

DOI:10.16799/j.cnki.csdqyfh.2023.09.071

# 装配式预制构件市场信息价动态测算模型研究

李立岩<sup>1</sup>,汪小南<sup>2,3</sup>

(1.武汉市市政建设集团有限公司,湖北 武汉 430023; 2.武汉市城市建设投资开发集团有限公司,湖北 武汉 430000;  
3.武汉市市政工程设计研究院有限责任公司,湖北 武汉 430023)

**摘要:** 预制构件市场价格是装配式建筑总成本的关键组成部分,建设行政管理部门需要通过及时发布市场信息价来引导和规范预制构件市场。为克服信息价发布存在的时滞性,实现精细化、及时性管理,提出预制构件市场信息价的及时动态测算方法,通过构建马尔科夫优化后的 SCGM(1,1)<sub>c</sub> 预测模型实现对信息价周期内主要波动项人材机费用的预测,再将其代入信息价测算模型中实现市场信息价的动态测算。以 W 市预制外墙板市场信息价为例进行实证分析,结果表明:基于马尔科夫 SCGM(1,1)<sub>c</sub> 预测模型能够很好地满足预制构件市场信息价提前预测的需求,MAPE 值为 0.81%,相比于其他 3 种常用的价格预测方法,具有更强的适应性和稳定性。

**关键词:** 预制构件;市场信息价;动态测算;SCGM(1,1)<sub>c</sub> 预测模型

**中图分类号:** TU990.0

**文献标志码:** B

**文章编号:** 1009-7716(2023)09-0300-07

## 0 引言

随着装配式建筑在我国的大力推行,预制构件使用量呈现上涨趋势,其生产成本是装配式建筑增量成本的主要增项<sup>[1]</sup>。为控制装配式建筑成本及满足市场定价的需求,各地建设行政主管部门先后建立了预制构件市场信息价发布机制。然而,当前预制构件信息价发布机制存在更新滞后、时效性差等问题,对预制构件市场的指导性作用较小,且滞后于现实需要。市场信息价作为规范预制构件市场、投标报价的主要依据,其准确性具有重要的现实意义。因此,亟须展开对预制构件市场信息价的及时动态测算方法研究来指导预制构件市场。

国内外学者对具有时间序列特征的价格预测问题进行了较为深入的研究,其选用的模型方法主要分为回归模型、神经网络模型、SVM 模型及灰色预测模型。Shanoli Samui Pal<sup>[2]</sup>、Mehmet Kabak 等<sup>[3-4]</sup>分别利用回归模型、神经网络对市场价格进行短期预测。这两种方法虽然具有较高的预测精度,但均需要大量的历史经验数据。而针对小样本数据的预测问题,一些学者<sup>[3,5-6]</sup>分别利用改进后的 SVM 模型进行市场参考价格的预测,展现了 SVM 算法在小样本数据学习上的优越性,但预测模型的稳定性取决于核函数的选取。不依赖于样本数据具有大量性、呈规律

性分布特征的 SCGM(1,1)<sub>c</sub> 预测模型展现了在时序数据预测上的特有优势,有学者<sup>[7-9]</sup>利用马尔科夫链、残差修正等方法进一步优化 SCGM(1,1)<sub>c</sub> 预测模型,不仅提升了 SCGM(1,1)<sub>c</sub> 预测模型的预测精度,同时改善了数据少、随机波动对预测精度的影响程度。相较于 SCGM(1,1)<sub>c</sub> 预测模型,SVM 模型结构的复杂性决定了其对数据量的要求会更高,因此优化后的 SCGM(1,1)<sub>c</sub> 预测模型更加适用于数据量少且存在随机波动的预测工作。

而目前,各地建设行政主管部门关于预制构件的相关技术标准、管理体系还有待完善,市场信息价发布机制也处于初步建立阶段,预制构件市场信息价及相关生产费用整体呈现出数据量偏少、随机波动,以及变化受众多因素影响等特征,适合与 SCGM(1,1)<sub>c</sub> 预测模型方法结合开展研究。

