# 基于数据序列特征的振荡序列GM(1,1)预测及其应用

王 霞，叶秋彤

（河南财经政法大学工商管理学院，郑州 450046）

**摘要：**针对传统GM(1,1)模型在处理振荡序列时预测模拟精度不高，部分改进模型计算复杂度高、数据需求大、泛化能力弱等问题，从数据序列特征的角度提出一种振荡序列灰色预测方法。观察分析振荡序列呈现的序列特征和发展趋势，利用序列变动趋势将数据分组截取部分近期数据序列、利用季节特性将序列分组3类规则对数据进行预处理，再根据分组数据序列特征利用缓冲算子和GM(1,1)模型对振荡序列进行预测。通过多案例实证分析，验证该方法在预测模拟性能方面明显优于传统GM(1,1)模型及部分改进模型，并且提高了GM(1,1)模型的泛化能力，且该方法简单易于操作。将该方法应用于河南省太阳能发电量的预测中，验证了方法的有效性。

**关键词：**振荡序列；数据序列特征；GM(1,1)模型；缓冲算子

**中图分类号：**N945.1 **文献标志码：**A **文章编号：**1671－1807(2026)09－0044－07

振荡序列是一种随时间推移呈现周期性或非周期性波动的数据序列，其本质源于系统内部的反馈机制与外部环境扰动的叠加效应，这种动态行为广泛存在于自然系统、社会系统和工程系统等现实生活中[1-2]，如太阳能发电呈现明显的季节性振荡特性[3]。振荡序列往往是非平稳的，统计特性随时间变化，这使得传统的预测方法难以直接应用，其预测精度会受到严重影响[4-5]。

灰色系统理论以“少数据、贫信息”的不确定性系统为研究对象，对其建模数据没有特殊要求，且需要的数据量少、计算简便等特点，取得了一系列重要的研究成果并得到了国内外同行的认可[6-7]。GM(1,1)(grey model first order one variable)模型是灰色预测理论的经典模型，对于具有近似指数规律的单调性序列[8]，其模拟和预测精度较高；同时一些学者从生成算子[9]、初始值[10]、时间响应函数[11]等方面对模型进行优化，进一步提高了GM(1,1)模型的预测精度，但是改进模型对于具有非指数律或波动性较强的振荡数据序列的预测仍难以取得理想的效果[12-13]。

针对GM(1,1)模型用于预测振荡序列时难以达到预期效果的问题，学者们从不同角度进行了深入探讨，其研究成果主要集中在两个方面：①通过数据变化使原始序列具有准指数规律。例如，钱吴永和党耀国[14]利用加速平移变换使振荡序列变为单调增加序列，显著提高了GM(1,1)模型的预测精度；李翀和谢秀萍[15]提出均值像反正切函数权值累加算子使序列变为单调递增序列，建立的$DGM(1,1)_{atan}$[discrete grey model (1,1)]模型综合考虑数据的整体增长趋势与局部波动特征；曾波等[16]基于幂指数构造的一种智能缓冲算子能够改变振荡序列的变化趋势从而提高预测的精度。②对传统模型的拓展。例如，Zhou等[17]提出的灰色季节趋势最小二乘支持向量机模型显著提高了模型的整体性能；Ding等[18]设计了一种新的空间接近效应测度综合空间指数，提出了嵌入时空联系的灰色多变量卷积模型；Qian和Wang[19]提出了一种将HP(Hodrick-Prescott)滤波器集成到灰色模型GM(1,1)中的季节性预测新方法；Wang等[20]提出了一种基于数据分组的灰色建模方法DGGM(1,1)。

综上所述，已有研究在运用灰色预测模型处理振荡现象方面取得了显著进展，这些模型在理论深

**收稿日期：**2026-01-11

**基金项目：**教育部人文社科项目(24YJC630217)；河南省科技攻关项目(242102320186)；河南省高校人文社会科学研究一般项目(2025-ZDJH-053)；河南省哲学社会科学规划项目(2024CJJ045)

**作者简介：**王霞(1985—)，女，河南淅川人，博士，副教授，硕士研究生导师，研究方向为综合评价、灰色系统理论、绿色低碳；叶秋彤(2006—)，女，河南平顶山人，研究方向为综合评价。

度上展现出极强的创新性，在技术验证层面确实具有突破性,为后续研究打下了坚实的基础。然而现有研究存在一些不足之处:①现有研究多是数据导向型建模方法,依赖数据驱动的模型无法反映系统发展的特征;②现有改进的灰色预测模型具有计算复杂度高、晦涩难懂、数据需求大、泛化能力弱等特点;③现有改进的灰色模型的模拟和预测精度并不理想。因此,现从数据序列特征出发,根据数据序列变动趋势将数据分组、截取部分近期数据序列、利用季节特性将数据分组 3 类规则对数据进行预处理,通过案例分析来探讨利用灰色 GM(1,1)模型如何处理振荡序列问题。

