

# 基于GM(1,1)模型和BP神经网络的四川省用电量预测

张煜熙\*, 陈勇明

成都信息工程大学应用数学学院, 四川 成都

收稿日期: 2023年4月9日; 录用日期: 2023年5月3日; 发布日期: 2023年5月12日

## 摘要

随着中国经济的快速增长, 人民对能源的需求也在逐步增长。电能作为居民基本的生活能源, 其是否能够充足稳定的供应决定了社会经济的运行。当在面对突发事件无法及时满足供电需求时, 对于用电量的预测就成为了一种未雨绸缪的重要方法。本文基于GM(1,1)模型和BP神经网络建立了一种新的GM-ABP模型。我们将GM-ABP模型用于预测中国四川省年用电量。本文提出的模型在GM(1,1)模型的基础上加以修正, 利用Adam算法优化的BP神经网络对残差进行拟合。预测结果显示GM-ABP模型的预测精度均优于GM(1,1)模型和Adam-BP神经网络模型, 且预测精度有较大提升。最后通过GM-ABP模型给出了四川省2021~2023年用电总量的预测值。

## 关键词

电量预测, GM(1,1)模型, BP神经网络, Adam优化算法

## Production of Electricity Consumption Based on GM(1,1) and BP Neural Network in Sichuan Province, China

Yuxi Zhang\*, Yongming Chen

College of Applied Mathematics, Chengdu University of Information Technology, Chengdu Sichuan

Received: Apr. 9<sup>th</sup>, 2023; accepted: May 3<sup>rd</sup>, 2023; published: May 12<sup>th</sup>, 2023

## Abstract

With the rapid growth of China's economy, people's demand for energy is also gradually increas-

\*通讯作者。

ing. Electric energy is the essential energy of life; its sufficient and stable supply determines the operation of the social economy. When the power supply demand cannot be timely met in the face of emergencies, the forecast of electricity consumption has become a meaningful way to prepare for that. This paper establishes a new GM-ABP model based on GM (1,1) model and BP neural network. We use the GM-ABP model to predict the total annual electricity consumption in Sichuan Province, China. The model proposed in this paper is modified based on the GM (1,1) model, and the residual is fitted by BP neural network optimized by the Adam algorithm. The prediction results show that the prediction accuracy of the GM-ABP model is better than that of the GM (1,1) model and Adam-BP neural network model, and the prediction accuracy is greatly improved. Finally, the GM-ABP model is used to predict the total electricity consumption of Sichuan Province in 2021~2023.

## Keywords

Electricity Consumption, GM(1,1) Model, BP Neural Network, Adam Optimization Algorithm

Copyright © 2023 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

能源是经济发展的基础[1]。而对于能源需求的预测则是国家决策和规划的基础。由于电能这种特殊能源具有产出、供给和销售同时进行和动态变化的特点,对于电力需求的预测就显得尤为重要。在2022年,中国四川省因罕见的高温天气导致主要流域缺水,水电供应下降严重。对于此次事件,四川省政府积极应对,调配用电结构,减少不必要用电,保障了人民日常用电需求。由此可见,对于能源需求的预测可以保障人们的生活和社会正常活动,有效地最大限度地降低运行成本,保障经济平稳运行,提高社会经济效益[2] [3] [4]。

已经有大量研究对电力能源相关问题进行建模预测[5] [6] [7] [8]。建模预测方法可以大致分为四类:统计方法、人工智能方法、灰色系统方法以及混合方法[9]。统计方法例如 Chu [10]和 Patrícia Ramos [11]分别利用 ARMA 和 ARIMA 方法进行预测研究。Carolina [12]通过对电力需求的预测分析对比了 VAR 和 iMLP 方法的优劣。Takeda [13]利用 Kalman filter (KF)进行电力负荷的预测和分析。但上述方法因为本身固有的弱点,未能给出所预测内容的非线性特征以及数据快速变化时的预测值[14]。相比较下,深度学习方向的研究可以弥补上述方法的不足并且也有更好的预测准确性[15]。因此,许多研究都基于深度学习的方法进行预测分析。

在众多以深度学习为主的预测研究中,神经网络是最常用和最重要的方法之一。Li [16]在研究中基于 Artificial Neural Network 建立了预测模型以对 town of Palermo 的居民用电量进行短期预测。随着神经网络的发展, BP 神经网络算法以其较强的非线性映射能力和自适应能力以及结构简单等优势逐渐成为研究的重点方向。而在 BP 神经网络中梯度下降算法是研究人员优化的核心,好的优化算法可以加速神经网络找到最小值并且可以有效避免陷入局部最小值等问题。Cinar 等人[17]建立的预测模型以遗传算法(GA)改进的 BP 神经网络为基础,预测分析了土耳其未来的能源结构。在上述研究的基础上, Wu 等人[18]结合了遗传算法(GA)和退火算法(SA)建立了 GASA-BP 预测模型。相较于传统 BP 神经网络和遗传算法改进的神经网络而言, GASA-BP 在模型迭代次数更少的前提下具有更小的误差,并且运行时间也有大幅优

化。Uzlu [19]和 Cinar [20]采用灰狼优化算法(GWO)分别对温室气体排放量和地区风速进行预测, 其误差结果相较于传统 BP 神经网络均有较大提高。Li *et al.* [2]利用粒子群(PSO)算法改进传统 BP 神经网络, 提供了一种应对类似新冠肺炎的紧急事件时的电力预测模型。

