

doi: 10.7690/bgzdh.2018.05.012

改进灰色残差模型在航迹预测中的应用

张晨, 毛征, 张广申, 王朋月, 邓锴, 职荣豪
(北京工业大学信息学部, 北京 100124)

摘要: 为了提高航迹预测的准确度, 加强对来袭目标的打击效果, 提出一种改进灰色残差模型对目标航迹进行预测。该方法将灰色 GM(1,1)模型与支持向量回归机相结合, 通过对原始航迹数据建立灰色模型得到预测值以及残差序列, 提出的改进残差模型运用支持向量回归机非线性拟合的能力对预测值进行修正, 在一定程度上克服了 GM(1,1)模型的缺陷, 使模型预测结果的精度得以提升。分别使用灰色 GM(1,1)模型、灰色残差 GM(1,1)模型、改进灰色残差 GM(1,1)模型 3 种方法对同一航迹进行预测并对预测的结果进行对比。计算结果表明: 该改进模型在航迹数据变化较大的情况下能够较为精确地对航迹进行预测, 有较高的理论和实用参考价值。

关键词: GM(1,1)模型; 残差修正; 支持向回归量机
中图分类号: TP391.9 **文献标志码:** A

Application of Improved Grey Residual Model in Track Prediction

Zhang Chen, Mao Zheng, Zhang Guangshen, Wang Pengyue, Deng Kai, Zhi Ronghao
(Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China)

Abstract: In order to improve the accuracy of the prediction of the track, and strengthen the impact of the attack on the target, an improved grey residual model is proposed to predict the target track. The method of grey GM(1,1) model with support vector regression combination, obtained by predictive value and residual sequence of the original track data to establish the grey model, the improved residual model is used to correct the predictive value by using the nonlinear fitting ability of support vector regression, to a certain extent overcome the GM(1,1) model the model defects, the prediction accuracy can be improved. Using the grey GM(1,1) model, the grey residual GM(1,1) model and the improved grey residual GM(1,1) model, 3 methods are used to predict the same track and to compare the predicted results. The results show that the improved model can predict the track accurately with the large variation of track data, which has a high theoretical and practical reference value.

Keywords: GM(1,1) model; residual error revision; support vector regression

0 引言

随着电子信息技术的迅猛发展及其在军事领域中的广泛应用, 新的军事技术革命正在形成。从近几年世界上的局部冲突可以看出, 现代战争中以空袭对敌方战略目标实施外科手术式的精确打击已经成为战争的先导和决定因素。由于来袭目标的航迹具有很强的不确定性, 为了提高对来袭目标的打击效果, 需要一种适应性较强的算法来处理航迹数据, 并对目标未来航迹作出准确预测。

近年来, 随着航迹处理技术的发展, 许多成熟算法都已成功应用于目标航迹预测。例如卡尔曼滤波算法^[1]、粒子滤波算法^[2]、混沌神经网络^[3]以及神经网络结合遗传算法^[4]。这些算法在对特定航迹的处理中都取得了较好的效果。

灰色系统理论是由我国邓聚龙教授提出的一种研究少数据、贫信息不确定性问题的方法^[5]。它在目标样本数量较少的情况下即可做出较为准

确的预测, 同时也不要求目标样本符合特定的分布规律; 因此, 十分适合解决文中“贫信息”“不确定性”的航迹预测问题。灰色预测就是通过对原始数据的处理和灰色模型的建立, 发现、掌握系统的发展规律, 对系统的未来状态做出科学的定量预测。其中灰色 GM(1,1)模型具有需求样本数据少、运算方便等优点, 因而得到了广泛应用; 但是, 和其他预测方法一样, 该模型本身也存在一定的局限性, 在预测准确度和适用范围方面还有提升空间。近年来, 随着研究的深入, 许多优化方法相继被提出。例如对预测模型背景值的重新构造^[6]、在模型中引入缓冲算子^[7]、改进模型初值的选择^[8]以及将预测模型与神经网络结合^[9]等, 这些方法都取得了一定的效果。

