文章编号：1674－9057(2018)02－0301－05　　doi:10.3969/j.issn.1674－9057.2018.02.018

基于卡尔曼滤波的 GM(1,1)－AR 预测模型在变形预测中的应用

容　静[1]，刘立龙[1]，文鸿雁[1]，王清涛[1]，周　吕[1,2,3]

（1. 桂林理工大学 a. 广西空间信息与测绘重点实验室；b. 测绘地理信息学院；c. 广西矿冶与环境科学实验中心，广西 桂林　541004；2. 武汉大学 测绘学院，武汉　430079；3. 东华理工大学 江西省数字国土重点实验室，南昌　330013）

摘　要：针对变形监测数据的随机不确定性规律，将卡尔曼滤波引入以消除随机扰动误差，利用 GM(1,1) 模型能直接处理非平稳时间序列且拟合时间序列中的趋势项功能强大这一优势，将灰色理论与时间序列分析法相结合形成非线性组合模型，对变形监测数据进行分析预测，并将该预测模型用于建筑物变形工程实例进行分析。对模型检验表明：基于卡尔曼滤波的 GM(1,1)－AR 模型的预测结果与其他预测模型相比，平均残差和残差的方差均有所减小，且具备较高的精度，对了解建筑物变形的发展趋势以及研究建筑物变形情况及稳定性具有一定的参考价值。

关键词：GM(1,1)；时间序列分析；卡尔曼滤波；变形预测

中图分类号：P207　　**文献标志码：**A

近年来，根据实测数据提取相关信息并建立合理的监测模型、评价建筑物安全状况是监控建筑物沉降变形与评估其安全性的有效方法。然而，国内外对建筑物安全监测的模型有很多，其中被广泛应用且比较典型的是采用统计模型、确定性模型和混合模型来进行安全性分析和预测。当观测数据序列属于大样本数据且平稳特点比较明显时，采用不同种类的单一数学建模方法一般均可取得相对一致的预测效果[1]。但对于短数据序列，由于信息量欠缺，规律性不明显，使得某些方法(如统计预测法)失去了预测的准确性。

而在实际工作中，由于受到环境和温度等不同程度的复杂因素影响，外业采集到的变形监测数据随机扰动误差很大，基本上属于非平稳时间序列且信息不足、小样本的情况，因此很难对建筑物的实际工作形态进行准确的预测。卡尔曼滤波可以较好地剔除建模数据中的随机扰动误差，使原始监测数据曲线变得平滑，增强了规律性和拟合效果；灰色模型为解决贫信息、小样本的问题提供了新的解决方案；时间序列分析模型具有很好的动态外延特性，能挖掘出数据系统反应的细节信息，保持较高的短期预测精度。本文将以上 3 种模型组合起来，得到基于卡尔曼滤波的 GM(1,1)－AR 预测模型，用该模型对某一边坡的变形预测结果，与 GM(1,1) 模型、灰时序模型的预测结果进行对比分析，验证了该算法模型的可行性。

1　基于卡尔曼滤波 GM(1,1)－AR 预测模型

1.1　灰色系统理论

灰色系统理论旨在研究数据量少、贫信息等的

收稿日期：2016－08－08

基金项目：国家自然科学基金项目（41461089）；广西空间信息与测绘重点实验室项目（桂科能 1638025－26；15－140－07－32）；广西研究生教育创新计划项目（YCSW2017155）；广西“八桂学者”岗位专项经费项目；江西省数字国土重点实验室开放研究基金项目（DLLJ 201711）

作者简介：容　静（1991—），女，硕士研究生，研究方向：变形监测与数据处理，rongjing1123@126.com。

通讯作者：刘立龙，教授，hn_liulilong@163.com。

引文格式：容静，刘立龙，文鸿雁，等. 基于卡尔曼滤波的 GM(1,1)－AR 预测模型在变形预测中的应用［J］. 桂林理工大学学报，2018，38（2）：301－305.