除了上述两种的预测方法外, 灰色系统理论也是研究不确定性的方法之一, 其在不确定信息系统的数学分析方面具有优越性。灰色系统也是一种潜在的构建预测模型的方法[21]。即使面对少量数据, 灰色系统也可以描述不确定系统的特征[22]电力需求的预测也可以看做一个灰色问题, 因为电力消耗受多方面因素影响, 且不确定各因素的影响强度。另外, 对于像中国这样的新兴国家, 工业发展晚, 数据记录时间短, 这样的数据正适合利用灰色系统中的 GM(1,1)模型方法进行预测分析。Ding 等人[23]在 GM(1,1)的基础上进行改进, 在初始条件中加入了动态加权系数。模型在遵循“新信息优先”时, 表现出比传统 GM(1,1)模型更好的适应性。研究最后对中国总量和工业用电量进行了预测。Guefano 等人[24]采用了另一种思路, 使用 VAR(1)模型来修正 GM(1,1)模型, 将两种模型进行加权平均以减少单纯使用 GM(1,1)模型带来的残差。最终建立了 GM(1,1)-VAR(1)模型并预测了喀麦隆居民的用电量。Du 等人[25]的研究基于多个输出变量的 GM(1,n)模型, 利用粒子群算法对输入灰色系统的数据进行预处理以满足建模条件, 并且利用灰色关联排序确定输入变量个数。最后作者预测了中国江苏省未来几年的用电量, 并提出了有关能源管理的政策建议。Xu 等人[26]提出了一种具有最优时间响应函数的混合 GM(1,1)模型, 该模型能够对用电量进行预测。Wu 等人[27]将总人口作为变量之一提出了一种多变量的灰色预测模型。该模型对分数阶累计的 GMC(1,1)模型进行了优化, 最终预测了中国山东省的用电总量。

相较于上述预测研究中使用的方法, 将不同的预测方法相结合在解决某些特定问题时更有效。Hu [28]提出了基于遗传算法的残差 GM(1,1)模型, 以中国能源需求为例的实验证明该模型优于其他 GM(1,1)模型变体。Hsu 等人[29]结合了 GM(1,1)和人工神经网络提出了一种改进的 GM(1,1)模型。作者为原始数据和残差数据分别建立了 GM(1,1)预测模型, 然后训练人工神经网络以确定残差预测值的符号。Zhu 等人[30]的研究将不同时间的数据进行动态加权处理, 使新数据在 GM(1,1)预测模型中占比加大, 并且引入粒子群算法(PSO)以确定加权系数和相应时间。作者将提出的 SFOGM(1,1)模型与五种预测模型进行残差比较, 结果均优于已有模型, 最后预测了中国江苏省 2020 年的用电量。

本文旨在构造一种新的预测模型, 以预测中国四川省用电量的准确值。该预测模型在 GM(1,1)预测模型的基础上利用改进的 BP 神经网络对残差部分进行补充, 被称为 GM-ABP 模型。GM(1,1)模型由一个单变量的一阶微分方程构成。其适合对“少数据, 贫信息”的原始数据进行分析, 所以我们将 GM(1,1)模型用于数据预测的第一步。预测数据与真实值之间进行比较, 残差部分则由人工神经网络进行训练。在对于传统神经网络的改进方面, 我们采用了 Adam 算法进行改进, 既减少了人工神经网络陷入局部最小值的问题, 又提高了训练的速度。GM-ABP 模型即兼顾了 GM(1,1)模型利用小样本预测的适用性, 又利用了人工神经网络对于非线性特性的强适应性。最终我们将 GM-ABP 模型用于预测中国四川省的电力消耗总量, 以扩展在解决预测问题上的新思路。

本文的设计工作如下: 下一节我们将介绍 GM(1,1)模型, 传统 BP 神经网络模型和 Adam 优化算法。第三节我们将介绍我们提出的新的 GM-ABP 模型。我们利用 GM-ABP 模型对中国四川省统计局给出的统计年鉴数据对用电总量进行预测, 并将另外两种模型的预测结果与之相比较, 这部分在第四节给出。最后一节, 我们给出了本文的结论以及一些政策建议, 并且在最后讨论了未来的研究方向。

## 2. 预备知识

### 2.1. GM(1,1)模型

GM(1,1)模型具有所需样本小, 无需考虑数据分布规律, 预测精度较高等特点, 这些特点也决定了

GM(1,1)模型可以被广泛的应用于各个领域。GM(1,1)模型的时间序列数据基于已知的综合信息,用微分方程来近似拟合时间序列的动态过程,然后对时间序列进行推导与达到预测的目的。用来拟合时间序列的是单基一阶微分方程,因此称为GM(1,1)模型[31]。具体建模步骤如下:

Step 1: 生成累加序列即 1-AGO 序列。假设有非负序列

$$X^{(0)} = (X_{(1)}^{(0)}, X_{(2)}^{(0)}, \dots, X_{(n)}^{(0)}) \quad (1)$$

取值的时间间隔相等,并且  $n \geq 4$ 。则有 1-AGO 序列为

$$X^{(1)} = (X_{(1)}^{(1)}, X_{(2)}^{(1)}, \dots, X_{(n)}^{(1)}) \quad (2)$$

其中第  $k$  个元素为  $X_{(k)}^{(1)} = \sum_{i=1}^k X_{(i)}^{(0)}$ ,  $k = (1, 2, \dots, n)$ 。