笔者针对灰色 GM(1,1)模型具有弱化序列随机性, 易于挖掘系统演化规律, 对一般模型具有很强的融合力和渗透力等特点, 结合支持向量回归机对

收稿日期: 2018-02-24; 修回日期: 2018-03-19

作者简介: 张晨(1992—), 男, 北京人, 硕士, 从事数据融合与航迹处理技术研究。

“小样本”“非线性”数据预测处理能力较好且可以避免陷入局部最优的特性^[10]，构造一种残差修正模型，该模型在原始 GM(1,1)模型的基础上通过支持向量机对预测结果进行优化，提高了预测精度，增加了模型的适用范围并成功应用于航迹预测。

1 灰色残差 GM(1,1)模型

1.1 GM(1,1)模型的建立

在灰色理论中，可以把随机量看作是在一定时段上、一定范围内变化的灰色量和灰色过程。对于灰色量的处理并不是为了寻求它的分布规律，而是通过一定的方法对看似杂乱无章的原始数据进行处理，以数据找数据的规律，弱化原始数据序列的随机性，使其变成具有一定规律的数据序列，并在此基础上建立动态模型^[11]。数列预测是对系统变量的未来行为进行预测，GM(1,1)是较为常用的数列预测模型。GM(1,1)模型适用于广义的能量系统，有较大的应用范围，GM(1,1)模型是微分方程模型，可对所描述的对象作长期、连续、动态的反映。

设原始序列为：

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

对其进行一次累加处理以弱化其随机性。

$$x^{(1)} = \{x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)\}。$$

称 $X^{(1)}$ 为 $X^{(0)}$ 的 1-AGO 序列。

设 $Z^{(1)}$ 为 $X^{(1)}$ 的紧邻均值序列：

$$z^{(1)} = \{z^{(1)}(2), z^{(1)}(3), \dots, z^{(1)}(n)\}。$$

其中

$$z^{(1)}(k) = 0.5(x^{(1)}(k) + x^{(1)}(k-1))。$$

建立生成序列相应的一阶线性白化微分方程：

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = u。 \tag{1}$$

离散化得矩阵形式

$$Y = XB。 \tag{2}$$

其中

$$Y = \begin{bmatrix} x_1^{(0)}(2) \\ x_1^{(0)}(3) \\ \vdots \\ x_1^{(0)}(N) \end{bmatrix}, \quad B = \begin{bmatrix} a \\ u \end{bmatrix}, \quad X = \begin{bmatrix} -z^{(1)}(2) & 1 \\ -z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix}。$$

通过最小二乘法求解得：

$$\hat{B} = (X^T X)^{-1} (X^T Y) = \begin{bmatrix} \hat{a} \\ \hat{u} \end{bmatrix}。 \tag{3}$$

微分方程解为：

$$\hat{x}^{(1)}(k+1) = (x^{(0)}(1) - \frac{\hat{u}}{\hat{a}})e^{-\hat{a}k} + \frac{\hat{u}}{\hat{a}}。 \tag{4}$$

经累减还原得到原始序列：

$$\hat{x}^{(0)}(k+1) = \hat{x}^{(1)}(k+1) - \hat{x}^{(1)}(k) = (1 - e^{\hat{a}})(x^{(0)}(1) - \frac{\hat{u}}{\hat{a}})e^{-\hat{a}k}。 \tag{5}$$

上式即为灰色 GM(1,1)模型的预测方程。

预测方程中的参数 \hat{a} 为发展系数， \hat{u} 为灰色作用量^[12]。其中 \hat{a} 反映了累减还原序列 $\hat{x}^{(0)}$ 的发展态势；灰色作用量 \hat{u} 是从背景值挖掘出来的数据，反映数据变化的关系，其确切内涵是灰的。灰色作用量是内涵外延化具体体现，是区别灰色建模与一般输入输出建模的分水岭，也是区别灰色系统观点与灰箱观点的重要标志。