鉴于此,本文拟选用 SCGM(1,1)<sub>c</sub> 预测模型对预制构件市场信息价进行预测,并利用马尔科夫链来优化改善数据随机波动对模型预测精度的影响,实现预制构件市场信息价的及时、动态测算。同时,与另外 3 种常用的预测模型方法对比来验证本文模型的优势,为主管部门实现规范引导预制构件市场价格精细化管理提供技术支撑,并为类似预测工作提供参考。

## 1 预制构件市场信息价动态测算模型方法

预制构件市场信息价(MIP)代表地区当前的市场平均价格水平,主要选取市场上具有代表性的预制

收稿日期:2023-04-27

作者简介:李立岩(1973—),女,本科,高级工程师,主要从事工程造价管理、经济分析工作。

构件生产企业的实际费用数据作为参考标准进行制定,由人工费( $L_c$ )、材料费( $M_c$ )、机械费( $M_f$ )、折旧及摊销( $D_a$ )、深化设计费( $D_f$ )、运输费( $T_f$ )、管理费、利润、税金组成。其中,人工费、材料费、机械费占比较大,是预制构件生产价格变化的主因<sup>[10]</sup>。通过市场调研和相关人员访谈,在以月为时间跨度的周期内,预制构件市场信息价的波动主要为人工费、材料费、机械费(合称直接费)的变化,折旧及摊销、深化设计费、运输费等在周期内基本无变化。

实现预制构件市场信息价的及时动态测算,需对周期内主要波动项数据的变化趋势加以预测,并对非波动项数据进行周期测定。测算思路如下:

第一步:从预制构件综合单价构成体系出发,建立预制构件市场信息价动态测算模型,如式(1)所示。

$$MIP=[(L_{c(t)}+M_{c(t)}+M_{f(t)})\times(1+i_{c1}+i_{c2})+D_a+D_f+T_f]\times(1+i_{c3}) \quad (1)$$

式中: $t$ 表示月份; $i_{c1}$ 表示管理费的费率; $i_{c2}$ 表示利润的费率; $i_{c3}$ 表示税金的税率。其中,管理费、利润取直接费的一定费率,税金在综合单价所有组成项的基础上取一定费率得到。

第二步:通过建立马尔科夫优化后的SCGM(1,1)<sub>c</sub>预测模型实现对主要波动项的预测,得到第 $t$ 月份人工费预测值 $L_{c(t)}$ 、材料费预测值 $M_{c(t)}$ 、机械费预测值 $M_{f(t)}$ 。

第三步:将主要波动项的预测值代入到式(1)中,结合对非波动项数据的周期测算,即可提前预测出第 $t$ 月份的预制构件市场信息价。待收集到各预制部件生产企业反馈的第 $t$ 月份的实际数据,即可实现第 $t+1$ 月份预制构件市场信息价的预测。如此进行,从而实现预制构件市场信息价的及时动态测算。

## 2 预测模型构建

### 2.1 建立SCGM(1,1)<sub>c</sub>预测模型

系统云灰色模型SCGM(1,1)<sub>c</sub>起源于灰色模型GM(1,1),主要针对“部分信息已知,部分信息未知”的“小样本”“贫信息”为特征的研究对象,通过系列数学运算使其成为具有指数变化规律的数列。为改善GM(1,1)模型在复杂情形下的适用性,系统云(System Cloud)凭借其在面临不确定性、多因子错综复杂行为预测上的优势,两者结合的SCGM(1,1)<sub>c</sub>预测模型在处理数据量少、波动明显、情形复杂的预

测工作中得到了大量使用,能最大限度的从自身寻找数据序列中的有用信息,探索内在规律。

面临预制构件市场信息价相关数据偏少且存在随机波动的实际状况,构建主要波动项的SCGM(1,1)<sub>c</sub>预测模型,操作过程如下:

(1)选取2022年1—11月份的人材机费用分别作为模型的原始时间序列矩阵 $X^0$ ,其中:

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

式中: $x^{(0)}(n)$ 代表第 $n$ 个月的人工费、材料费、机械费数据。对原始序列进行相应处理得到均值序列 $\bar{x}^{(0)}(k)$ [见式(2)]和积分生成序列 $\bar{x}^{(1)}(k)$ [见式(3)],其中 $k=2,3,\dots,n$ 。

$$\bar{x}^{(0)}(k)=\frac{x^0(k)+x^0(k-1)}{2} \quad (2)$$

$$\bar{x}^{(1)}(k)=\sum_{i=1}^k \bar{x}^{(0)}(i) \quad (3)$$

(2)SCGM(1,1)<sub>c</sub>预测模型如式(4)所示。

$$\frac{\partial x^{(1)}(k)}{k}=ax^{(1)}(k)+U \quad (4)$$

式中: $a$ 、 $U$ 为参数。

于是,其一次响应函数为:

$$\hat{x}^{(1)}(k)=\left[\hat{x}^{(1)}(1)+\frac{U}{a}\right]e^{ak}-\frac{U}{a} \quad (5)$$

式中: $\hat{x}^{(1)}(1)=b-c$ ,参数 $a$ 、 $b$ 、 $c$ 计算公式见式(6)~式(8)。

$$a=\ln\frac{\sum_{k=3}^n \bar{x}^{(0)}(k-1)\bar{x}^{(0)}(k)}{\sum_{k=3}^n [\bar{x}^{(0)}(k-1)]^2} \quad (6)$$

$$b=\frac{(n-1)\sum_{k=2}^n e^{a(k-1)}\bar{x}^{(1)}(k)-\left[\sum_{k=2}^n e^{a(k-1)}\right]\left[\sum_{k=2}^n \bar{x}^{(1)}(k)\right]}{(n-1)\sum_{k=2}^n e^{2a(k-1)}-\left[\sum_{k=2}^n e^{a(k-1)}\right]^2} \quad (7)$$

$$c=\frac{1}{n-1}\left[\left(\sum_{k=2}^n e^{a(k)}\right)b-\sum_{k=2}^n \bar{x}^{(1)}(k)\right] \quad (8)$$

(3)对 $\hat{x}^{(1)}(k)$ 进行还原处理,得到拟合值 $\hat{x}^{(0)}(k)$ ,具体见式(9)。

$$\hat{x}^{(0)}(k)=\frac{2b(1-e^{-a})}{1+e^{-a}}e^{a(k-1)} \quad (9)$$

式中: $\hat{x}^{(0)}(k)$ 为人材机费用数据的拟合值。

### 2.2 建立马尔科夫优化后的SCGM(1,1)<sub>c</sub>预测模型

马尔科夫链是研究某一事件的状态及状态之间转移规律的随机过程理论<sup>[11]</sup>。它通过对某一时刻不同状态的初始概率及状态之间的转移概率关系,来研究未来时刻状态的变化趋势,适用于存在随机波动的数据预测工作。

利用马尔科夫优化SCGM(1,1)<sub>c</sub>预测模型的流

程如图 1 所示。

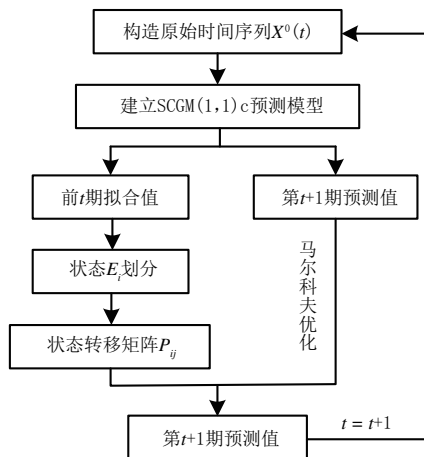


图 1 马尔科夫优化 SCGM(1,1)c 预测模型流程

具体操作步骤如下:

(1)状态划分。预制构件市场价格中人材机费用的变动没有明显的规律,灰精度指标  $Y(k)$ 也是随机的,计算公式见式(10)。将拟合精度划分为  $m$  个状态,则可将任一状态  $E_i$  表示为如式(11)所示。

$$Y(k) = \frac{x^{(0)}(k)}{\hat{x}^{(0)}(k)} \times 100\% \quad (10)$$

$$E_i = [\otimes_{1i}, \otimes_{2i}] \quad (11)$$

式中: $\otimes_{1i}$ 、 $\otimes_{2i}$  分别表示状态  $E_i$  的上下限,其中, $\otimes_{1i} = Y(k) + A_i$ ,  $\otimes_{2i} = Y(k) + B_i$ ,  $i \in (1, \dots, m)$ ,  $A_i$  和  $B_i$  为根据待预测数据而定的常数。

(2)构建状态转移矩阵  $p(k)$ 。因为人材机费用预测存在诸多不确定性,对未来较长时间进行预测误差较大,所以一般仅考虑一步转移矩阵,状态转移矩阵  $p(k)$  如下所示。

$$p(k) = \begin{bmatrix} p_{11}(k) & p_{12}(k) & \dots & p_{1m}(k) \\ p_{21}(k) & p_{22}(k) & \dots & p_{2m}(k) \\ \vdots & \vdots & & \vdots \\ p_{m1}(k) & p_{m2}(k) & \dots & p_{mm}(k) \end{bmatrix}$$

式中: $p(k)$  表示转移  $k$  步的状态转移矩阵; $p_{ij}(k)$  表示经  $k$  步由状态  $i$  转移到状态  $j$  的概率,计算公式如式(12)所示。 $M_i$  为状态  $E_i$  出现的次数; $M_{ij}(k)$  为状态  $E_i$  转移到  $E_j$  的样本数。

$$p_{ij}(k) = \frac{M_{ij}(k)}{M_i}, \quad i, j = 1, 2, \dots, m. \quad (12)$$

(3)基于马尔科夫状态转移矩阵对人材机费用预测值进行修正,计算如式(13)所示。

$$\hat{x}_{mp}^{(0)}(k) = \hat{x}_p^{(0)}(k) \times \frac{(\otimes_{1i}, \otimes_{2i})}{2} \quad (13)$$

式中: $\hat{x}_{mp}^{(0)}(k)$  表示经过马尔科夫修正后得到的人材机费用预测值。

### 3 实证分析

#### 3.1 预测分析

选取 W 市的预制构件市场作为实际案例进行分析,由于 W 市预制构件市场信息价均于每月末发布当月信息指导价,难以对当月的市场经济活动提供有效指导,存在严重的时滞性问题。

本文实例利用 2022 年 1—11 月份的预制构件市场信息价和各项经济指标数据,数据的主要来源为实地调研的 10 家大型预制构件生产企业和建设工程标准定额管理站官方网站发布的建设工程价格信息文件。出于对预制构件造价管理精细化的要求,对预制构件应分构件类型进行市场信息价的管理工作。于是,选用最常用的预制外墙板进行市场信息价的及时动态测算演示,其他类型的预制构件可参照进行。

数据采集工作分为 3 个部分:

第一部分为随时间周期变化波动明显的人材机费用数据。经整理汇总得到 2022 年 1 月至 2022 年 11 月预制外墙板人材机费用(见表 1)。

表 1 预制外墙板人材机费用汇总 单位:元/m<sup>3</sup>

时间	人工费	材料费	机械费
2022.01	473.32	1 561.44	91.82
2022.02	469.37	1 547.42	91.27
2022.03	465.46	1 576.90	90.73
2022.04	493.13	1 610.39	90.18
2022.05	522.45	1 614.28	89.65
2022.06	553.50	1 600.99	89.11
2022.07	564.28	1 617.07	89.74
2022.08	575.26	1 587.59	90.36
2022.09	586.45	1 601.30	87.53
2022.10	608.60	1 598.81	87.96
2022.11	631.59	1 632.18	86.49