Step 2: 生成紧邻均值序列。有序列

$$Z^{(1)} = (Z_{(2)}^{(1)}, Z_{(3)}^{(1)}, \dots, Z_{(n)}^{(1)}) \quad (3)$$

被称为紧邻均值序列,其中  $Z_{(k)}^{(1)} = \delta X_{(k)}^{(1)} + \delta X_{(k-1)}^{(1)}$ ,  $k = (2, 3, \dots, n)$ ,  $\delta = 0.5$ 。

Step 3: 建立灰色微分方程。GM(1,1)模型的均值形式为  $X_{(k)}^{(0)} + aZ_{(k)}^{(1)} = b$ , 则 GM(1,1)模型相应的白化微分方程为

$$\frac{dX^{(1)}}{dt} + aX^{(1)} = b \quad (4)$$

其中  $a$  称为发展系数,  $b$  称为内生控制灰数。

Step 4: 计算系数。设待估向量  $\hat{u} = (a, b)^T$ , 利用最小二乘法计算  $\hat{u} = (B^T B)^{-1} B^T Y$ , 其中  $B = \begin{bmatrix} -Z_{(2)}^{(1)} & 1 \\ -Z_{(3)}^{(1)} & 1 \\ \vdots & \vdots \\ -Z_{(n)}^{(1)} & 1 \end{bmatrix}$ ,

$$Y = \begin{bmatrix} X_{(2)}^{(0)} \\ X_{(3)}^{(0)} \\ \vdots \\ X_{(n)}^{(0)} \end{bmatrix}。$$

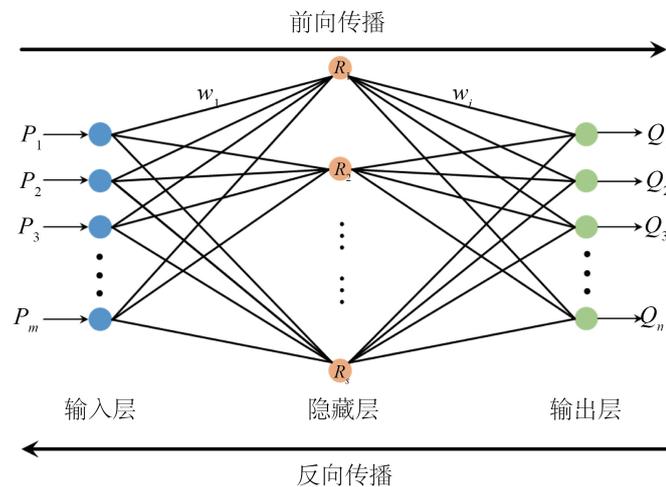
Step 5: 得出灰色预测结果。

$$\begin{cases} \hat{X}_{(k+1)}^{(1)} = \left( X_{(1)}^{(0)} - \frac{b}{a} \right) e^{-ak} + \frac{b}{a}, & k = 1, 2, \dots, n \\ \hat{X}_{(k+1)}^{(0)} = \hat{X}_{(k+1)}^{(1)} - \hat{X}_{(k)}^{(1)} \end{cases} \quad (5)$$

其中  $\hat{X}_{(k+1)}^{(0)}$  即为  $k+1$  时刻的预测值。

## 2.2. BP 神经网络

BP (back propagation)神经网络是一种按照误差逆向传播算法训练的多层前馈神经网络,是应用最广泛的神经网络模型之一。BP神经网络分为三层即输入层,隐藏层和输出层,具体结构如图1所示。



**Figure 1.** The structure of BP neural network  
**图 1.** BP 神经网络结构图

BP 算法包括信号的正向传播和误差的反向传播两个过程。正向传播时, 输入信号通过隐藏层作用于输出节点, 经过非线性变换得到输出信号, 完成一次正向传播。反向传播则是将输出误差反向传输给隐藏层, 并将误差按权重分摊给各个节点, 以各节点获得的误差信号作为调整权重的依据。通过反复学习, 使误差沿梯度方向下降, 最终按照可接受的最小误差范围结束学习得到结果。在 BP 神经网络的反向传播中, 每个连接权重均需更新。例如更新图 1 中的权重, 更新公式为:

$$w'_i = w_i - \eta \frac{\partial \delta}{\partial w_i} \quad (6)$$

其中  $\eta$  为学习率,  $\delta$  为误差函数。在传统 BP 神经网络中学习率  $\eta$  是一个人为固定的值, 这就导致函数可能在极值点处来回震荡, 导致最终无法收敛。因此我们需要选取一种动态方法对学习率进行修正。学习率关系到神经网络梯度下降的方向及快慢, 好的学习率可以优化下降路径减少迭代次数, 减少陷入局部最小值的情况。本文就采用了 Adam 优化器对 BP 神经网络的梯度下降进行优化。

### 2.3. Adam 优化算法

Adam 优化算法是结合了 RMSprop 优化算法和动量法所提出的优化算法[32] [33]。Adam 优化算法改进后更新权重的计算公式为:

$$w_{(t)} = w_{(t-1)} - \frac{\eta}{\sqrt{S_{(t)} + \varepsilon}} \cdot V_{(t)} \quad (7)$$

其中  $V_{(t)} = \beta_1 V_{(t-1)} + (1 - \beta_1) \Delta w_{(t)}$ ,  $S_{(t)} = \beta_2 S_{(t-1)} + (1 - \beta_2) \Delta w_{(t)} \cdot \Delta w_{(t)}$ 。  $V_{(t)}$  是指数加权移动平均后  $t$  时刻的冲量,  $S_{(t)}$  是指数加权移动平均后所有梯度的平方和,  $\varepsilon$  是一个极小值, 防止分母为 0。  $\beta_1$  和  $\beta_2$  是两个超参数用于指数加权移动平均。