近年来，许多对于灰色模型的研究表明，原始序列的光滑度是影响模型预测精度的关键因素。原始序列的光滑度越高，则模型的建模精度就越高，就越能反映出序列的变化趋势。通过对原始序列建模即可得到较高精度的预测数据。在实际应用中许多数据序列的光滑度较低，虽然通过累加处理可以在一定程度上弱化原始序列的随机性，强化其规律性，但并不能从根本上提高建模精度，这大大限制了灰色模型的适用范围。

1.2 残差修正模型

如果由原始数据建立的 GM(1,1)模型预测误差较大，可以建立残差的 GM(1,1)模型对原模型进行修正，以提高预测精度^[5]。

设残差为：

$$\varepsilon(k) = x^{(0)}(k) - \hat{x}^{(0)}(k) \quad k = i, i = 1, \dots, n。 \tag{6}$$

则残差序列为：

$$\varepsilon^{(0)}(k) = (\varepsilon^{(0)}(i), \varepsilon^{(0)}(i+1), \dots, \varepsilon^{(0)}(n))。$$

以此建立残差的 GM(1,1)模型得到残差的预测模型：

$$\hat{\varepsilon}^{(0)}(k+1) = (\varepsilon^{(0)}(i) - \frac{\hat{u}'}{\hat{a}'}) (1 - e^{\hat{a}'}) e^{-\hat{a}'k} + \frac{\hat{u}'}{\hat{a}'}。 \tag{7}$$

将残差模型与原始数据建立的 GM(1,1)模型相加得到残差修正模型

$$\hat{x}^{(0)}(k+1) = (1 - e^{\hat{a}})(x^{(0)}(1) - \frac{\hat{u}}{\hat{a}})e^{-\hat{a}k} + \delta(k-i)(\varepsilon^{(0)}(i) - \frac{\hat{u}'}{\hat{a}'}) (1 - e^{\hat{a}'}) e^{-\hat{a}'k}。 \tag{8}$$

其中

$$\begin{cases} \delta(k-i) = 0 & k < i \\ \delta(k-i) = 1 & k \geq i \end{cases}。$$

2 支持向量回归机

支持向量回归机 (support vector regression, SVR) 是基于支持向量机 (support vector machine, SVM) 理论建立的一种用于解决回归估计问题的技术。对于非线性回归问题，其主要通过升维后，在高维空间中构造线性决策函数从而转化为线性回归问题。使用不敏感函数 ϵ 时，其基础主要是 ϵ 和核函数算法。若将拟合的数学模型表达多维空间的某一曲线，则根据 ϵ 所得的结果，就是包括该曲线和训练点的 ϵ 管道。在所有样本点中，只有分布在管壁上的那一部分样本点决定管道的位置。这一部分训练样本称为支持向量。

支持向量回归算法为了解决过拟合这一矛盾，用核函数代替线性方程中的线性项，可以使原来的线性算法“非线性化”，即能做非线性回归。与此同时，引进核函数达到了“升维”的目的，而增加的可调参数使过拟合依然能控制。支持向量机在回归算法研究方面有极好的性能，在许多领域已得到应用。

若原始数据序列符合线性变化规律，那么支持向量回归算法的目标函数^[13]为：

$$\min J = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i^* + \xi_i) \quad (9)$$

目标函数的约束条件为：

$$\left. \begin{aligned} y_i - w\varphi(x) - b &\leq \epsilon + \xi_i \\ w\varphi(x) + b - y_i &\leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* &\geq 0, i=1, 2, \dots, n \end{aligned} \right\} \quad (10)$$

其中： ξ_i 和 ξ_i^* 为松弛因子； C 为惩罚系数。

通过引入拉格朗日函数简化求解过程，将求解问题转化为凸二次优化问题：

$$\begin{aligned} L(w, b, \xi, \xi^*, a, a^*, \gamma, \gamma^*) &= \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \\ &\sum_{i=1}^n a_i (\xi_i + \epsilon - y_i + f(x_i)) - \sum_{i=1}^n a_i^* (\xi_i^* + \epsilon - y_i + f(x_i)) - \\ &\sum_{i=1}^n (\xi_i \gamma_i - \xi_i^* \gamma_i^*) \end{aligned} \quad (11)$$