不确定性问题，它通过一定的系统行为特征数据作相应的生成变换，进而找到数据间潜在的变化规律和大致发展情况，建立了灰色模型[2]。GM(1,1)模型的建模过程如下：

设 $x^{(0)}$ 为非负的等间隔离散序列

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

其中，n 为序列长度。

$$x^{(1)} = (x^{(1)}(1), x^{(1)}(2), \cdots, x^{(1)}(n)), \quad (2)$$

记 $x^{(1)} = \mathrm{AGO}x^{(0)}$ 为 $x^{(0)}$ 的一次累加序列

$$\frac{\mathrm{d}x^{(1)}(k)}{\mathrm{d}t} + ax^{(1)}(k) = b。\quad (3)$$

式(3)是GM(1,1)模型的影子方程，也叫做白化方程。白化方程的解为

$$x^{(1)}(t) = \left(x^{(1)}(1) - \frac{b}{a}\right)\mathrm{e}^{-at} + \frac{b}{a}。\quad (4)$$

从式(4)中可求出待定常数 a、b 的值，a 是发展系数，系统整体发展局势的大小靠 a 来控制；b 是灰色作用量，它的大小是数据变化关系的直接反映。根据白化方程，可得出GM(1,1)模型的时间响应序列：

$$\hat{x}^{(1)}(k+1) = \left(x^{(0)}(1) - \frac{b}{a}\right)\mathrm{e}^{-ak} + \frac{b}{a},$$

$$k = 1, 2, \cdots, n; \quad (5)$$

最后，通过累减生成可还原数据，得到GM(1,1)预测模型：

$$\hat{x}^{(0)}(k+1) = (1 - \mathrm{e}^{a})\left(x^{(0)}(1) - \frac{b}{a}\right)\mathrm{e}^{-ak},$$

$$k = 1, 2\cdots, n; \quad (6)$$

最终得到GM(1,1)表达式为

$$\hat{x}^{(0)}(k) = \left(\frac{1 - 0.5a}{1 + 0.5a}\right)^{k-2}\frac{b - ax^{(0)}(1)}{1 + 0.5a}。\quad (7)$$

1.2 时间序列分析模型

时序分析是建立在输出等价的基础上的、对不同时间(或空间)上的实测数据进行相关分析的一种动态数据处理方法，实测数据具有平稳性是能够进行时间序列分析的先决条件[3]。

设 x_t 时间序列是平稳、正态、零均值的，那么可以将它描述为

$$x_t = \varphi_1 x_{t-1} + \varphi_2 x_{t-2} + \cdots + \varphi_p x_{t-p} + a_t, \quad (8)$$

此方程叫做 x_t 的 p 阶自回归模型方程。φ_1，φ_2，φ_3，…，φ_n 是自回归参数；p 表示模型属于几阶，为正整数；$\{a_t\}$ 属于白噪声序列且和前一时刻序列 $x_t(k < t)$ 不相关，当

$$\Omega = E\{(x_t - \hat{x}_t)^2\} = \min, \quad (9)$$

且 $k > p$ 时，有 $\varphi_k = 0$，或者 φ_k 服从渐近正态分布 $N(0, 1/n)$，符合这一条件就称偏自相关函数已经 p 步截尾，即该序列就为AR(p)模型。其中，N 为序列数据总个数；σ^2 为各阶数对应的残差方差；AIC(p)是模型阶次 p(一般小于5)的函数，AIC(p)绝对值最小时 p 为最适合模型阶次。

$$\mathrm{AIC}(p) = N\ln\sigma^2 + 2p。\quad (10)$$

1.3 卡尔曼滤波

卡尔曼滤波法是现代控制理论中用来剔除随机干扰误差的重要方法，有连续性系统和离散线性系统两种。在沉降变形监控中，所监测对象的状态通常是以离散的数据序列来表示，因此本文仅介绍离散线性系统的Kalman滤波[4]。