Adam 算法从两方面对权重更新进行了优化。一是加入冲量法的思想, 结合历史数据修正不同维度上的分量, 减小导致震荡方向的分量, 增加方向稳定不变的分量。这样就可以优化下降路径, 更快的到达极值点。另一方面, Adam 算法中结合了 RMSprop 算法, 利用历史数据对学习率实现自适应。如果对历史数据修改越大, 那么学习率减小量也就越大。

### 3. 构建 GM-ABP 模型

灰色预测模型可以在不确定系统中对非线性的小数据量的数据进行预测。但当数据发生突变时, 灰色预测的误差就会很高。因此我们需要对灰色预测后的数据进行误差补偿。神经网络具有强大的学习能力, 通过学习可以预测这些突变情况。但如果用神经网络完全取代灰色预测也会发生问题。数据在进入神经网络需做预处理, 否则会造成训练模式过多增加网络结构, 降低学习效率, 大量消耗资源。另外, 单独使用神经网络进行预测的数据应是非稀疏的, 且数据量越大模式预测越准确, 故电力消耗预测问题不适用于单独的人工神经网络。基于以上原因本文提出了利用神经网络来建立误差修正模型修正灰色预测结果的 GM-ABP 模型, GM-ABP 模型步骤如图 2 所示。

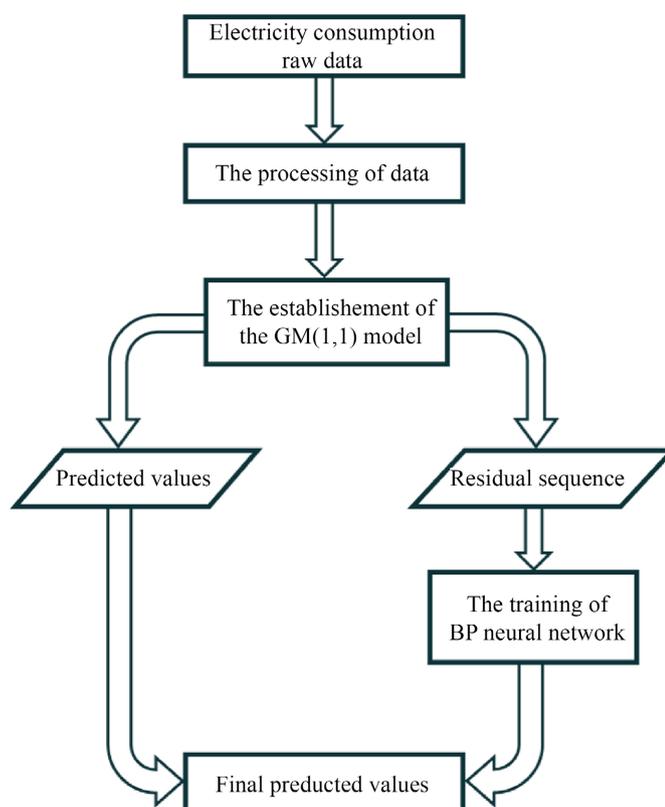


Figure 2. The structure of GM-ABP model

图 2. GM-ABP 模型流程图

本文所用到的数据均来自中国四川省统计年鉴, 我们以 2005-2020 年电力平衡表中消费总量数据作为原始数据进行分析预测, 则有  $E^{(0)} = (E_{(1)}^{(0)}, E_{(2)}^{(0)}, \dots, E_{(n)}^{(0)})$ 。GM-ABP 模型具体步骤如下:

Step1: 生成 1-AGO 序列。有序列

$$E^{(1)} = (E_{(1)}^{(1)}, E_{(2)}^{(1)}, \dots, E_{(n)}^{(1)}) \quad (8)$$

其中  $E_{(k)}^{(1)} = \sum_{i=1}^k E_{(i)}^{(0)}$ ,  $k = (1, 2, \dots, n)$ 。

Step2: 生成紧邻均值序列。有序列

$$Z^{(1)} = (Z_{(2)}^{(1)}, Z_{(3)}^{(1)}, \dots, Z_{(n)}^{(1)}) \quad (9)$$

其中  $Z_{(k)}^{(1)} = \delta X_{(k)}^{(1)} + \delta X_{(k-1)}^{(1)}$ ,  $k = (2, 3, \dots, n)$ ,  $\delta = 0.5$ 。

Step3: 建立灰色微分方程。GM(1,1)模型的均值形式为  $X_{(k)}^{(0)} + aZ_{(k)}^{(1)} = b$ , 相应的白化微分方程为

$$\frac{dX^{(1)}}{dt} + aX^{(1)} = b \quad (10)$$

Step4: 计算系数。利用最小二乘法计算灰参数  $a$  和  $b$ 。

Step5: 得出灰色预测结果。计算方程组

$$\begin{cases} \hat{E}_{(k+1)}^{(1)} = \left( E_{(1)}^{(0)} - \frac{b}{a} \right) e^{-ak} + \frac{b}{a}, & k = 1, 2, \dots, n \\ \hat{E}_{(k+1)}^{(0)} = \hat{E}_{(k+1)}^{(1)} - \hat{E}_{(k)}^{(1)} \end{cases} \quad (11)$$