其中 a_i , a_i^* 为拉格朗日乘子。线性预测模型为

$$f(x) = \sum_{i=1}^n (a_i - a_i^*) \phi(x_i, x) + b \quad (12)$$

由于在实际应用中存在非线性回归预测问题，故引入核函数将非线性问题映射到高维空间中，从而将非线性问题转化为线性问题。预测模型变为：

$$f(x) = \sum_{i=1}^n (a_i - a_i^*) k(x_i, x) + b \quad (13)$$

其中 $k(x_i, x)$ 为核函数。由于径向基函数在大多数情况下的性能要优于其它核函数，因此选用径向基函数作为核函数，最终预测模型为

$$f(x) = \sum_{i=1}^n (a_i - a_i^*) \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) + b \quad (14)$$

3 支持向量回归机改进残差修正模型

对于前文介绍的残差修正模型，其实质是对残差序列建立灰色预测模型，因此同样受到残差序列光滑度的影响^[14]。当残差序列波动较小时，原模型的预测精度通过修正可以得到较大提高。而残差序列波动较大时，对原模型的修正效果就变得十分有限，难以真正起到对其进行修正的作用。为了解决上述问题，笔者采用支持向量回归机对原模型进行修正，以克服残差序列的波动性对修正效果的影响。

首先对原始序列 $x^{(0)}$ 进行一次累加处理得到累加序列 $x^{(1)}$ ，建立 GM(1,1) 预测模型得到 1 到 n 时刻的残差序列 $\epsilon^{(0)}$ ，以及 $n+1$ 时刻的预测值 $\hat{x}^{(0)}(n+1)$ 。接着利用残差序列对预测结果进行修正。设 $\epsilon^{(0)}(i)$ 为残差序列， $i=1, 2, \dots, n$ ，若预测阶数为 S ，即用 $\epsilon^{(0)}(i-1), \epsilon^{(0)}(i-2), \dots, \epsilon^{(0)}(i-S)$ 作为支持向量回归机的训练样本，将 $\epsilon^{(0)}(i)$ 作为期望值。通过训练，笔者利用 $\epsilon^{(0)}(n), \epsilon^{(0)}(n-1), \dots, \epsilon^{(0)}(n+1-S)$ 作为输入，通过支持向量回归机得到 $n+1$ 时刻的残差 $\epsilon^{(0)}(n+1)$ 。将 $n+1$ 时刻的预测值与残差值相加得到修正后的预测值 $\hat{x}^{(0)}(n+1) + \epsilon^{(0)}(n+1)$ 。具体流程如图 1 所示。

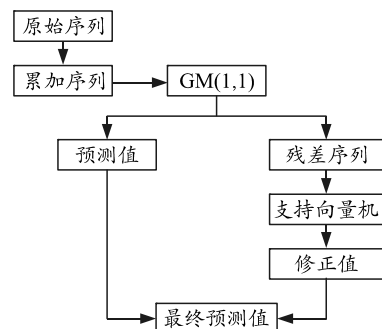


图 1 改进残差模型流程

4 后验差检验

后验差检验是根据预测模型的预测值与实际值之间的统计情况进行检验的方法，是以残值为计算基础，统计残差较小的点出现的概率，以及有关预测误差方差的指标大小^[15]。设残差平均值为

$$\bar{\varepsilon} = \frac{1}{n} \sum_{k=1}^n \varepsilon(k) \quad (15)$$

原始数据的平均值为

$$\bar{x} = \frac{1}{n} \sum_{k=1}^n x^{(0)}(k) \quad (16)$$

记原始数据方差和残差方差分别为 S_1^2 和 S_2^2 :

$$S_1^2 = \frac{1}{n} \sum_{k=1}^n [x^{(0)}(k) - \bar{x}]^2; \quad (17)$$

$$S_2^2 = \frac{1}{n} \sum_{k=1}^n [\varepsilon(k) - \bar{\varepsilon}]^2. \quad (18)$$