## 1　GM(1,1)模型

设非负原始序列为 $X^{(0)}=\{x^{(0)}(1),x^{(0)}(2),\cdots,x^{(0)}(n)\}$,若存在 $k$ , $k'\in\{2,3,\cdots,n\}$ , 有 $x(k)-x(k-1)>0$,$x(k')-x(k'-1)<0$,则称 $X$ 为随机振荡序列,其中 $x^{(0)}(t)$为序列 $X^{(0)}$在第 $t$ 个时间点的观测值。原始序列 $X^{(0)}$的一阶累加生成序列 $X^{(1)}=\{x^{(1)}(1),x^{(1)}(2),\cdots,x^{(1)}(n)\}$,其中 $x^{(1)}(k)=\sum_{i=1}^{k}x^{(0)}(i)$; 原始序列 $X^{(0)}$做一阶累减生成序列 $\alpha^{(1)}X^{(0)}=\{\alpha^{(1)}x^{(0)}(1),\alpha^{(1)}x^{(0)}(2),\cdots,\alpha^{(1)}x^{(0)}(n)\}$,其中 $x^{(0)}(k)d=x^{(0)}(k)-x^{(0)}(k-1),k=2,3,\cdots,n$。$Z^{1}=\{z^{(1)}(1),z^{(1)}(2),\cdots,z^{(1)}(n)\}$为序列 $X^{(1)}$的紧邻均值生成序列,其中 $z^{(1)}(k)=0.5[x^{(1)}(k)+x^{(1)}(k-1)],k=2,3,\cdots,n$。

**定义 1**:设 $X^{(0)}$、$X^{(1)}$、$Z^{(1)}$如上所述,则

$$x^{(0)}(k)+ax^{(1)}(k)=b,\ k=2,3,\cdots,n \tag{1}$$

称式(1)为 GM(1,1)模型的基本形式,其中 $a$ 为发展系数,$b$ 为灰色作用量。其相应的白化微分方程为

$$\frac{\mathrm{d}x^{(1)}(t)}{\mathrm{d}t}+ax^{(1)}(t)=b \tag{2}$$

式中:$t$ 为连续时间变量。白化方程的解也是 GM(1,1)模型的时间响应函数:

$$\hat{x}^{(1)}(k+1)=\left[x^{(0)}(1)-\frac{b}{a}\right]\mathrm{e}^{-ak}+\frac{b}{a},\quad k=1,2,\cdots,n \tag{3}$$

式中:$\hat{x}^{(1)}(k+1)$为 $x^{(1)}$在 $k+1$ 点的预测值。通过累减还原可以得到原始序列的预测值:

$$\begin{aligned}\hat{x}^{(0)}(k)&=\hat{x}^{(1)}(k)-\hat{x}^{(1)}(k-1)\\&=(1-\mathrm{e}^{a})\left[x^{(0)}(1)-\frac{b}{a}\right]\mathrm{e}^{-a(k-1)},\\&\quad k=2,3,\cdots,n\end{aligned} \tag{4}$$

式中:由最小二乘法得到模型参数的估计值为 $\hat{\boldsymbol{a}}=(a,b)^{\mathrm{T}}=(\boldsymbol{B}^{\mathrm{T}}\boldsymbol{B})^{-1}\boldsymbol{B}^{\mathrm{T}}\boldsymbol{Y}$[8],其中

$$\boldsymbol{Y}=\begin{bmatrix}x^{(0)}(2)\\x^{(0)}(3)\\\vdots\\x^{(0)}(n)\end{bmatrix},\quad \boldsymbol{B}=\begin{bmatrix}-z^{(1)}(2) & 1\\-z^{(1)}(3) & 1\\\vdots & \vdots\\-z^{(1)}(n) & 1\end{bmatrix}。$$

科学的模型性能评估对于研究模型的有效性非常重要,常见的测量指标有均方根误差(RMSE)、平均绝对误差(MAE)和平均绝对百分比误差(MAPE)、平均绝对模拟百分误差(MASPE)和平均绝对预测百分误差(MAFPE)[21]。其中,MAE、MAPE 和 RMSE 都是用来衡量模型的整体精度,MASPE 和 MAFPE 则是用来分别衡量模型的模拟和预测精度。如果模型整体精度与模拟精度较高,而预测精度较差,说明模型过度拟合建模序列,但对于预测序列的发展趋势不能进行有效描述,则认为模型的精度较差。