得到  $k+1$  时  $E_{(k+1)}^{(0)}$  的预测值。

Step6: 得到残差序列。原始数据与预测数据之间的差为残差序列。残差序列为:

$$e_{(k)}^{(0)} = E_{(k)}^{(0)} - \hat{E}_{(k)}^{(0)} \quad (12)$$

Step7: 训练人工神经网络。将残差序列作为输入,  $k$  时的误差项  $e_{(k)}^{(0)}$  作为输出训练 Adam 算法优化的 BP 神经网络。然后将前  $k$  期的残差作为输入放入 BP 神经网络中, 此时的输出  $\hat{e}_{(k+1)}^{(0)}$  即是  $k+1$  时的预测残差。

Step8: 得到最终预测值。最终预测值为:

$$E_{(k+1)} = \hat{E}_{(k+1)}^{(0)} + \hat{e}_{(k+1)}^{(0)} \quad (13)$$

## 4. 四川省用电量预测

### 4.1. GM-ABP 模型预测

我们统计了 2005 年至 2021 年中国四川省统计局发布的统计年鉴, 将 2010 年至 2020 年用电数据进行分析。最终通过 GM-ABP 模型对中国四川省 2021 年至 2023 年的用电量进行预测。2010~2020 年中国四川省用电量如表 1 所示:

**Table 1.** Electricity consumption in Sichuan Province (100 million kWh)

**表 1.** 四川省用电量(100 million kWh)

年份	用电量	年份	用电量	年份	用电量	年份	用电量
2005	1018.76	2010	1549.03	2015	2013.4	2020	2880.2
2006	1059.44	2011	1962.5	2016	2101		
2007	1177.5	2012	2009.6	2017	2205.2		
2008	1235.78	2013	1984.6	2018	2459.5		
2009	1361.87	2014	2055.2	2019	2635.8		

将原始数据带入 GM-ABP 模型, 通过公式(8)和公式(9)分别得到 1-AGO 序列和紧邻均值序列, 最终的紧邻均值序列为: {1548.48, 2666.95, 3873.59, 5172.415, 6627.865, 8383.63, 10369.68, 12366.78, 14386.68, 16420.98, 18478.18, 20631.28, 22963.63, 25511.28, 28269.28}。再利用最小二乘法计算得

到白化方程的灰参数  $a = -0.044353$ ,  $b = 1701.793968$ 。利用公式(10)计算得出拟合结果如表 2 所示。并且通过初步预测可以得出 2021~2023 年用电量的预测值分别为 3002.08, 3188.32, 3386.10 (100 million kWh), 此时的预测值并非最终预测结果, 还需要 BP 神经网络部分进行误差修正。

**Table 2.** Fitted electricity consumption of the GM(1,1) model (100 million kWh)

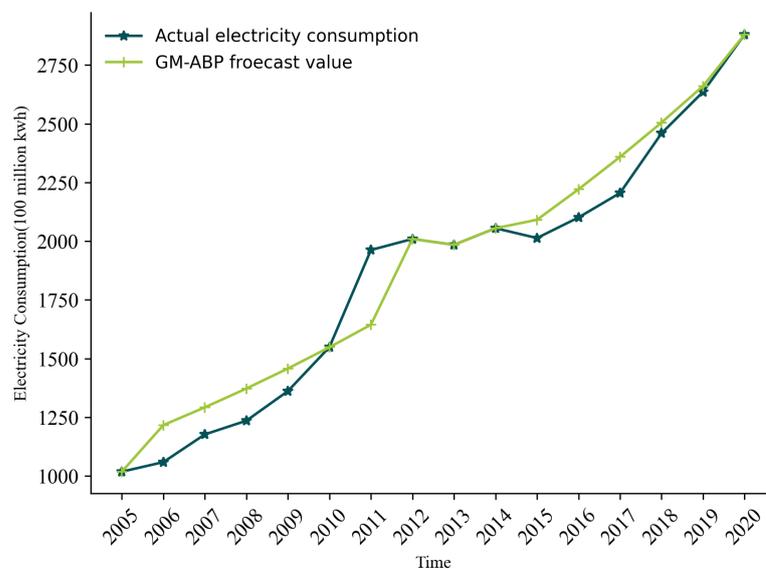
**表 2.** GM(1,1)模型的拟合用电量(100 million kWh)

年份	用电量	年份	用电量	年份	用电量	年份	用电量
2005	1018.76	2010	1548.44	2015	2092.13	2020	2826.73
2006	1217.14	2011	1644.50	2016	2221.92		
2007	1292.64	2012	1746.52	2017	2359.76		
2008	1372.83	2013	1854.86	2018	2506.14		
2009	1458.00	2014	1969.93	2019	2661.61		

通过公式(11)计算残差序列, 并作为 BP 神经网络的输入。GM-ABP 模型的人工神经网络部分采用双隐藏层的 BP 神经网络, 以 6 年的数据作为输入, 预测下一年的总用电量值。采用双隐藏层的原因是双隐藏层可以表示任意精度的决策边界, 可以更好的映射非线性数据。在对 2022 年和 2023 年总电量的预测过程中, 我们分别将模型给出的 2021 年和 2022 年的预测值作为输入值, 再通过 GM-ABP 模型给出最终预测值。最终预测得到 2021~2023 年用电总量分别为: 3245.55, 3328.90, 3475.96 (100 million kWh)。