定义后验差比值 C 和小误差概率 P 为:

$$C = \frac{S_2}{S_1}; \quad (19)$$

$$P = P\{|\varepsilon(k) - \bar{\varepsilon}| < 0.674 5S_1\}. \quad (20)$$

后验差比值 C 越小, 表明由建立的预测模型所得到的预测值与实际值的拟合度越高。小误差概率 P 越大, 说明残差与残差平均值之差小于给定值 $0.674 5S_1$ 的点较多。预测模型的评判标准由表 1 所示。

表 1 预测模型评定标准

预测精度等级	小误差概率 P	后验差比值 C
好(一级)	> 0.95	< 0.35
合格(二级)	> 0.80	< 0.45
勉强(三级)	> 0.70	< 0.50
不合格(四级)	≤ 0.70	≥ 0.65

5 仿真结果与分析

5.1 目标航迹

为测试文中提出的改进残差修正模型, 生成如图 2(a)所示航迹。该航迹的 X 轴、 Y 轴、 Z 轴映射分别如图 2(b)、(c)、(d)所示。




图 2 目标航迹

5.2 仿真结果

以图 2 中的航迹为例, 使用原始 GM(1,1)模型、残差修正 GM(1,1)模型以及笔者提出的改进残差模型分别对该航迹进行预测, 预测结果如图 3 所示。图 4(a)、图 5(a)、图 6(a)分别显示了在 X 轴、 Y 轴、 Z 轴 3 种预测方法对航迹的预测结果。图 4(b)、图 5(b)、图 6(b)分别显示了 3 种预测方法的预测值与实际值间的偏差曲线。表 2 分别显示了在 X 、 Y 、 Z 轴上对 3 种预测模型预测精度的评定。