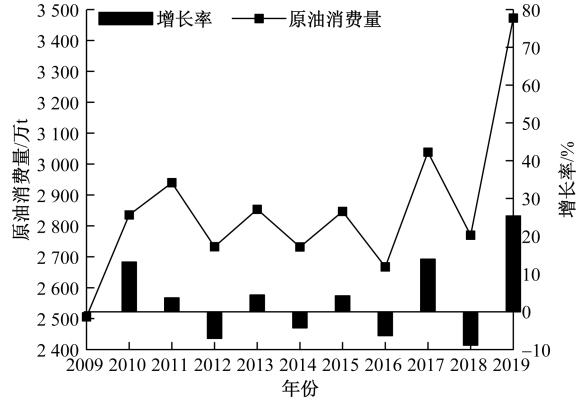
## 2　基于数据序列特征的振荡序列数据预处理

振荡序列是一类具有显著非线性波动特征的时间序列,常伴随随机性和突变性,因此在预测实践中现有模型无法有效拟合非线性振荡模式,导致预测精度不足。首先根据原始数据绘制数据的序列图,根据数据序列图呈现的特征,分析其发展趋势,从根据数据序列变动趋势将数据分组、截取部分近期数据序列、利用季节特性将数据分组 3 个角度对原始数据进行预处理,以提高预测精度。

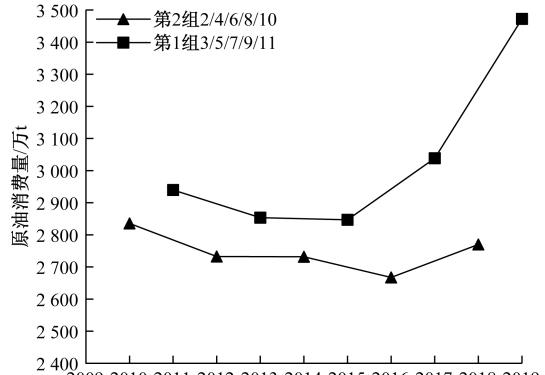
### 2.1　基于序列变动趋势的分组预处理

以文献[21]中 2009—2019 年浙江省原油消费量的数据为例,为更直观地展现数据序列特征与发展趋势,绘制了原油消费量的折线图,如图 1(a)所示。

从图 1(a)中可看出,浙江省原油消费量序列在多个时间点振荡,序列整体无明显上升或下降趋势,该数据序列无法直接适用 GM(1,1)模型进行预测。通过对数据特征折线图的分析可知,第一个数据相对于整个数据序列而言波动比较大,因此如果舍弃第一个数据,剩余的 10 个数据可以等间隔地分成两组,如图 1(b)所示。第 1 组数据包括第 3/5/7/9/11 这 5 个点,表达式为 $X_1=2n-1(n=2,3,\cdots,6)$,该数据序列呈现明显的近似指数规律。第 2 组数据包括第 2/4/6/8/10 这 5 个点,表达式为 $X_2=2n(n=1,2,\cdots,5)$,这 5 个点构成的曲线呈现较小波动,累加生成可以消除这种波动趋势。因此,分组后两组数据分别呈现一定的特征,都适用于 GM(1,1)模型进行预测。




(a) 原油消费量及其年增长率




(b) 原油消费量分组数据

**图 1　2009—2019 年浙江省原油消费量及分组数据、年增长率**

## 2.2　基于序列特征的截取部分数据预处理

以文献[21]中 2000—2021 年欧洲煤炭发电量的数据为例，为更直观地展现数据序列特征与发展趋势，绘制欧洲煤炭发电量的折线图，如图 2 所示。

根据图 2 所示，欧洲煤炭发电量序列在多个时间点振荡，整体无明显的上升或者下降趋势，该数据序列无法直接适用 GM(1,1)模型进行预测。但是通过对数据特征折线图的分析可知，从 2012 年开始欧洲煤炭发电量呈明显的下降趋势；其次，GM(1,1)模型适用于少数据序列的预测，对于30 个数据的序列是否适用 GM(1,1)模型的问题值得深入探讨。因此，截取 2012—2021 年的数据，表达式为 $X_1=n_0+1(n_0=12,\cdots,30)$，该数据序列呈现明显的递减趋势，近似指数规律，适用 GM(1,1)模型进行预测。