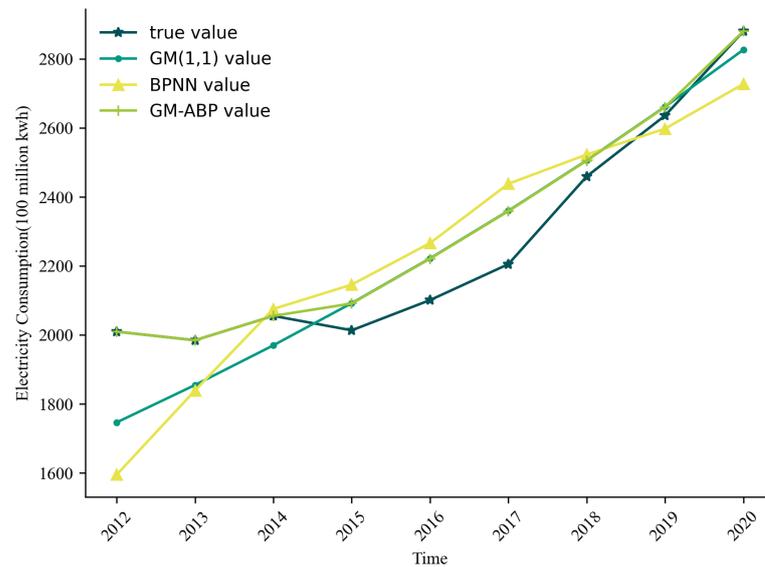
#### 4.2. 模型预测结果分析

因为 GM-ABP 源于 GM(1,1)模型和 Adam-BP 神经网络模型的结合, 因此我们将这两种模型的预测结果与 GM-ABP 模型的结果相比较, 以验证模型在电力预测方面的准确性。GM-ABP 模型的拟合图像如图 3 所示。三种模型对于中国四川省 2012~2020 年用电总量的预测图像如图 4 所示。



**Figure 3.** The fitting diagram of the GM-ABP model

**图 3.** GM-ABP 模型拟合图



**Figure 4.** The fitting comparison of GM(1,1), BPNN, and GM-ABP model  
**图 4.** GM(1,1)、BPNN、GM-ABP 拟合比较

我们采用平均绝对误差(MAE), 平均绝对百分比误差(MAPE), 均方误差(MSE), 均方根误差(RMSE), 决定系数( $R^2$ )五类误差数据对 GM-ABP 模型的预测精度进行检验。设  $f(x_i)$  为第  $i$  个数据的真值,  $\hat{f}(x_i)$  为第  $i$  个数据的预测值,  $n$  为数据总量。五种误差数据的计算公式如下:

$$\text{MAE}(f(x_i), \hat{f}(x_i)) = \frac{1}{n} \sum_{i=1}^n |f(x_i) - \hat{f}(x_i)| \quad (14)$$

$$\text{MAPE}(f(x_i), \hat{f}(x_i)) = \left( \frac{1}{n} \sum_{i=1}^n \left| \frac{f(x_i) - \hat{f}(x_i)}{f(x_i)} \right| \right) * 100\% \quad (15)$$

$$\text{MSE}(f(x_i), \hat{f}(x_i)) = \frac{1}{n} \sum_{i=1}^n (f(x_i) - \hat{f}(x_i))^2 \quad (16)$$

$$\text{RMSE}(f(x_i), \hat{f}(x_i)) = \sqrt{\frac{1}{n} \sum_{i=1}^n (f(x_i) - \hat{f}(x_i))^2} \quad (17)$$

$$R^2_{(f(x_i), \hat{f}(x_i))} = 1 - \frac{\sum_{i=1}^n (f(x_i) - \hat{f}(x_i))^2}{\sum_{i=1}^n (f(x_i) - \bar{f}(x))^2} \quad (18)$$

三种模型的误差表现如表 3 所示:

**Table 3.** Error representation of the three models

**表 3.** 三种模型的误差表现

模型	MAE	MAPE(%)	MSE	RMSE	$R^2$
GM-ABP	46.85	0.02	5189.16	72.04	0.94
GM(1,1)	106.47	0.05	15969.40	126.37	0.83
BPNN	151.63	0.07	35698.19	188.94	0.62

根据上表所示, GM-ABP 模型在 MSE, RMSE, MAE, MAPE 数据方面均优于另外两种模型。另外 GM-ABP 模型  $R^2$  数值达到 0.944 说明模型拟合程度较好, 具有对用电量数据准确预测的能力。在图中我们还得出, 神经网络对 GM(1,1)模型的补充效果很明显, 前三种误差值平均减少了 35.71%, 并且提高了 GM(1,1)模型预测的拟合程度。GM-ABP 模型 MSE 值相较于 Adam-BPNN 模型提高了 85.46%。另外, 我们发现 GM(1,1)相较于 Adam-BPNN 模型更适用于电力预测模型, 说明我们利用 GM(1,1)模型进行趋势预测并加以 BPNN 的修正是正确的。综上所述, GM-ABP 模型在用电量预测问题上优于 GM(1,1)模型和 Adam-BPNN 模型, 且在预测结果上有很好的表现。