第二部分为随时间周期波动较小,但从较长周期来看会发生变化的折旧及摊销、深化设计费、运输费。经过对 W 市装配式预制构件市场调研可知,预制构件综合单价中的折旧及摊销、深化设计费、运输费在以月为时间跨度的周期内保持不变,但长期会随着达产率、标准化程度等而发生变化。

经合理测算,2022 年 W 市的预制构件折旧及摊销费平均水平为 292.40 元/m<sup>3</sup>,深化设计费平均水平为 98.04 元/m<sup>3</sup>,30 km 以内运费平均水平为 132.74 元/m<sup>3</sup>。

第三部分为在较长周期内无变化的管理费、利润及税金,与现行预制构件市场费率保持一致即可。

将表 1 中的数据按人材机分类分别代入到原始时间序列  $X^0$  中,借助 MATLAB2014a 进行计算,得到人工费的模型拟合系数  $a_1=0.0307, b_1=15040.3654$ 。于是,人工费的 SCGM(1,1)<sub>c</sub> 预测模型如式(14)所示。

$$\hat{x}_1^{(0)}(k)=461.8950 e^{0.0307(k-1)} \quad (14)$$

同理,得到材料费的模型拟合系数  $a_2=0.0042, b_2=37361.2332$ ,材料费的 SCGM(1,1)<sub>c</sub> 预测模型如式(15)所示。

$$\hat{x}_2^{(0)}(k)=1565.2591 e^{0.0042(k-1)} \quad (15)$$

于是,机械费的模型拟合系数  $a_3=-0.0054, b_3=-1718.0140$ ,机械费的 SCGM(1,1)<sub>c</sub> 预测模型如式(16)所示。

$$\hat{x}_3^{(0)}(k)=92.0804 e^{-0.0054(k-1)} \quad (16)$$

最后,利用式(17)表示 SCGM(1,1)<sub>c</sub> 预测模型的拟合效果。

$$\delta_k = \frac{[\hat{x}^{(0)}(k) - x^0(k)]}{x^0(k)} \times 100\% \quad (17)$$

式中: $\delta_k$  表示第  $k$  个月的拟合误差。

结合式(14)、式(15)、式(16)可计算得到 2022 年 1 月~11 月份的人材机拟合值,利用式(17)得到人工费的平均相对误差为 1.6556%,材料费的平均相对误差为 0.9152%,机械费的平均相对误差为 0.6448%,拟合效果如图 2 所示。同时,得到 2022 年 12 月份的人工费  $L_c(12)$ 、材料费  $M_c(12)$ 、机械费  $M_f(12)$  预测值,其拟合精度及拟合误差详见表 2。




图 2 2022 年 1—11 月人材机费用拟合误差图

表 2 预制外墙板人材机预测结果

时间	人工费			材料费			机械费		
	预测值 / (元·m <sup>-3</sup> )	$Y(k)/\%$	$\delta_k / \%$	预测值 / (元·m <sup>-3</sup> )	$Y(k)/\%$	$\delta_k / \%$	预测值 / (元·m <sup>-3</sup> )	$Y(k)/\%$	$\delta_k / \%$
2022.01	461.90	102.47	2.4140	1565.26	99.76	0.2446	92.08	99.71	0.2865
2022.02	476.30	98.55	1.4761	1571.83	98.45	1.5778	91.59	99.65	0.3489
2022.03	491.16	94.77	5.5213	1578.43	99.90	0.0970	91.10	99.59	0.4114
2022.04	506.48	97.36	2.7065	1585.06	101.60	1.5729	90.61	99.53	0.4739
2022.05	522.27	100.03	0.0332	1591.71	101.42	1.3978	90.13	99.47	0.5365
2022.06	538.56	102.77	2.6998	1598.39	100.16	0.1623	89.65	99.40	0.5991
2022.07	555.36	101.61	1.5802	1605.10	100.75	0.7400	89.17	100.64	0.6342
2022.08	572.68	100.45	0.4476	1611.84	98.50	1.5275	88.69	101.89	1.8524
2022.09	590.54	99.31	0.6979	1618.61	98.93	1.0811	88.22	99.22	0.7871
2022.10	608.96	99.94	0.0589	1625.41	98.36	1.6634	87.74	100.25	0.2504
2022.11	627.95	100.58	0.5761	1632.23	100.00	0.0032	87.28	99.10	0.9126
2022.12	647.54	—	—	1639.08	—	—	86.81	—	—