离散线性系统的Kalman滤波的数学模型包括状态方程和观测方程，分别为

$$\boldsymbol{X}_k = \boldsymbol{F}_{k/k-1}\boldsymbol{X}_{k-1} + \boldsymbol{G}_{k-1}\boldsymbol{W}_{k-1}; \quad (11)$$

$$\boldsymbol{L}_k = \boldsymbol{H}_k\boldsymbol{X}_k + \boldsymbol{V}_k。\quad (12)$$

式中：$\boldsymbol{X}_k$ 为系统 k 时刻的 $n\times1$ 阶状态向量；$\boldsymbol{F}_{k/k-1}$ 为作用在前一状态的 $n\times n$ 阶状态转移矩阵；$\boldsymbol{G}_{k-1}$ 为系统 $k-1$ 时刻的 $n\times r$ 阶动态噪声矩阵；$\boldsymbol{W}_{k-1}$ 为系统 $k-1$ 时刻的 $r\times1$ 阶动态噪声，其协方差矩阵为 $\boldsymbol{Q}_k$(非负定方差矩阵)；$\boldsymbol{L}_k$ 为系统 k 时刻的 $m\times1$ 阶观测向量；$\boldsymbol{H}_k$ 为系统 k 时刻的 $m\times n$ 阶观测矩阵；$\boldsymbol{V}_k$ 为系统 k 时刻的 $m\times1$ 阶观测噪声矩阵，其协方差为 $\boldsymbol{R}_k$(正定方差矩阵)。

根据最小二乘原理，可得到随机离散线性系统的Kalman滤波递推公式如下：

状态向量一步预测值

$$\hat{\boldsymbol{X}}_{k/k-1} = \boldsymbol{F}_{k/k-1}\hat{\boldsymbol{X}}_{k-1}; \quad (13)$$

一步预测方差矩阵

$$\boldsymbol{P}_{k/k-1} = \boldsymbol{F}_{k/k-1}\boldsymbol{P}_{k-1}\boldsymbol{F}^{\mathrm{T}}_{k/k-1} + \boldsymbol{G}_{k-1}\boldsymbol{Q}_{k-1}\boldsymbol{G}^{\mathrm{T}}_{k-1}; \quad (14)$$

状态向量估计值

$$\hat{\boldsymbol{X}}_k = \hat{\boldsymbol{X}}_{k/k-1} + \boldsymbol{J}_k(\boldsymbol{L}_k - \boldsymbol{H}_k\hat{\boldsymbol{X}}_{k/k-1}); \quad (15)$$

状态向量估值的方差阵

$$\boldsymbol{P}_k = (\boldsymbol{I} - \boldsymbol{J}_k\boldsymbol{K}_k)\boldsymbol{P}_{k/k-1}, \quad (16)$$

其中，$\boldsymbol{J}$ 是滤波增益矩阵，表示为

$$\boldsymbol{J} = \boldsymbol{P}_{k/k-1}\boldsymbol{H}^{\mathrm{T}}_k(\boldsymbol{H}_k\boldsymbol{P}_{k/k-1}\boldsymbol{H}^{\mathrm{T}}_k + \boldsymbol{R}_k)^{-1}。\quad (17)$$

在确定Kalman滤波初始值后，可启动卡尔曼滤波递推算法，依据 k 时刻的观测值 $\boldsymbol{L}_k$ 递推计算出对应时刻的状态估计值 $\hat{\boldsymbol{X}}_k$，$(k = 1, 2, 3, \cdots)$，从而

实现滤波与预测,剔除随机噪声的干扰[5-7]。

2 模型的精度检验

本文采用后验差检验法评判模型精度[8]。设原始监测数据方差为 S_1^2,残差数据方差为 S_2^2,$\bar{x}$ 为原始数据的平均值,$\bar{\varepsilon}$ 为平均残差,则后验差比值 C 为

$$C = \sqrt{S_2^2} / \sqrt{S_1^2}; \tag{18}$$

$$S_1^2 = \frac{1}{n}\sum_{k=1}^{n}(x^0(k) - \bar{x})^2; \tag{19}$$

$$S_2^2 = \frac{1}{n}\sum_{k=1}^{n}(\varepsilon(k) - \bar{\varepsilon})^2; \tag{20}$$