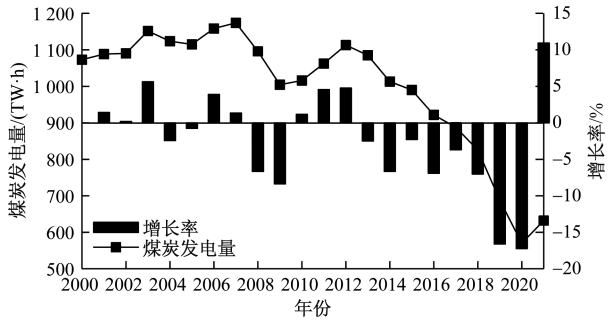



**图 2　2000—2021 年欧洲煤炭发电量及其年增长率**

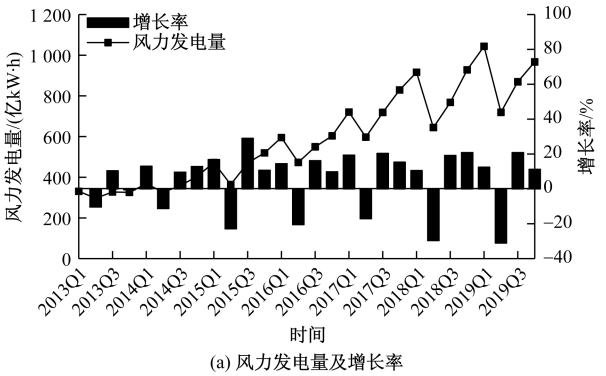
## 2.3　基于数据季节性特征的分组预处理

以文献[19]中中国季节性风力发电数据作为案例 3，为更直观展现数据特点，绘制 2013—2019 年中国风力发电量的折线图，如图 3(a)所示。

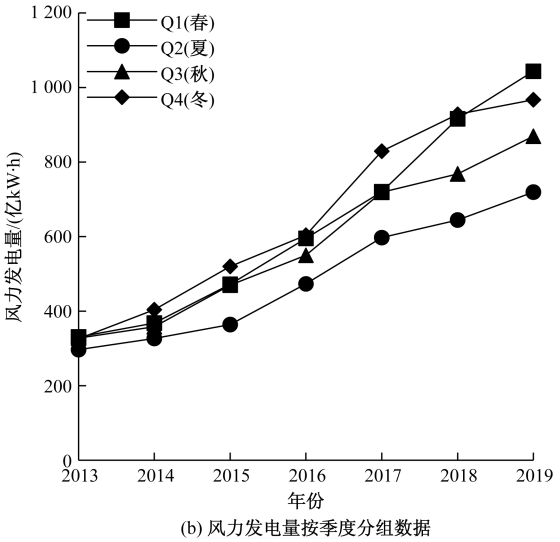
从图 3(a)中可看出，中国风力发电量具有明显的上升趋势，风力发电的季节差异相当大，这是由于风力的季节变化明显，整体而言呈现明显的振荡趋势，该数据序列无法直接适用 GM(1,1)模型进行预测。采用文献[20]中的 DGGM(1,1)模型的思路，将原始数据序列按季度分成 4 组数据，表达式为

$$x^{(0)}(s)=[x^{(0)}(s,1),x^{(0)}(s,2),\cdots,x^{(0)}(s,n)],\quad s=1,2,3,4 \tag{5}$$

由图 3(b)可知，每个季度的数据呈现稳定的上




(a) 风力发电量及增长率




(b) 风力发电量按季度分组数据

Q1～Q4 表示春、夏、秋、冬四季

**图 3　2013—2019 年 Q1～Q4 中国风力发电量及按季度分组数据、增长率**

升趋势,没有出现大幅度振荡的情形,且每组数据呈现明显的递增规律,适用于 GM(1,1)模型进行预测。

## 3　基于数据序列特征的振荡序列 GM(1,1)预测案例分析

### 3.1　案例 1:浙江省原油消费量

根据图 1(b)可知,通过分析第 1 组数据序列的增长率发现,该数据序列前期增长较慢后期增长较快,因此采用文献[22]中的平均弱化缓冲算子作用于原始序列,再用 GM(1,1)模型进行预测。第 2 组数据包括第 2/4/6/8/10 这 5 个点,根据图 1(b)可知,这 5 个点构成的曲线波动较小,累加后近似呈指数规律,因此可以直接运用 GM(1,1)模型进行预测。两个数据序列的 MASPE 值见表 1。