由图 2 可知,人工费的拟合误差波动幅度较之于材料费、机械费处于较大水平,材料费次之,机械费的误差波动最小。

由于人工费、材料费、机械费的绝对值相差较大,且各自的数据变化规律、影响因素均存在较大区别,因此在利用马尔可夫优化 SCGM(1,1)<sub>c</sub> 预测模型时,应采用不同的状态划分。

根据表 2 中的拟合精度  $Y(k)$  的结果,采用最优

$K$  分法<sup>[12]</sup>将状态划分为为 4 个状态[E1, E2, E3, E4],划分区间详见表 3。

表 3 状态划分

状态	人工费	材料费	机械费
E1	94%~98%	96.5%~98.5%	98%~99.5%
E2	98.5%~99.5%	98.5%~100%	99.5%~100%
E3	99.5%~100.5%	100%~101.5%	100%~100.5%
E4	100.5%~103%	101.5~103%	100.5%~102%

结合表 2 中的拟合精度和表 3 中的状态划分,绘制人工费的状态转移具体情形如图 3 所示。




图 3 人工费状态转移图

结合图 3 中各状态的转移情形,再根据式(12)可以计算出人工费的状态转移矩阵  $P_1(1)$ ,具体如下:

$$P_1(1) = \begin{bmatrix} 1/2 & 0 & 1/2 & 0 \\ 1/2 & 0 & 1/2 & 0 \\ 0 & 1/3 & 0 & 2/3 \\ 0 & 1/4 & 1/4 & 1/2 \end{bmatrix}$$

由表 2 知,2022 年 11 月份人工费的拟合精度为 100.58%,处于 E4 状态。根据其状态转移矩阵  $P_1(1)$  可知,12 月份的人工费状态最有可能向 E4 转移。所以,根据式(13)得到经马尔科夫优化后的人工费预测值为:

$$\hat{x}_{mp}^{(0)}(12) = 647.54 \times \left[ \frac{1}{2} \times (100.5\% + 103\%) \right] = 658.87 \text{ 元/m}^3$$

同理,可绘制出材料费的状态转移图,进而得到材料费的一步状态转移矩阵为  $P_2(1)$ 。

$$P_2(1) = \begin{bmatrix} 0 & 2/3 & 1/3 & 0 \\ 2/3 & 0 & 0 & 1/3 \\ 1/4 & 0 & 3/4 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

由表 2 知,2022 年 11 月份材料费的拟合精度为 100.00%,处于 E2 状态。根据状态转移矩阵  $P_2(1)$  可知,12 月份的材料费状态最有可能转向 E1 状态,于是经马尔科夫优化后的材料费预测值为 1 598.10 元/m<sup>3</sup>。

同理,机械费的一步状态转移矩阵为  $P_3(1)$ ,具体如下:

$$P_3(1) = \begin{bmatrix} 1/2 & 0 & 1/4 & 1/4 \\ 1/4 & 3/4 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 1/2 & 0 & 0 & 1/2 \end{bmatrix}$$

