短期预测中的精度很高, 但对长期预测和波动性较强的序列预测拟合度较差。马尔科夫链的无后效性对中长期预测和波动性较强的序列效果较好。因此, 将灰色理论和马尔科夫链融合, 提出基于灰色马尔科夫燃气年负荷预测模型。

灰色马尔科夫预测模型的基本思想是通过将燃气年负荷原始序列进行序列变换, 对原始序列进行累加, 减少原始燃气年负荷的随机性。通过序列的变换使得不稳定的系统变得能够有效抵抗随机干扰, 再利用马尔科夫状态转移矩阵来确定未来某时刻的状态, 通过分析该未来时刻和误差的概率, 从而达到提升预测精度的目的。通过生成初值燃气年负荷序列算子, 即用原始序列的第一个值去除序列中每一个值, 其作用是以序列的第一个值考察整体系统的发展趋势。通过上述方法将原始序列进行变换之后, 建立微分方程, 即可得到 GM(1, 1)模型。

设燃气年负荷 $M_y^{(0)} = \{M_y^{(0)}(i), i = 1, 2, 3, \dots, n\}$ 为单调原始数据序列, 建立灰色预测模型:

首先对燃气年负荷原始序列 $M_y^{(0)}$ 进行一次累加得到一次累加序列 $M_y^{(1)} = \{M_y^{(1)}(k), k = 1, 2, 3, \dots, n\}$ 。

对 $M_y^{(1)}$ 建立一阶线性微分方程如下:

$$\frac{dM_y^{(1)}}{dt} + aM_y^{(1)} = u \quad (11)$$

式(11)为 GM(1, 1)模型通过求解式(11)的微分方程, 得到灰色模型如下:

$$\widehat{M_y^{(1)}}(k+1) = \left[\widehat{M_y^{(0)}}(0) - \frac{\hat{u}}{a} \right] e^{-\hat{a}k} + \frac{\hat{u}}{a} \quad (12)$$

由于 GM(1, 1)模型得到的式一次累加量, 将 GM(1, 1)模型所得燃气年负荷数据 $\widehat{M_y^{(1)}}(k+1)$ 经过累减还原为 $\widehat{M_y^{(0)}}(k+1)$, 即 $M_y^{(0)}$ 的灰色预测模型可以表达为:

$$\widehat{M_y^{(0)}}(k+1) = (e^{-\hat{a}} - 1) \left[\widehat{M_y^{(0)}}(n) - \frac{\hat{u}}{a} \right] e^{-\hat{a}k} \quad (13)$$

定义向量 $A = (a, u)^T$, A 可通过最小二乘法求得:

$$A = (a, u)^T = (B^T B)^{-1} B^T Y \quad (14)$$

$$B = \begin{bmatrix} -\frac{1}{2}(M_y^{(1)}(2) + M_y^{(1)}(1)) & 1 \\ \dots & \dots \\ -\frac{1}{2}(M_y^{(1)}(m) + M_y^{(1)}(m-1)) & 1 \end{bmatrix} \quad (15)$$

$$Y = \begin{bmatrix} M_y^{(0)}(2) \\ M_y^{(0)}(3) \\ \dots \\ M_y^{(0)}(m) \end{bmatrix} \quad (16)$$

将燃气年负荷数据序列分成若干种状态, 记为 $E_1, E_2, \dots, E_n$, 并把可能发生转移概率的时间记为 $t_1, t_2, \dots, t_n$ 。燃气年负荷残差数据由状态 E_i 经过 m 个步骤转移到 E_j 的转移概率, 记为 P_{ij}^m , 其计算公式可表达为:

$$P_{ij}^m = \frac{r_{ij}^m}{R_i} \quad (17)$$

式中: r_{ij}^m 为状态概率元素, P_{ij}^m 为状态转移概率。因此, 可以获得燃气年负荷残差数据转移概率矩阵如式(18)所示, 根据该式的状态转移矩阵和初始状态 E_i , 确定马尔科夫链, 据此对灰色模型进行修正。

$$\mathbf{P}^m = \begin{bmatrix} P_{11}^m & P_{12}^m & \cdots & P_{1k}^m \\ P_{21}^m & P_{22}^m & \cdots & P_{2k}^m \\ \cdots & \cdots & \cdots & \cdots \\ P_{n1}^m & P_{n2}^m & \cdots & P_{nk}^m \end{bmatrix}$$