## 5. 研究结论与政策建议

### 5.1. 研究结论

本文基于 GM(1,1)模型和 BP 神经网络建立了新的 GM-ABP 模型。我们将 GM-ABP 模型用于中国四川省年用电总量的预测, 并与传统 GM(1,1)模型和 Adam-BP 神经网络模型进行了比较, 证明了该模型的优越性。本文提出的模型在 GM(1,1)模型的基础上加以修正, 利用 Adam 算法优化的 BP 神经网络对残差进行拟合。结果显示 GM-ABP 模型的预测精度均优于 GM(1,1)模型和 Adam-BP 神经网络模型, 且预测精度有较大提升。最后通过 GM-ABP 模型给出了四川省 2021~2023 年用电总量的预测值。

### 5.2. 政策建议

随着中国经济的不断高速增长, 用电量激增导致的问题日益突出。四川省目前所有的常规发电方式中, 水利发电最为突出。2021 年, 四川省全年发电量 4530.33 (100 million kWh), 其中水电 3531 (100 million kWh), 占比高达 77.95%。2022 年, 四川省就因罕见的高温天气导致主要流域缺水, 水电供应下降严重。对于用电量的提前预测就可以预防用电高峰时用电紧张的问题, 做到未雨绸缪。另外降水量和蓄水量的多少直接影响着水利发电能力, 因此对于区域的水文监测必不可少。对于电力存储的研究也是保障用电稳定的一方面。

### 5.3. 未来研究方向

本文提出的 GM-ABP 模型可以很好地解决用电量预测的问题, 但也存在一定的局限性。例如, 影响用电量的因素有很多, 类似极端高温天气这类的突变因素很大程度会影响年用电量。因此, 在未来可以将此类因素造成的影响进行量化, 加入模型的预测中。

## 参考文献

- [1] Pao, H.T. (2009) Forecast of Electricity Consumption and Economic Growth in Taiwan by State Space Modeling. *Energy*, **34**, 1779-1791. <https://doi.org/10.1016/j.energy.2009.07.046>
- [2] Li, X., Wang, Y., Ma, G., Chen, X., Fan, J. and Yang, B. (2022) Prediction of Electricity Consumption during Epidemic Period Based on Improved Particle Swarm Optimization Algorithm. *Energy Reports*, **8**, 437-446. <https://doi.org/10.1016/j.egyr.2022.05.088>
- [3] Ghalekhondabi, I., Ardjmand, E., Weckman, G.R. and Young, W.A. (2017) An Overview of Energy Demand Forecasting Methods Published in 2005-2015. *Energy Systems*, **8**, 411-447. <https://doi.org/10.1007/s12667-016-0203-y>
- [4] An, N., Zhao, W., Wang, J., Shang, D. and Zhao, E. (2013) Using Multi-Output Feed forward Neural Network with Empirical Mode Decomposition Based Signal Filtering for Electricity Demand Forecasting. *Energy*, **49**, 279-288. <https://doi.org/10.1016/j.energy.2012.10.035>
- [5] Hernandez, L., Baladron, C., Aguiar, J.M., Carro, B., Sanchez-Esguevillas, A.J., Lloret, J. and Massana, J. (2014) A Survey on Electric Power Demand Forecasting: Future Trends in Smart Grids, Microgrids and Smart Buildings. *IEEE Communications Surveys and Tutorials*, **16**, 1460-1495. <https://doi.org/10.1109/SURV.2014.032014.00094>
- [6] Lopez-Martin, M., Sanchez-Esguevillas, A., Hernandez-Callejo, L., Arribas, J.I. and Carro, B. (2021) Novel Data-Driven