2022 年 11 月份的拟合精度处于 E1 状态,故 12 月份最有可能转向 E1 状态,于是 12 月份的机械费

预测值为 85.71 元/m<sup>3</sup>。

于是,根据 2022 年 12 月份的人材机的预测值、折旧及摊销、深化设计费、运输费的测定值,测算 2022 年 12 月的预制外墙板市场信息价为 3 834.05 元/m<sup>3</sup>。

基于等维选取数据的思路,选取 2022 年 2—12 月份的人材机数据作为原始时间序列代入到马尔科夫优化后的 SCGM(1,1)<sub>c</sub> 预测模型中,得到 2023 年 1 月份市场信息价为 3 876.03 元/m<sup>3</sup>。依次进行,得到 2023 年 2—4 月份的信息价预测值,预测结果分析详见表 4。

表 4 预制外墙板市场信息价预测

时间	实际值 / (元·m <sup>-3</sup> )	预测值 / (元·m <sup>-3</sup> )			
		优化前	$\delta_k / \%$	优化后	$\delta_k / \%$
2022.12	3 836.00	3 876.61	1.06	3 834.05	0.05
2023.01	3 816.00	3 892.24	2.00	3 876.03	1.57
2023.02	3 796.00	3 854.26	1.53	3 824.12	0.74
2023.03	3 801.00	3 837.91	0.97	3 821.45	0.54
2023.04	3 781.00	3 849.04	1.80	3 825.02	1.16

由表 4 可知,SCGM(1,1)<sub>c</sub> 预测模型的平均误差为 1.47%;经马尔科夫优化后,预测值的平均误差下降至 0.81%,表明该模型能够有效地为预制构件市场信息价提供预测支持。

### 3.2 预测模型验证

运用 W 市 2022—2023 年间预制外墙板的市场信息价数据,并选取多元线性回归模型、BP 神经网络模型和 SVM 模型进行对比,以体现本文模型优越性。

其中,多元线性回归模型结构、操作步骤较为简单,主要是利用人材机数据进行多元函数的拟合,在拟合优度达到预期后即可输出预测结果;BP 神经网络模型和 SVM 模型内部结构较为复杂,借鉴陈伟<sup>[13]</sup>在钢材价格预测中使用的滚动预测方法,将模型输入、输出项设置为表 5 中数据,并对模型初始化参数进行优化调整,使得预测模型的输出值与实际值误差更小,满足精度要求。

表 5 BP 神经网络和 SVM 模型输入、输出项

输入值	输出值	输入值	输出值
$x^0(1), x^0(2)$	$x^0(3)$	$x^0(6), x^0(7)$	$x^0(8)$
$x^0(2), x^0(3)$	$x^0(4)$	$x^0(7), x^0(8)$	$x^0(9)$
$x^0(3), x^0(4)$	$x^0(5)$	$x^0(8), x^0(9)$	$x^0(10)$
$x^0(4), x^0(5)$	$x^0(6)$	$x^0(9), x^0(10)$	$x^0(11)$
$x^0(5), x^0(6)$	$x^0(7)$	$x^0(10), x^0(11)$	$x^0(12)$

根据表 5 中的数据选取规则,可形成模型训练所需的数据集,然后进行模型的训练及测试。待模型训练完成且精度符合要求之后,输入 2022 年 10 月份、11 月份的预制外墙板的人材机费用数据  $x^0(10)$ 、 $x^0(11)$ ,即可输出 12 月份的预测值  $x^0(12)$ 。再将其代入到市场信息价动态测算模型中,得到预制外墙板 12 月份的市场信息价预测值。以此类推,即可实现后续预测工作。