(18)

综上所述，基于 GM(1, 1)的燃气年负荷预测流程如图 4 所示。




Figure 4. Process of the GM(1, 1) algorithm for annual gas load forecasting
图 4. GM(1, 1)燃气年负荷预测算法流程

3. 实例预测

3.1. 数据处理

(1) 输入数据量化：根据前文影响因素与预测目标确定 IQPSO-NN 负荷预测模型的输入变量与输出变量。其中，日期变量与季节变量按照以下方式进行处理，如表 5~7 所示。

Table 5. Date type quantification
表 5. 日期类型量化

日期	星期一	星期二	星期三	星期四	星期五	星期六	星期天	节假日
量化数值	1	2	3	4	5	6	7	8

Table 6. Seasonal type quantification
表 6. 季节类型量化

季节	春	夏	秋	冬
量化数值	1	2	3	4

Table 7. Year date quantification
表 7. 年份数据量化

年份	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
量化数值	1	2	3	4	5	6	7	8	9	10

(2) 数据归一化：通过归一化加快梯度下降求最优解的速度，使数据处理更便捷，减少数据冗余并提高数据完整性，减小数据过拟合的可能，并且能在一定程度上提升算法预测精度。当不同类型的数据间存在着不同单位或相差较大的量纲时，通过归一化处理能够有效使得同一层次的神经元之间能够进行加权计算。本文采用线性归一化对数据进行处理，公式为：

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (19)$$

式中： x'_i 为归一化后的第 i 个数据； x_i 为归一化前的第 i 个数据； $x_{\max}$ 为归一化前的最大数值； $x_{\min}$ 为归一化前的最小数值。

(3) 适应度函数：适应度函数是用于衡量目标值与实际值的相似程度的指标，合适的适应度函数能有效评价每一次优化迭代的效果，从而决定算法收敛时机和收敛精度，对于保障神经网络结构参数的最优化有重要意义。本文将适应度函数定义为预测样本与目标样本间的误差平方和，公式为：

$$f(M'_i) = \sum_{i=1}^n (M'_i - M_i)^2 \quad (20)$$

式中： M'_i 为燃气日负荷预测值； M_i 为燃气日负荷测量值。

3.2. 燃气日负荷预测




Figure 5. The fitness value iteration curve of the IQPSO-NN algorithm for daily gas load forecasting
图 5. IQPSO-NN 算法燃气日负荷预测适应度值迭代曲线

根据构建的燃气日负荷预测数据集, 将该地区 2021 年之前的燃气日负荷作为训练集, 将该地区 2021 年的燃气日负荷作为测试集。在 IQPSO-NN 算法中进行训练并通过对测试集进行计算给出基于 IQPSO-NN 的燃气日负荷预测结果。IQPSO-NN 训练过程中迭代次数对应下的适应度值曲线如图 5 所示。从图中看出, 收敛过程中没有出现陷入局部最优的情况, 适应度值在迭代初期随迭代次数的增加而不断下降, 当迭代次数超过 14 时, 下降速度逐渐减小并呈现出逐渐收敛的趋势, 当迭代次数大于 38 时, 适应度值下降速度逐渐收敛至满足迭代结束条件即达到最大迭代次数。在迭代次数最大值为 200 时, 适应度值最小为 1.10886。

基于 IQPSO-NN 的燃气日负荷预测结果分别如图 6 和表 8 所示。所提出的 IQPSO-NN 燃气日负荷预测模型能够较好地根据日期信息、气温信息、日照信息、降雨信息预测燃气日负荷变化情况, 燃气日负荷平均精度达到 94.8787% (平均误差: $\pm 5.1213\%$), 预测精度足够。




Figure 6. The results of the IQPSO-NN based daily gas forecasting model
图 6. 基于 IQPSO-NN 的燃气日负荷预测模型测试结果

Table 8. Daily gas load forecasting results based on IQPSO-NN
表 8. 基于 IQPSO-NN 的燃气日负荷预测结果