其中:$\bar{x} = \frac{1}{n}\sum_{k=1}^{n} x^{(0)}(k)$;$\varepsilon(k) = x^{(0)}(k) - \hat{x}^{(0)}(k)$;$\bar{\varepsilon} = \frac{1}{n}\sum_{k=1}^{n}\varepsilon(k)$。

小误差概率 P 为

$$P = P\{|\varepsilon(k) - \bar{\varepsilon}| < 0.674\ 5S_1\}。 \tag{21}$$

本文采用的 C 和 P 两个指标是后验差检验法中综合评价预测模型精度的唯一标准，具体精度等级如表 1 所示。若 C 和 P 值在等级合格要求以上，即可进行预测，否则需要残差修正，直到满足精度需求为止[9-10]。

表 1　后验差检验法精度等级

Table 1　Precision grade of posterior deviation test

模型精度等级	C	P
一级(好)	<0.35	>0.95
二级(合格)	0.35≤C<0.50	0.80<C≤0.95
三级(勉强合格)	0.50≤C<0.65	0.70<C≤0.80
四级(不合格)	≥0.65	≤0.70

3 算例分析

以文献[8]中某边坡上的其中一个监测点 P4 的竖向原始监测数据(观测间隔为 1 d)为例(表 2)。利用卡尔曼滤波方法对原始监测数据进行处理,估计出测量数据的真实值。其次,根据卡尔曼滤波校正值来建立非线性 GM(1,1) – AR 组合模型。

3.1 卡尔曼滤波去噪

若设系统噪声和观测噪声均为平稳、随机的时间序列，根据经验值可取初始参数值 Q_k、R_k 均为 1。本文考虑观测点位置和其变化速率作为状态参数,初始状态向量及协方差阵由前两期数据的平差值确定

$$\boldsymbol{X}_0 = [63.003\ 3 \quad 0.470\ 0]^{\mathrm{T}},$$

表 2　卡尔曼滤波值与原始监测数据对比

Table 2　Kalman filtering value and monitoring data　mm

监测期数	原始数据	卡尔曼滤波值	滤波残差
1	62.69	62.74	–0.05
2	63.16	63.08	0.08
3	62.83	62.95	–0.12
4	62.39	62.53	–0.14
5	62.21	62.22	–0.01
6	62.15	62.09	0.06
7	61.86	61.87	–0.01
8	61.28	61.38	–0.10
9	60.91	60.93	–0.02
10	60.34	60.38	–0.04
11	59.69	59.73	–0.04
12	59.09	59.10	–0.01
13	58.76	58.69	0.07
14	58.54	58.46	0.08
15	58.3	58.26	0.04
平均残差			0.014 1

$$\boldsymbol{P}_0 = \begin{bmatrix} 0.427\ 1 & 0.382\ 0 \\ 0.382\ 0 & 1.236\ 1 \end{bmatrix}。$$

根据以上初始值及卡尔曼滤波的推导公式，通过卡尔曼滤波程序对该组数据进行滤波处理，对比分析滤波前后的变化，结果见图 1 和图 2。原始数据与滤波后的数据信噪比分别为 31.385 1 和 58.761 4，滤波后的信噪比比滤波前有了较大的提