由表 1 可知,单双数数据序列的模拟误差均达到一级模拟精度标准。由于 2020 年 4 月,国务院批复同意《关于支持中国(浙江)自由贸易试验区油气全产业链开放发展的若干措施》以及浙石化炼化一体化项目一期于 2019 年底顺利投产等政策的制定和项目的开展,导致 2020 年和 2021 年浙江省原油产量剧增,因此不再计算 MAFPE,将文献[21]的结果与该模型所得结果进行对比,结果见表 2。

由表 2 可知,本文的预测模型在 MASPE、MAPE、MAE、RMSE 性能方面均优于模型 ODGM(1,1,inif,$w$,$r$)、ODGM(1,1)、TDGM(1,1)和 NGM(1,1,$k$)。该模型是从数据序列的变动趋势角度出发,通过观察原始数据序列呈现的序列特征和发展变动趋势将原始数据序列分组,再结合缓冲算子和 GM(1,1)模型进行预测。该思路易于理解,操作简单,模型性能优良。

**表 1　单双数点数序列模拟相对误差**

| 序列 | 单数点序列 | 双数点序列 |
|---|---|---|
| MASPE/% | 1.073 8 | 1.114 9 |

### 3.2　案例 2:欧洲煤炭发电量

由图 2 可知,2012—2021 年欧洲煤炭发电量数据虽然呈明显的递减规律,但是从年增长率来看,该序列的递减速率不均衡,且前期数据衰减速度较慢,后期数据衰减速度较快,因此采用文献[22]中的平均弱化缓冲算子作用于原始序列,然后构建部分数据 GM(1,1)模型,同时增加 2022 年和 2023 年的数据作为预测数据。将文献[21]的结果与该模型所得结果进行对比,结果见表 3。

由表 3 可知,本文的预测模型在 MASPE、MAPE、MAE、RMSE 性能方面均优于模型 ODGM(1,1,inif,$w$,$r$)、ODGM(1,1)、TDGM(1,1)和 NGM(1,1,$k$)。该预测模型是从数据序列的变动趋势角度出发,通过观察原始数据序列呈现的序列特征和发展变动趋势截取部分原始数据序列,再结合缓冲算子和 GM(1,1)模型进行预测。该思路易于理解,操作简单,模型性能优良。

### 3.3　案例 3:中国风电发电量

由图 3(b)可知,4 组数据增长率呈现前期增长较慢、后期增长较快的特征,因此采用文献[22]中的平均弱化缓冲算子作用于原始序列,再构建 GM(1,1)模型。为了便于进行对比,选取 2013—2018 年作为模拟序列,2019 年作为预测序列,Q1～Q4 这 4 组数据的模拟相对误差见表 4。

由表 4 可知,4 组数据的模拟误差均达到一级模拟精度标准。将文献[19]的结果与本文的结果进行对比,结果见表 5。

**表 2　不同模型的性能评估结果(案例 1)**

| 模型 | MAE/万 t | RMSE/万 t | MAPE/% | MASPE/% | MAFPE/% |
|---|---|---|---|---|---|
| ODGM(1,1,inif,$w$,$r$) | 81.241 9 | 137.999 7 | 2.602 2 | 1.288 3 | 7.200 6 |
| ODGM(1,1) | 107.804 9 | 205.992 5 | 3.356 0 | 1.525 6 | 9.762 2 |
| TDGM(1,1) | 175.451 3 | 290.092 4 | 5.590 1 | 3.643 4 | 13.376 9 |
| NGM(1,1,$k$) | 271.966 4 | 432.846 2 | 9.117 0 | 8.831 7 | 10.258 1 |
| 本文的模型 | 32.380 1 | 35.555 1 | 1.094 4 | 1.094 4 | — |

**表 3　不同模型的性能评估结果(案例 2)**

| 模型 | MAE/(TW·h) | RMSE/(TW·h) | MAPE/% | MASPE/% | MAFPE/% |
|---|---|---|---|---|---|
| ODGM(1,1,inif,$w$,$r$) | 39.798 2 | 52.742 4 | 4.515 2 | 3.352 2 | 8.044 0 |
| ODGM(1,1) | 73.375 4 | 95.215 5 | 8.796 6 | 5.377 9 | 19.052 5 |
| TDGM(1,1) | 80.575 1 | 113.668 2 | 10.302 6 | 4.255 8 | 39.652 4 |
| TGM(1,1,$k$) | 151.924 6 | 221.996 1 | 19.233 1 | 8.024 1 | 55.101 8 |
| 本文的模型 | 20.278 5 | 30.595 5 | 3.135 3 | 2.002 9 | 8.231 2 |