序号	实际值(m³)	预测值(m³)	序号	实际值(m³)	预测值(m³)	序号	实际值(m³)	预测值(m³)
1	628810	655651.6131	6	661085	632439.5316	...	...	...
2	656771	663757.6601	7	699316	657492.8596	360	715597	647629.2033
3	674441	620146.9113	8	674889	628657.798	361	663281	631411.008
4	617316	601021.3672	9	748723	712027.8898	362	638614	675941.2447
5	625366	603530.0018	10	748721	651137.5934	363	624064	629645.4321

3.3. 燃气月负荷预测

基于 IQPSO-NN 算法, 并根据月负荷输入变量: 月平均气温、月最高气温、月最低气温、月总日照

时长、月总降雨量、季节类型、年份数据, 以及构建的月负荷预测数据集, 对基于 IQPSO-NN 的燃气月负荷模型进行了训练学习, 训练过程中适应度值迭代曲线如图 7 所示, 由图可知适应度值随着训练过程的不断进行逐渐下降, 直至收敛完成训练过程, 未发生局部最优现象, 在迭代次数超过 12 时, 下降速度逐渐减小并呈现出逐渐收敛的趋势, 在迭代次数大于 52 时, 适应度值下降速度逐渐变慢并逐渐收敛直至满足迭代结束条件即达到最大迭代次数, 最佳适应度值为 1.72×10^{-5} 。基于 IQPSO-NN 的燃气月负荷预测结果分别如图 8 和表 9 所示。所构建的 IQPSO-NN 算法能够较好地预测燃气月负荷数值, 测试集合的平均预测精度可达 99.90%, 误差为 $\pm 0.1\%$, 预测精度足够。




Figure 7. The fitness value iteration curve of the IQPSO-NN algorithm for monthly gas load forecasting
图 7. IQPSO-NN 算法燃气月负荷预测适应度值迭代曲线




Figure 8. The results of the IQPSO-NN based monthly gas forecasting model
图 8. 基于 IQPSO-NN 的燃气月负荷预测结果

Table 9. Monthly gas load forecasting results based on IQPSO-NN
表 9. 基于 IQPSO-NN 的燃气月负荷预测结果

序号	实际值(m³)	预测值(m³)	绝对误差(m³)	相对误差(%)
1	19,770,767	19772510.13	1743.126112	0.008816684
2	12,494,718	12483807.91	-10910.09275	-0.087317639
3	10,806,388	10803239.82	-3148.180421	-0.029132587
4	8,682,289	8686210.92	3921.920003	0.045171498
5	7,721,852	7712341.679	-9510.320888	-0.123161139
6	6,899,419	6896051.983	-3367.017193	-0.04880146
7	6,875,150	6861922.862	-13227.13826	-0.192390541
8	6,911,911	6921746.221	9835.221121	0.142293804
9	7,340,175	7357521.755	17346.75514	0.236326179
10	9,349,770	9334662.226	-15107.77416	-0.161584447
11	13,248,274	13242235.29	-6038.711639	-0.04558112
12	17,989,629	17997960.11	8331.105867	0.046310604

3.4. 燃气季度负荷预测




Figure 9. Quarterly gas load forecasting results based on BP neural network
图 9. 基于 BP 神经网络的燃气季度负荷预测结果

基于燃气季度负荷预测模型，构建了燃气季度负荷预测数据集，并进行了模型训练学习和负荷预测，预测数据集包含了 26 组数据，其中 22 组为训练数据，4 组为预测数据，其结果如图 9 所示。由图可知，所构建的基于 BP 神经网络模型能够较好地预测燃气季度负荷值，平均预测精度可达 93.83%，燃气季度

负荷预测值和实际值相关系数为: 0.9833, 预测精度足够。四个样本的预测值分别为: 43,947,605.6 m³、22,801,531.68 m³、22,009,428.1 m³ 和 46,948,959.3 m³, 实际值分别为: 42,803,497 m³、23,303,560 m³、21,127,236 m³ 和 40,587,673 m³。