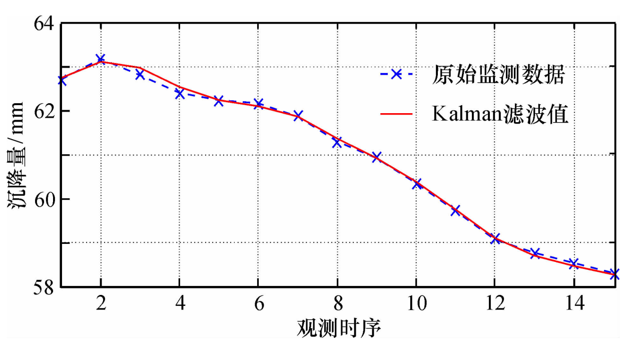

图 1　Kalman 滤波前后对比

Fig. 1　Monitoring data and Kalman filtering value

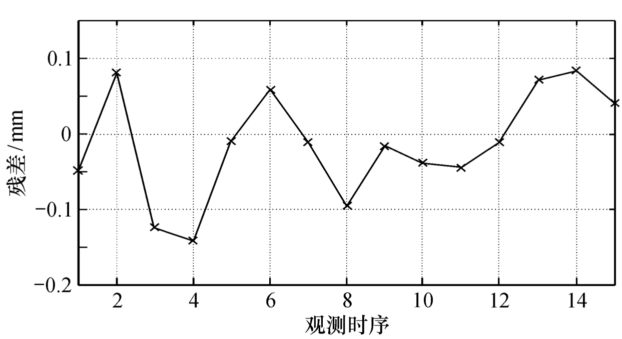

图 2　残差曲线

Fig. 2　Residual curve

高，噪声过滤得越干净，收敛效果越好。原始沉降曲线在滤波后变得平滑(图 1)，残差曲线处于收敛趋势，表明原始数据中随机噪声的影响在减弱，原始数据的显示更加逼近真实值(图 2)。

3.2 基于卡尔曼滤波的 GM(1,1) –AR 模型的建立

GM(1,1) –AR 组合模型的建模方法通常有两种[9-14]：一种是线性组合法即直接剔除法，另一种是非线性组合法也叫趋势项提取法。本文采用的是趋势项提取法。该方法在非平稳序列中，通过 GM(1,1)模型对监测物的位移进行非线性拟合以提取确定性部分即趋势项，将趋势项用明确的函数表示，继而得到随机项，然后对剩下的随机项（残差序列）进行标准化处理来满足 AR 模型建模时对时序的平稳、零均值和正态要求，从而建立 AR 模型。最后，将 GM(1,1)确定性函数关系式与 AR 模型处理结果进行叠加，即可得到非平稳的非线性组合模型，根据模型预测结果以分析该沉降监测点的变形情况。

本文将卡尔曼滤波校正后的前 15 期数据作为 GM(1,1) –AR 模型的初始值，经检验发现，灰色残差属于非平稳序列，不能满足 AR(p)对于平稳性与正态性的要求，故对残差序列进行零化处理和标准化处理，继而根据上述提到的 GM(1,1) –AR 模型的非线性组合算法建立基于卡尔曼滤波的 GM(1,1) –AR 模型，最后对该模型的可行性和有效性进行检验。以后 5 期的数据序列进行预测，同时将其预测结果与非线性 GM(1,1) –AR 模型、传统的灰色 GM(1,1)模型结果进行对比分析。运用后验差检验法来判定新算法模型与其他两个模型的精度。

3.3 结果分析

由表 3 和表 4 可知，GM(1,1)模型预测的平均残差值为 0.583 7，GM(1,1) –AR 模型和基于卡尔曼滤波的 GM(1,1) –AR 模型的分别为 0.454 2 和 0.372 1，这 3 个模型的预测精度均为一级，不同的是，GM(1,1)模型的后验方差比值 $C=0.149\ 8$，而 GM(1,1) –AR 模型与基于卡尔曼滤波的 GM(1,1) –AR 模型的后验方差比值均处于 0.1 左右，说明当加入了时序分析模型，单一模型变成组合模型后比单一模型更具动态外延性，已经能更精确地根据数据序列的有效信息延伸出预测信息；比较残差的绝对值和残差的方差可以发现，基于卡尔曼滤波的 GM(1,1) –AR 模型的误差均最小，其预测值也更接近实测值。总体看来，该组合模型更加综合体现出了模型融合的互补优势及卡尔曼滤波其较好的剔除不确定性误差干扰的特点，使模型能保持较高的短期预测精度。