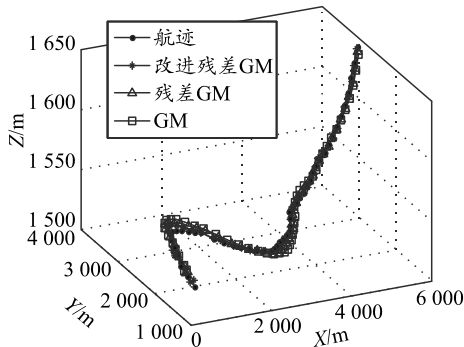




图 3 预测结果



(a) X轴预测结果比较



(b) X轴预测偏差比较

图 4 X 轴预测结果比较与预测偏差比较

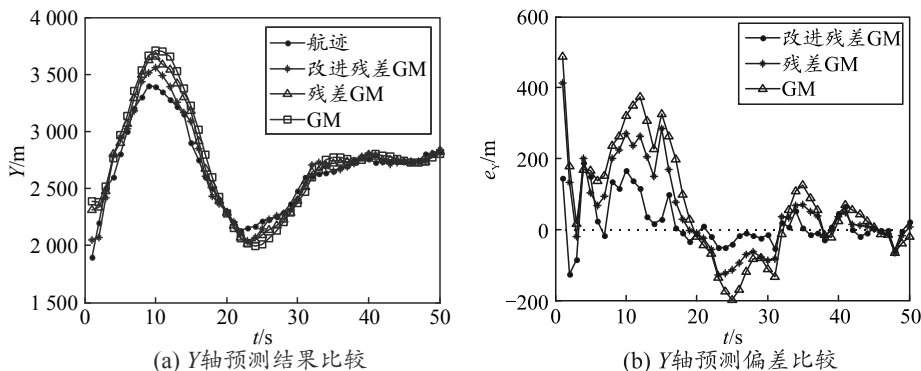


图 5 Y 轴预测结果比较与预测偏差比较




图 6 Z 轴预测结果比较与预测偏差比较

表 2 预测模型评定

坐标轴	测评标准	残差 GM(1,1)模型		
		GM(1,1)模型	改进残差模型	改进残差模型
X 轴	小误差概率 P	1	1	1
	后验差比值 C	0.024 0	0.021 2	0.011 4
	预测精度	一级	一级	一级
Y 轴	小误差概率 P	0.860 0	0.950 0	0.981 5
	后验差比值 C	0.440 0	0.374 3	0.212 1
	预测精度	二级	二级	一级
Z 轴	小误差概率 P	1	1	1
	后验差比值 C	0.039 8	0.029 6	0.014 8
	预测精度	一级	一级	一级

5.3 结果分析

图 4(a)、图 6(a)显示了原始航迹以及 3 种预测模型的预测结果在 X 轴和 Z 轴的映射。在图 4(a)、图 6(a)中 3 种预测模型的预测结果几乎重合。但在图 4(b)、图 6(b)显示文中提出的改进残差预测模型的预测偏差均小于另外 2 种模型。按照表 1 的评定标准，表 2 显示在 X 轴与 Z 轴 3 种预测模型的预测精度均达到一级，但改进残差修正模型在后验差比值这项上小于另外 2 种模型，说明它的预测值与实际值的拟合度更高。图 5(a)显示了原始航迹以及 3 种模型的预测结果在 Y 轴的映射。从图 5(b)可以看到：在航迹变化较大的时段，改进残差模型的预测偏差明显小于另外 2 种模型。表 2 显示 Y 轴改进残差模型在小误差概率和后验差比值这 2 项测评标准

上，均优于另外 2 种模型且预测精度依旧为一级，而另 2 种预测模型的精度则下降为二级。

6 结论

灰色 GM(1,1)模型利用对原始时间序列累加后生成的新序列进行建模。对于累加后呈单一指数增长模式的序列，GM(1,1)模型的预测精度较高而对于波动性较强的时间序列，其预测结果偏差较大。同时由于参数序列的波动较大，即便采用灰色模型进行修正，预测精度等级也未能提升。笔者提出的改进残差模型运用支持向量回归机非线性拟合的能力对预测值进行修正，在一定程度上克服了 GM(1,1)模型的缺陷，使模型预测结果的精度得以提升。

参考文献：

- [1] 王涛波, 黄宝军. 基于改进卡尔曼滤波的四维飞行航迹预测模型[J]. 计算机应用, 2014, 34(6): 1812-1815.
- [2] 刘志花, 李淑芬, 李宝安. 基于粒子滤波的无人机航迹预测方法研究[J]. 电子测量与仪器学报, 2010, 24(7): 643-649.
- [3] HE B L, Mao Z. A Track-to-track Association Algorithm with Chaotic Neural Network[C]. Asian-Pacific Conference on Synthetic Aperture Radar Proceedings, 2009: 788-791.
- [4] 谭伟, 陆百川, 黄美灵. 神经网络结合遗传算法用于航

迹预测[J]. 重庆交通大学学报, 2010, 29(1): 147-150.

[5] 刘思峰, 党耀国, 方志耕, 等. 灰色系统理论及其应用[M]. 北京: 科学出版社, 2004: 134-138.

[6] 蒋诗泉, 刘思峰, 周兴才. 基于复化梯形公式的 GM(1, 1)模型背景值的优化[J]. 控制与决策, 2014, 29(12): 2221-2225.

[7] 苏永. 灰色缓冲算子与序列光滑性研究[D]. 杭州: 浙江理工大学, 2013.

[8] 马洪松. 基于改进灰色模型的电力负荷预测方法研究及应用[D]. 北京: 华北电力大学, 2013.

[9] 王守相, 张娜. 基于灰色神经网络组合模型的光伏短期出力预测[J]. 电力系统自动化, 2012, 36(19): 37-41.

[10] 邓乃扬, 田英杰. 支持向量机—理论、算法与拓展[M].

北京: 科学出版社, 2009: 10-12.