3.5. 燃气年负荷预测

基于 GM(1, 1)灰色马尔科夫链的燃气年负荷预测结果如图 10 所示, 可以看出拟合曲线较好地兼顾了各个年份在整体变化趋势中的作用, 拟合曲线呈现出随年份增加负荷值不断上升的趋势, 根据拟合曲线的结果, 2021 年的年负荷预测值为 135,108,000 m³, 该年实际用气量 127,821,966 m³, 相对误差为 5.7%, 预测具有较高精度。随着运行年数的增加, 用于 GM(1, 1)灰色马尔科夫模型训练的数据也将增加, 因而该模型的精度能够进一步提升。若是燃气年负荷存在较为明显波动现象的地区, 则可考虑采用灰色神经网络模型进行预测, 若是燃气年负荷呈现单调上升趋势的地区, 则考虑使用本文所构建的 GM(1, 1)灰色马尔科夫预测模型。




Figure 10. Annual gas load prediction using GM(1, 1) grey Markov chain model
图 10. 基于 GM(1, 1)灰色马尔科夫链的燃气年负荷预测结果

4. 结论

本文针对不同时间尺度开展了燃气负荷预测研究, 根据不同时间尺度的燃气负荷数据特点和变化规律分别构建了不同的预测模型, 并实现了燃气负荷的精准预测。

(1) 分析了影响不同时间尺度下燃气负荷的主要因素, 并基于 Pearson 相关性分析方法, 分析了影响燃气日负荷、月负荷、季度负荷和年负荷的主要因素。基于相关性分析结果, 将相关性系数高的参数作为燃气负荷预测模型的输入参数。燃气日负荷的输入参数为: 日期、日平均气温、日最高气温、日最高气温、季节、日照时长和降雨量, 燃气月负荷的输入参数为: 月平均气温、月最高气温、月最低气温、月总日照时长、月总降雨量、季节类型、年份数据。

(2) 提出改进平均最好位置计算方法和长短步长跳跃搜索方法的改进量子粒子群算法 IQPSO, 用于优化传统神经网络偏重和阈值更新过程。介绍了基于 IQPSO-NN 的燃气日负荷预测模型, 以及算法结构和基本流程。分析了基于 IQPSO-NN 的燃气负荷预测结果, 结果证明燃气日负荷预测结果预测精度足够, 平均精度可达 94.8787%。

(3) 分析了燃气月负荷、季度负荷和年负荷预测结果, 结果证明燃气中长期负荷预测结果精度足够, 月负荷、季度负荷和年负荷预测平均精度分别为: 99.9%、93.83%和 94.3%。