**表 4　单、双数点数序列模拟相对误差**

| 季节 | Q1(春) | Q2(夏) | Q3(秋) | Q4(冬) |
|---|---|---|---|---|
| MASPE/% | 0.463 | 1.347 | 1.283 | 0.809 |

**表 5　不同模型的性能评估结果**

| 模型 | MAE/(亿 kW·h) | RMSE/(亿 kW·h) | MAPE/% | MASPE/% | MAFPE/% |
|---|---|---|---|---|---|
| GM(1,1) | 37.230 0 | 47.190 0 | 7.840 0 | 8.558 2 | 19.834 0 |
| DGGM(1,1) | 13.030 0 | 15.460 0 | 2.580 0 | — | — |
| SGM(1,1) | 26.870 0 | 33.490 0 | 5.460 0 | — | — |
| HPF-GM(1,1) | 18.900 0 | 24.620 0 | 4.170 0 | 4.188 9 | 4.746 3 |
| 本文模型 | 6.857 8 | 8.724 8 | 1.425 8 | 0.975 3 | 3.678 2 |

由表 5 可知，本文预测模型在 MASPE、MAPE、MAE、RMSE 性能方面均优于模型 GM(1,1)、DGGM(1,1)和 SGM(1,1)和 HPF-GM(1,1)。该预测模型是从数据序列的变动趋势角度出发，通过观察原始数据序列呈现的序列特征和发展变动趋势按季节将原始数据序列分组，再结合缓冲算子和 GM(1,1)模型进行预测。该思路易于理解，操作简单，模型性能优良。

### 3.4　案例 4：河南省太阳能发电的实例分析

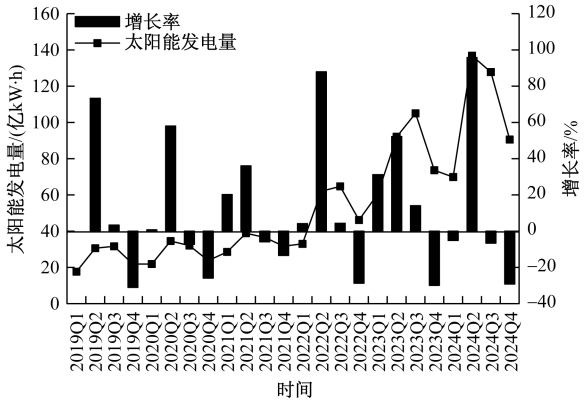
河南省可再生能源主要以风能、太阳能、生物质能和水电为主，近年来光伏和风电发展尤为迅猛。截至 2024 年底，河南可再生能源发电装机由 2019 年年底的2 256万 kW，增长至7 562万 kW，占电源总装机的比重达到 51.5%，其中光伏占比 57.2%，风电占比 30.1%，水电占比 7.1%，光伏发电是河南省可再生能源的重要组成部分。同时考虑数据的可获取性，选取河南省 2019—2024 年太阳能发电量的数据，见表 6。

绘制河南省 2019—2024 年太阳能发电量的折线图[图 4(a)]来更直观地展现其发展规律。

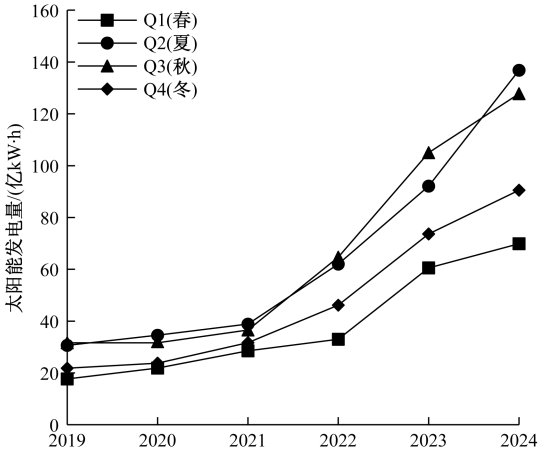
从图 4(a)可知，河南省太阳能发电量虽有明显的上升趋势，但光伏发电的季节差异相当大，呈现季节振动趋势。如果以季度作为划分数据的标准，则原始数据可以分成 4 组数据，如图 4(b)所示。由图 4(b)可知，每个季度的数据呈现稳定的上升趋势，没有出现振荡的情形。通过分析增长率可知，这