表 3　3 种模型的拟合值、预测值、残差对比

Table 3　Fitted, predictive and residual values of three models　mm

期数	原始数据	GM(1,1)模型		GM(1,1) –AR 模型		基于卡尔曼滤波的 GM(1,1) –AR 模型	
		拟合/预测值	残差	拟合/预测值	残差	拟合/预测值	残差
1	62.69	62.69	0.00	62.69	0.00	62.69	0.00
2	63.16	63.45	–0.29	63.16	0.00	63.16	0.00
3	62.83	63.04	–0.21	62.64	0.19	62.53	0.30
4	62.39	62.62	–0.23	62.45	–0.06	62.48	–0.09
5	62.21	62.21	0.00	61.97	0.24	61.96	0.25
6	62.15	61.81	0.34	61.89	0.26	61.97	0.18
7	61.86	61.40	0.46	61.87	–0.01	62.00	–0.14
8	61.28	61.00	0.28	61.50	–0.22	61.54	–0.26
9	60.91	60.60	0.31	60.82	0.09	60.75	0.16
10	60.34	60.20	0.14	60.53	–0.19	60.53	–0.19
11	59.69	59.81	–0.12	59.89	–0.20	59.82	–0.13
12	59.09	59.42	–0.33	59.21	–0.12	59.11	–0.02
13	58.76	59.03	–0.27	58.63	0.13	58.55	0.21
14	58.54	58.64	–0.10	58.40	0.14	58.42	0.12
15	58.3	58.26	0.04	58.22	0.08	58.28	0.02
16	58.18	57.88	0.30	57.98	0.20	57.99	0.19
17	57.96	57.50	0.46	57.62	0.34	57.68	0.28
18	57.85	57.12	0.73	57.26	0.59	57.35	0.50
19	57.49	56.75	0.74	56.89	0.60	57.01	0.48
20	57.07	56.38	0.69	56.53	0.54	56.66	0.41

表 4　3 种模型的精度对比

Table 4　Prediction accuracy of three models　mm

模型	后验差比值 C	小误差概率/%	平均残差	残差的方差
GM(1,1)模型	0.149 8	100	0.583 7	0.030 3
GM(1,1) - AR 模型	0.092 6	100	0.454 2	0.024 3
基于卡尔曼滤波的 GM(1,1) - AR 模型	0.100 1	100	0.372 1	0.013 8

4　结　论

本文将卡尔曼滤波模型和时间序列分析模型引入,剔除了不必要的噪声干扰,有效缓和了沉降曲线中波动较大的转折点,缩小了 GM(1,1)模型的局限性来拟合数据序列中的波动项,利用 3 种模型各自的优势组合成一种新算法模型。灰色模型适用于小样本数据,GM(1,1) - AR 模型适用于中长样本数据,但都无法处理变形监测数据中含随机噪声扰动的因素,根据实例分析看出,基于卡尔曼滤波的 GM(1,1) - AR 模型在一定程度上修正了 GM(1,1)模型及其传统 GM(1,1) - AR 模型的偏差,对于短中期、含噪较大的建筑物变形监测数据的预测具备一定的参考价值。但是仍有一些不足:

(1) 基于卡尔曼滤波的 GM(1,1) - AR 模型一开始并没有对数据进行预处理，虽然对短期预测不会有太大影响，但长期预测效果如果没有及时更新数据就会引起误差的滞怠，这时候如果引入动态模型可能会得到更加优化的效果。

(2) 该模型虽然剔除了部分噪声的影响，但去噪效果的优劣主要取决于滤波初始值的准确选择，对于卡尔曼滤波用于长期预测是否会引起一定发散的问题，有待今后进一步探究。

参考文献:

[1] 张正禄，黄全义，文鸿雁，等. 工程的变形监测分析与预报［M］. 北京：测绘出版社，2007.