于是,根据以上预测思路得到 4 种模型的运行对比结果(见表 6)。

表 6 预制外墙板市场信息价预测模型对比

时间	实际值 $I$ (元·m <sup>-3</sup> )	预测值 $I$ (元·m <sup>-3</sup> )			
		马尔科夫 SCGM(1,1) <sub>c</sub> 预测模型	多元线性回归模型	BP 神经网络模型	SA-LSSVM 模型
2022.12	3 836.00	3 834.05	4 002.43	3 762.56	3 754.60
2023.01	3 816.00	3 876.03	4 437.93	3 698.43	3 718.00
2023.02	3 796.00	3 824.12	3 958.47	3 734.02	3 836.54
2023.03	3 801.00	3 821.45	3 896.22	3 749.38	3 869.32
2023.04	3 781.00	3 805.02	3 871.63	3 855.61	3 821.19
检验指标	MAPE	0.81%	5.96%	1.99%	1.72%
	RMSE	32.84	302.71	79.11	69.51

由表 6 各数据指标可知,针对样本个数较少的时间序列数据,马尔科夫优化后的 SCGM(1,1)<sub>c</sub> 预测模型整体表现出了很好的预测效果,可以很好地实现预制构件市场信息价的预测工作;适用于小样本数据预测的优化后的 SVM 模型也表现出了较好的预测性能,但 RMSE 值过大,表明预测稳定性差;依赖于大数据的神经网络的 MAPE 值与 SVM 模型较为接近,但稳定性依然较差;多元线性回归模型拟合效果最差,且预测数据与实际数据之间的离散程度高,不适宜用于小样本数据的预测工作。

### 4 结 语

针对我国目前预制构件市场信息价发布机制建立初期的现状,利用马尔科夫优化后的 SCGM(1,1)<sub>c</sub> 预测模型进行预制构件市场信息价的动态测算模型研究,得到如下结论:

(1)本文建立的预制构件市场信息价动态测算模型方法可有效地解决市场信息价发布滞后的现状,可进一步规范和引导预制构件市场,实现造价管理的精细化。

(2)经实证分析表明,SCGM(1,1)<sub>c</sub> 预测模型更适用于样本数据少、规律性不强且存在随机波动的

表 6 中,MAPE 为平均绝对百分比误差,值越小,表明整体预测效果越好,计算公式如式(18)所示;RMSE 为均方根误差,值越小,表明预测样本数据个体之间拟合性能越好,计算公式如式(19)所示。

$$MAPE = \frac{100\%}{n} \cdot \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (18)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (19)$$

式中: $\hat{y}_i$  表示第  $i$  期市场信息价预测值; $y_i$  表示第  $i$  期市场信息价实际值。

预测工作,经马尔科夫优化后具有较高的预测精度,进一步提升了 SCGM(1,1)<sub>c</sub> 预测模型的适用性和稳定性。

(3)本文提供的预制构件市场信息价的预测思路,可为类似具有时间序列特征的预测工作提供参考。

#### 参考文献:

- [1] 陈伟,江雪,余杨清,等.装配式建筑工程增量成本测算[J].财会月刊,2018(6):75-81.
- [2] S S PAL,S KAR . Forecasting stock market price by using fuzzified Choquet integral based fuzzy measures with genetic algorithm for parameter optimization[J]. RAIRO-Operations Research,2020,54(2): 597-614.
- [3] MEHMET KABAK,TAHA TASDEMIR. Electricity day-ahead market price forecasting by using artificial neural networks: an application for turkey [J]. Arabian Journal for Science and Engineering, 2020,45(3): 2317-2326.
- [4] ZAKARIA ALAMEER, MOHAMED ABD ELAZIZ, AHMED A. E-WEES, et al. Forecasting copper prices using Hybrid adaptive neuro-fuzzy inference system and genetic algorithms [J]. Natural Resources Research,2022,28(4): 1385-1401.
- [5] 刘刚刚,陈铭.基于 BA-SVM 及大数据的物资信息价预测[J].技术经济与管理研究,2017(5):24-28.
- [6] MOJTABA SEDIGHI HOSSEIN JAHANGIRNIA, MOHSEN GHARAKHANI, et al. A Novel Hybrid Model for Stock Price Forecasting Based on Metaheuristics and support vector machine [J]. Data,