**表 6　河南省 2019—2024 年太阳能发电量**

| 年份 | 发电量/(亿 kW·h) | | | |
|---|---|---|---|---|
| | Q1(春) | Q2(夏) | Q3(秋) | Q4(冬) |
| 2019 | 17.67 | 30.62 | 31.64 | 21.83 |
| 2020 | 21.87 | 34.55 | 32.06 | 23.76 |
| 2021 | 28.56 | 38.85 | 36.58 | 31.68 |
| 2022 | 33.00 | 62.02 | 64.70 | 46.14 |
| 2023 | 60.52 | 92.09 | 105.01 | 73.64 |
| 2024 | 69.87 | 136.82 | 127.78 | 90.55 |




(a) 2019—2024年太阳能发电量及增长率




(b) 太阳能发电量分组数据

**图 4　2019—2024 年河南省太阳能发电量及分组数据、增长率**

4 组数据呈现前期增长较慢、后期增长较快的特征，因此采用文献[22]中的平均弱化缓冲算子分别作用于 4 个原始季度数据序列，再构建 GM(1,1)模型(模型 1)。为了便于进行对比，选取 2019—2023 年作为模拟序列，2024 年作为预测序列，并与以原始数据直接建立的 GM(1,1)模型(模型 2)的结果进行对比，结果见表 7。

由表 7 可知，模型 1 的性能明显优于模型 2，由此说明通过观察原始序列呈现的特征对数据分组后先进行弱化再运用 GM(1,1)模型进行预测，显著提高了数据预测的性能。该预测模型是从数据序列的变动趋势角度出发，通过观察原始数据序列呈现的序列特征和发展变动趋势按季节将原始数据序

**表 7　河南省太阳能发电在不同模型下的性能评估结果**

| 模型 | MAE/(亿 kW·h) | RMSE/(亿 kW·h) | MAPE/% | MASPE/% | MAFPE/% |
|---|---|---|---|---|---|
| 模型 1 | 2.691 3 | 6.716 7 | 3.001 5 | 2.021 6 | 6.920 9 |
| 模型 2 | 12.430 8 | 15.450 9 | 21.883 6 | 20.907 7 | 26.518 8 |

列分组,再结合缓冲算子和 GM(1,1)模型进行预测。该思路易于理解,操作简单,模型性能优良。

## 4　结论

针对运用传统 GM(1,1)模型处理振荡序列时预测和模拟效果不佳,部分相关改进模型多是数据导向型建模无法反映系统发展的趋势,且改进模型计算复杂度高、晦涩难懂、数据需求大、泛化能力弱等问题,从数据序列特征的角度提出一种振荡序列灰色预测方法。主要研究结论体现在如下 3 个方面。

(1)观察分析振荡序列的序列特征和发展趋势,根据序列曲线的变动趋势将数据序列进行分组,结合数据序列的发展特征运用平均弱化缓冲算子对数据进行弱化,再利用 GM(1,1)模型进行模拟和预测。案例分析结果显示该方法显著提高了模型的预测和模拟性能。

(2)针对传统 GM(1,1)模型的建模机理适用于少数据的特征,观察分析振荡序列的序列特征和发展趋势,截取部分近期数据序列,结合数据序列的发展特征运用平均弱化缓冲算子对数据进行弱化,再利用 GM(1,1)模型进行模拟和预测。案例分析结果显示该方法显著提高了模型的预测和模拟性能。

(3)针对振荡序列具有的季节性特征,利用 DGGM(1,1)模型的思想,将序列按季节进行分类,根据数据序列特征对不同序列作用于平均弱化缓冲算子,再利用 GM(1,1)模型进行模拟和预测。案例分析结果显示,该方法显著提高了模型的预测和模拟性能。

综上所述,从根据数据序列特征将数据分组、截取部分近期数据序列、利用季节特性将数据分组 3 个角度,结合缓冲算子对振荡序列运用 GM(1,1)模型进行预测,显著提高了模型的性能,并且提高了 GM(1,1)模型的泛化能力,且该方法简单易于操作。将本文的方法应用于河南省太阳能发电量的预测中,证明了该方法的有效性。

## 参考文献


[1] 曾亮. 基于振荡序列的灰色 GM(1,1|sin)幂模型及其应用[J]. 浙江大学学报(理学版), 2019, 46(6): 697-704.

[2] 王正新. 振荡型 GM(1, 1)幂模型及其应用[J]. 控制与决策, 2013, 28(10): 1459-1464.

[3] LIU H C, CAI C L, LI P Y, et al. Hybrid prediction method for solar photovoltaic power generation using normal cloud parrot optimization algorithm integrated with extreme learning machine[J]. Scientific Reports, 2025, 15(1): 6491.

[4] 曾祥艳, 王旻燕, 何芳丽, 等. 基于 GM(0,N)模型的三元区间数序列预测[J]. 控制与决策, 2020, 35(9): 2269-2276.