[2] 何君，杨国东. 灰色预测理论在建筑物沉降中的应用研究［J］. 测绘通报，2012 (3)：63 - 64.

[3] 刘汉丽，裴韬，周成虎. 用于时间序列聚类分析的小波变换和特征量提取方法［J］. 测绘科学技术学报，2014，31 (4)：372 - 376.

[4] 苏观南,郑东健,孙斌斌. 卡尔曼滤波灰色模型在大坝变形预测中的应用［J］. 水电能源科学,2014,32(4):37 - 40.

[5] 朱军桃，熊东旭，李亚威. 基于卡尔曼滤波的灰色马尔科夫组合模型在基坑变形监测中的应用［J］. 桂林理工大学学报，2017，37 (4)：653 - 657.

[6] 韩厚增，王坚，马昌中. 基于有色噪声 Kalman 滤波的桥梁自振频率提取模型研究［J］. 大地测量与地球动力学，2012，32 (1)：123 - 126，135.

[7] 周吕，文鸿雁，韩亚坤. 灰关联 Kalman 滤波的大坝变形分析模型[J]. 桂林理工大学学报，2013，33(1)：95 - 98.

[8] 喜文飞，史正涛. 基于卡尔曼滤波的动态灰色理论模型研究［J］. 测绘工程，2014，23 (3)：24 - 27.

[9] 文鸿雁，聂光裕，袁明月，等. 基于小波去噪的改进 GM(1,1)模型在高铁线下工程中的应用[J]. 桂林理工大学学报，2017，37(1)：131 - 135.

[10] 文鸿雁，周吕，韩亚坤，等. 基于卡尔曼滤波的 GM (1, 1)模型在高铁隧道沉降变形分析中的应用［J］. 大地测量与地球动力学，2014，34 (1)：88 - 91.

[11] 张正虎，袁孟科，邓建辉，等. 基于改进灰色 - 时序分析时变模型的边坡位移预测［J］. 岩石力学与工程学报，2014，33 (S2)：3791 - 3797.

[12] 胡泽周，刘国超. GM - AR 模型在变形监测数据处理中的应用［J］. 勘察科学技术，2015 (3)：45 - 48.

[13] 高宁，崔希民，高彩云. 灰时序 GM - AR 模型在建筑物沉降变形预测中的应用［J］. 测绘科学，2013，38 (1)：139 - 141.

[14] 容静，文鸿雁，周吕. 一种改进灰色预测模型在变形预测中的应用［J］. 测绘科学，2017，42 (3)：35 - 38.

Application of GM(1,1) - AR forecasting model based on Kalman filter in deformation forecast

RONG Jing[1], LIU Li-long[1], WEN Hong-yan[1], WANG Qing-tao[1], ZHOU Lyv[1,2,3]

(1. a. Guangxi Key Laboratory of Spatial Information and Geomatics; b. College of Geomatics and Geoinformation; c. Guangxi Scientific Experiment Center of Mining, Metallurgy and Environment, Guilin University of Technology, Guilin 541004, China; 2. School of Geodesy and Geomatics, Wuhan University, Wuhan 430079, China; 3. Key Laboratory for Digital Land and Resources of Jiangxi Province, East China University of Technology, Nanchang 330013, China)

Abstract: For the random uncertainty rule for deformation monitoring data, the Kalman filter is introduced to eliminate the random disturbance error. Grey model GM (1, 1) can directly handle non-stationary time series and has the powerful function in fitting trend items in time series. We take the grey theory and nonlinear time series analysis method to form the composite model, then analyze and predict the deformation monitoring data. The prediction model will be used to analyze the building deformation. Compared with other forecasting models, the model verification shows that the GM(1,1) - AR forecasting model based on Kalman filter predicted results is better, the average error and the residual variance are relatively decreased, with higher precision. These results have a certain reference value on the development of building deformation and the building stability.

Key words: GM(1,1); analysis of time series; Kalman filter; deformation prediction