参考文献

- [1] 徐鹏, 杜景勃, 刘伟. 城镇天然气负荷预测方法研究进展[J]. 油气储运, 2023, 42(5): 481-491.
- [2] Herbert, J.H., Sitzer, S. and Eades-Pryor, Y. (1987) A Statistical Evaluation of Aggregate Monthly Industrial Demand for Natural Gas in the U.S.A. *Energy*, **12**, 1233-1238. [https://doi.org/10.1016/0360-5442\(87\)90030-2](https://doi.org/10.1016/0360-5442(87)90030-2)
- [3] Siemek, J., Nagy, S. and Rychlicki, S. (2003) Estimation of Natural-Gas Consumption in Poland Based on the Logistic-Curve Interpretation. *Applied Energy*, **75**, 1-7. [https://doi.org/10.1016/s0306-2619\(03\)00013-8](https://doi.org/10.1016/s0306-2619(03)00013-8)
- [4] Aras, H. and Aras, N. (2004) Forecasting Residential Natural Gas Demand. *Energy Sources*, **26**, 463-472. <https://doi.org/10.1080/00908310490429740>
- [5] Gorucu, F.B. (2004) Evaluation and Forecasting of Gas Consumption by Statistical Analysis. *Energy Sources*, **26**, 267-276. <https://doi.org/10.1080/00908310490256617>
- [6] 王根林. 城市天然气用气规律及负荷预测[J]. 煤气与热力, 2004(7): 391-394.
- [7] 何春蕾, 段言志, 郭宗婧, 等. 基于气温的城市燃气短期日负荷预测模型: 以四川省成都地区为例[J]. 天然气工业, 2013(4): 131-134.
- [8] 王春秀. 北京市昌平区燃气负荷分析[D]: [硕士学位论文]. 北京: 北京建筑大学, 2017.
- [9] 胡秀. 基于竞争力评价的城市燃气长期负荷预测[D]: [硕士学位论文]. 北京: 北京建筑大学, 2018.
- [10] Brown, R.H., et al. (1994) Development of Feed-Forward Network Models to Predict Gas Consumption. *Proceedings of 1994 IEEE International Conference on Neural Networks (ICNN'94)*. Orlando, 28 June-2 July 1994, 802-805.
- [11] Brown, R.H. and Matin, I. (1995) Development of Artificial Neural Network Models to Predict Daily Gas Consumption. *Proceedings of IECON '95-21st Annual Conference on IEEE Industrial Electronics*, Vol. 2, 1389-1394. <https://doi.org/10.1109/iecon.1995.484153>
- [12] 谭羽非, 陈家新, 焦文玲, 等. 基于人工神经网络的城市煤气短期负荷预测[J]. 煤气与热力, 2001(3): 199-202.
- [13] 谭羽非, 陈家新. 城市燃气短期负荷预测的神经网络等维新息模型[J]. 计算机仿真, 2001(5): 80-82, 75.
- [14] 张超, 刘奕, 张辉, 等. 基于支持向量机的城市燃气日负荷预测方法研究[J]. 清华大学学报(自然科学版), 2014, 54(3): 320-325, 333.
- [15] 白雪. 川渝地区城镇冬季燃气日负荷特性分析及预测方法研究[D]: [硕士学位论文]. 成都: 西南石油大学, 2016.
- [16] Qin, Y., Song, D., Chen, H., Cheng, W., Jiang, G. and Cottrell, G.W. (2017). A Dual-Stage Attention-Based Recurrent Neural Network for Time Series Prediction. *Proceedings of the 26th International Joint Conference on Artificial Intelligence*, Melbourne, 19-25 August 2017, 2627-2633. <https://doi.org/10.24963/ijcai.2017/366>
- [17] 黄建安, 金亚东, 杨谈. 基于机器学习的日用气量预测及影响因素分析[J]. 煤气与热力, 2019, 39(9): 29-32, 43.
- [18] 郭琳. LSTM 城市燃气负荷预测技术的研究与开发[D]: [硕士学位论文]. 西安: 西安石油大学, 2020.
- [19] 陈亮, 王震, 王刚. 深度学习框架下 LSTM 网络在短期电力负荷预测中的应用[J]. 电力信息与通信技术, 2017, 15(5): 8-11.
- [20] 苏雅茜, 崔超然, 曲浩. 基于自注意力移动平均线的时间序列预测[J]. 南京大学学报(自然科学), 2022, 58(4): 649-657.
- [21] Khotanad, A., et al. (1999) Natural Gas Load Forecasting with Combination of adaptive Neural Networks. *IJCNN'99. International Joint Conference on Neural Networks. Proceedings*, Vol.6, 4069-4072.
- [22] Chen, R., et al. (2009) The Forecasting of China Natural Gas Consumption Based on Genetic Algorithm. 2009 5th International Joint Conference on INC, IMS and IDC, Seoul, 25-27 August 2009, 1436-1439. <https://doi.org/10.1109/ncm.2009.389>
- [23] 周伟国, 张中秀, 姚健. 城市燃气负荷的混沌特性与预测[J]. 同济大学学报(自然科学版), 2010(10): 1511-1515.

- [24] Panapakidis, I.P. and Dagoumas, A.S. (2017) Day-Ahead Natural Gas Demand Forecasting Based on the Combination of Wavelet Transform and ANFIS/Genetic Algorithm/neural Network Model. *Energy*, **118**, 231-245.
<https://doi.org/10.1016/j.energy.2016.12.033>
- [25] 广元市统计局, 编. 广元统计年鉴 2022 [M]. 广元: 广元市统计局, 2022.
- [26] 陈曦, 许亮, 王涛, 等. 融合莱维飞行与黄金正弦的粒子群优化算法[C]//中国自动化学会系统仿真专业委员会, 中国仿真学会仿真技术应用专业委员会. 第 22 届中国系统仿真技术及其应用学术年会(CCSSTA 22nd 2021)论文集. 2021: 235-238.
- [27] 张玉, 卢子广, 卢泉, 等. 基于 Levy 飞行改进鸟群算法的光伏直流微电网优化配置研究[J]. 太阳能学报, 2021, 42(5): 214-220.