- Models Applied to Short-Term Electric Load Forecasting. *Applied Sciences (Switzerland)*, **11**, Article No. 5708. <https://doi.org/10.3390/app11125708>
- [7] Lopez-martin, M., Sanchez-esquivillas, A., Hernandez-callejo, L., Arribas, J.I. and Carro, B. (2021) Additive Ensemble Neural Network with Constrained Weighted Quantile Loss for Probabilistic Electric-Load Forecasting. *Sensors*, **21**, Article No. 2979. <https://doi.org/10.3390/s21092979>
- [8] Mariano-Hernández, D., Hernández-Callejo, L., Solís, M., Zorita-Lamadrid, A., Duque-Perez, O., Gonzalez-Morales, L. and Santos-García, F. (2021) A Data-Driven Forecasting Strategy to Predict Continuous Hourly Energy Demand in Smart Buildings. *Applied Sciences (Switzerland)*, **11**, Article No. 7886. <https://doi.org/10.3390/app11177886>
- [9] Lei, M., Shiyang, L., Chuanwen, J., Hongling, L. and Yan, Z. (2009) A Review on the Forecasting of Wind Speed and Generated Power. *Renewable and Sustainable Energy Reviews*, **13**, 915-920. <https://doi.org/10.1016/j.rser.2008.02.002>
- [10] Chu, F.L. (2009) Forecasting Tourism Demand with ARMA-Based Methods. *Tourism Management*, **30**, 740-751. <https://doi.org/10.1016/j.tourman.2008.10.016>
- [11] Ramos, P., Santos, N. and Rebelo, R. (2015) Performance of State Space and ARIMA Models for Consumer Retail Sales Forecasting. *Robotics and Computer-Integrated Manufacturing*, **34**, 151-163. <https://doi.org/10.1016/j.rcim.2014.12.015>
- [12] García-Ascanio, C. and Maté, C. (2010) Electric Power Demand Forecasting Using Interval Time Series: A Comparison between VAR and iMLP. *Energy Policy*, **38**, 715-725. <https://doi.org/10.1016/j.enpol.2009.10.007>
- [13] Takeda, H., Tamura, Y. and Sato, S. (2016) Using the Ensemble Kalman Filter for Electricity Load Forecasting and Analysis. *Energy*, **104**, 184-198. <https://doi.org/10.1016/j.energy.2016.03.070>
- [14] Chan, S.C., Tsui, K.M., Wu, H.C., Hou, Y., Wu, Y.C. and Wu, F.F. (2012) Load/Price Forecasting and Managing Demand Response for Smart Grids: Methodologies and Challenges. *IEEE Signal Processing Magazine*, **29**, 68-85. <https://doi.org/10.1109/MSP.2012.2186531>
- [15] Lago, J., de Ridder, F. and de Schutter, B. (2018) Forecasting Spot Electricity Prices: Deep Learning Approaches and Empirical Comparison of Traditional Algorithms. *Applied Energy*, **221**, 386-405. <https://doi.org/10.1016/j.apenergy.2018.02.069>
- [16] Li, R.X. (2012) Design and Realization of 3-DOF Welding Manipulator Control System Based on Motion Controller. *Energy Procedia*, **14**, 931-936. <https://doi.org/10.1016/j.egypro.2011.12.1163>
- [17] Cinar, D., Kayakutlu, G. and Daim, T. (2010) Development of Future Energy Scenarios with Intelligent Algorithms: Case of Hydro in Turkey. *Energy*, **35**, 1724-1729. <https://doi.org/10.1016/j.energy.2009.12.025>
- [18] Wu, Y., Gao, R. and Yang, J. (2020) Prediction of Coal and Gas Outburst: A Method Based on the BP Neural Network Optimized by GASA. *Process Safety and Environmental Protection*, **133**, 64-72. <https://doi.org/10.1016/j.psep.2019.10.002>
- [19] Uzlu, E. (2021) Estimates of Greenhouse Gas Emission in Turkey with Grey Wolf Optimizer Algorithm-Optimized Artificial Neural Networks. *Neural Computing and Applications*, **33**, 13567-13585. <https://doi.org/10.1007/s00521-021-05980-1>
- [20] Cinar, A.C. and Natarajan, N. (2022) An Artificial Neural Network Optimized by Grey Wolf Optimizer for Prediction of Hourly Wind Speed in Tamil Nadu, India. *Intelligent Systems with Applications*, **16**, Article ID: 200138. <https://doi.org/10.1016/j.iswa.2022.200138>
- [21] Deng, J.L. (1989) Introduction Grey System Theory. *Journal of Grey System*, **1**, 191-243.
- [22] Deng, J.L. (1989) Introduction to Grey System Theory. *The Journal of Grey System*, **1**, 1e24.
- [23] Ding, S., Hipel, K.W. and Dang, Y.G. (2018) Forecasting China's Electricity Consumption Using a New Grey Prediction Model. *Energy*, **149**, 314-328. <https://doi.org/10.1016/j.energy.2018.01.169>
- [24] Guefano, S., Tamba, J.G., Azong, T.E.W. and Monkam, L. (2021) Forecast of Electricity Consumption in the Cameroon Residential Sector by Grey and Vector Autoregressive Models. *Energy*, **214**, Article ID: 118791. <https://doi.org/10.1016/j.energy.2020.118791>
- [25] Du, X., Wu, D. and Yan, Y. (2023) Prediction of Electricity Consumption Based on GM(1,Nr) Model in Jiangsu Province, China. *Energy*, **262**, Article ID: 125439. <https://doi.org/10.1016/j.energy.2022.125439>
- [26] Xu, N., Dang, Y. and Gong, Y. (2017) Novel Grey Prediction Model with Nonlinear Optimized Time Response Method for Forecasting of Electricity Consumption in China. *Energy*, **118**, 473-480. <https://doi.org/10.1016/j.energy.2016.10.003>
- [27] Wu, L., Gao, X., Xiao, Y., Yang, Y. and Chen, X. (2018) Using a Novel Multi-Variable Grey Model to Forecast the Electricity Consumption of Shandong Province in China. *Energy*, **157**, 327-335. <https://doi.org/10.1016/j.energy.2018.05.147>
- [28] Hu, Y.C. (2017) A Genetic-Algorithm-Based Remnant Grey Prediction Model for Energy Demand Forecasting. *PLOS*

- ONE*, **12**, e0185478. <https://doi.org/10.1371/journal.pone.0185478>
- [29] Hsu, C.C. and Chen, C.Y. (2003) Applications of improved Grey Prediction Model for Power Demand Forecasting. *Energy Conversion and Management*, **44**, 2241-2249. [https://doi.org/10.1016/S0196-8904\(02\)00248-0](https://doi.org/10.1016/S0196-8904(02)00248-0)
- [30] Zhu, X., Dang, Y. and Ding, S. (2020) Using a Self-Adaptive Grey Fractional Weighted Model to Forecast Jiangsu's Electricity Consumption in China. *Energy*, **190**, Article ID: 116417. <https://doi.org/10.1016/j.energy.2019.116417>
- [31] Liu, H. and Zhang, D.L. (2012) Analysis and Prediction of Hazard Risks Caused by Tropical Cyclones in Southern China with Fuzzy Mathematical and Grey Models. *Applied Mathematical Modelling*, **36**, 626-637. <https://doi.org/10.1016/j.apm.2011.07.024>
- [32] Kingma, D.P. and Ba, J. (2014) Adam: A Method for Stochastic Optimization.
- [33] 2019 Third International Conference on Inventive Systems and Control (ICISC) (n.d.) IEEE.