[11] 陈秋妹. 数据光滑度改进与灰色关联研究[D]. 杭州: 浙江工商大学, 2006.

[12] 李玲玲, 段超颖, 孙训俊. 灰色模型的改进及其应用[J]. 统计与决策, 2014, 38(24): 11-15.

[13] 金超, 牟燕, 马堃, 等. 灰色模型和支持向量机组合的预测模型及其应用[J]. 微型电脑应用, 2015, 31(1): 25-28.

[14] 杨春波. 基于灰色模型与人工神经网络的改进合预测模型及其应用研究[D]. 济南: 山东师范大学, 2009.

[15] 张军. 灰色预测模型的改进及其应用[D]. 西安: 西安理工大学, 2008.

 (上接第 39 页)

4 实验结果与分析

为了验证笔者设计的线缆故障快速诊断系统的有效性, 笔者制作了 2 根 10 芯线缆, 1 号线缆连通性良好, 2 号线缆的 2 号芯线断路, 4、5 号芯线错接, 7、8 号芯线短路, 其他芯线连通性正常, 2 号线缆包含了笔者研究的所有故障类型。为确保实验的准确性, 在测试之前人工先用万用表对待测线缆进行测试, 再用笔者设计的线缆快速诊断系统对待测线缆进行检测。测试结果如图 7 所示, 其正确性和人工用万用表检测一致, 并且由于采用通信方式对线缆故障进行检测, 其检测速度较快, 一组 10 芯线缆检测大概只需 3~5 s, 效率远大于人工检测。

果的功能, 减少了检测人员的工作量。根据合作单位的要求以及 CPLD 芯片 I/O 口数目限制, 该系统最多可以检测 41 芯的线缆。

5 结束语

笔者通过 FTA+FMCECA 分析法对线缆潜在故障进行定性分析, 包括线缆在使用时可能发生“断路”“短路”“错接”等故障。针对分析结果, 笔者设计了基于 STM32+CPLD 的线缆故障快速诊断系统。实验结果证明: 该快速诊断系统能够快速、准确地检测待测线缆, 与传统检测方式相比, 大大提高了检测效率。

参考文献:

[1] 郭庆明. 武器电缆电参量综合测试系统研究[D]. 南京: 南京理工大学, 2011.

[2] 李宏伟, 林玉池, 郑桐, 等. 新型便携式线缆快速测试技术的研究[J]. 机床与液压, 2007, 35(7): 101-102.

[3] 杨春宇. 电力电缆故障分析与诊断技术的研究[D]. 大连: 大连理工大学, 2013.

[4] 鲍永胜. 电力电缆局部放电在线监测与故障诊断[D]. 北京: 北京交通大学, 2012.

[5] 陈颖. FMCECA 技术及其应用[M]. 北京: 国防工业出版社, 2014: 172-196.

[6] 夏明旗. 故障模式与影响分析技术及其应用[J]. 国防技术基础, 2010(10): 21-23.

[7] 韩琦文, 赵转萍, 梁爽. 某型导弹电缆网导通绝缘性能检测系统设计[J]. 机电工程, 2016, 33(4): 442-447.

[8] 李金洪. 电缆连通性快速检测系统设计[J]. 电子设计工程, 2014, 22(20): 146-148.

[9] SUN Q. Application and Improvement of Cable Inspection Technology [J]. Low Voltage Apparatus, 2010, 12(8): 65-69.

[10] 孙玉胜, 马平, 邹玉炜. CPLD 在多芯电缆测试仪中的应用[J]. 科技创新导报, 2008(6): 170-171.



图 7 检测结果

线缆连通性的传统测试方式是使用万用表进行测试, 对于 n 芯的线缆需要检测 C_n^2 次, 检测人员的工作量较大且效率较低, 而笔者设计的线缆故障快速诊断系统对于 n 芯的线缆只需要检测 n 次, 大大提高了检测效率并且能够直接显示出故障的芯线。笔者设计的快速诊断系统增加了保存、打印检测结