[5] 李晔, 刘冬玉, 刘盼, 等. 一种新的振荡型 DGPM(1,$N$|sin)模型及其应用[J]. 数学的实践与认识, 2024, 54(1): 164-171.

[6] YIN M S. Fifteen years of grey system theory research: a historical review and bibliometric analysis[J]. Expert Systems with Applications, 2013, 40: 2767-2775.

[7] WANG J, YAN R, HOLLISTER K, et al. A historic review of management science research in China[J]. Omega, 2008, 36: 919-932.

[8] 刘震, 谢玉梅, 党耀国. 基于改进 GM(1, 1)模型的中国脱贫攻坚进展分析[J]. 系统工程理论与实践, 2019, 39(10): 2476-2486.

[9] 周伟杰, 姜慧敏, 党耀国. 基于动态局部累加生成的灰色预测建模及应用[J]. 系统工程理论与实践, 2023, 43(11): 3353-3367.

[10] XIONG X, HU X, GUO H. A hybrid optimized grey seasonal variation index model improved by whale optimization algorithm for forecasting the residential electricity consumption[J]. Energy, 2021, 234: 121127.

[11] TIEN T L. A research on the grey prediction model GM(1, $n$)[J]. Applied Mathematics and Computation, 2012, 218(9): 4903-4916.

[12] 白雪, 任洪涛, 刘冬玉, 等. 振荡型 GM(1,1,$k$)幂模型的构建及其应用[J]. 系统工程, 2023, 41(4): 137-144.

[13] DANG Y G, ZHANG Y F, WANG J J. A novel multivariate grey model for forecasting periodic oscillation time series[J]. Expert Systems with Application, 2022, 211: 118556.

[14] 钱吴永, 党耀国. 基于振荡序列的 GM(1, 1)模型[J]. 系统工程理论与实践, 2009, 29(3): 149-154.

[15] 李翀, 谢秀萍. 基于反正切函数权值累加生成的 DGM$(1,1)_{atan}$模型及其应用[J]. 系统工程理论与实践, 2017, 37(12): 3227-3234.

[16] 曾波, 尹凤凤, 余乐安, 等. 基于幂指数的智能缓冲算子及其应用研究[J]. 管理科学学报, 2024, 27(10): 68-87.

[17] ZHOU W J, JIANG H M, CHENG Y K, et al. Predicting seasonal patterns of energy production: a grey seasonal trend least squares support vector machine[J]. Expert Systems with Applications, 2023, 213: 118874.

[18] DING S, WANG Y, SHEN X G. Forecasts and analysis of economic outputs for chinese high-tech industries: insights from spatial-temporal information fusion[J]. Computational Economics, 2025, 66(6): 5207-5255.

[19] QIAN W Y, WANG J. An improved seasonal GM(1,1) model based on the HP filter for forecasting wind power generation in China[J]. Energy, 2020, 209: 118499.

[20] WANG Z X, LI Q, PEI L L. Grey forecasting method of quarterly hydropower production in China based on a data grouping approach [J]. Applied Mathematical Modelling, 2017, 51: 302-316.

[21] 杨爽艺. 灰色振荡预测建模技术及其应用[D]. 重庆: 重庆工商大学, 2023.

[22] 刘思峰. 灰色系统理论及其应用[M]. 北京: 科学出版社, 2024.

# GM(1,1) Prediction for Oscillatory Sequences Based on Data Sequence Characteristics and Its Application

WANG Xia, YE Qiutong

(School of Business Administration, Henan University of Economics and Law, Zhengzhou 450046, China)

**Abstract**: To address the issues of low prediction accuracy when traditional GM(1,1) models handle oscillatory sequences, as well as problems such as high computational complexity, large data requirements, and weak generalization capabilities in some improved models, a grey prediction method for oscillatory sequences was proposed from the perspective of data sequence characteristics. By observing and analyzing the sequence characteristics and development trends of oscillatory sequences, the data was approached from three angles: subgrouping data based on sequence characteristics, truncating recent partial data sequences, and grouping data using seasonal features. Subsequently, a novel GM(1,1) model was constructed by integrating data sequence characteristics with the average weakening buffer operator. Through empirical analysis of multiple cases, it is verified that the proposed method significantly outperforms the traditional GM(1,1) model and some improved models in prediction performance. It also enhances the generalization ability of the GM(1,1) model while remaining simple and easy to implement. The method is applied to predict solar power generation in Henan Province, once again confirming its effectiveness.

**Keywords**: oscillatory sequence; data sequence characteristics; GM(1,1) model; buffer operator