

基于灰色神经网络的战场态势分析及预测

王劲松, 李宗育, 隋雷
(解放军信息工程大学, 郑州 450001)

摘要: 针对指挥决策者难以从复杂多变的战场态势要素中获取关联信息从而预判战场态势发展趋势的问题, 将战场态势视为灰色系统, 利用灰色系统理论对战场态势要素进行分类, 分析要素之间的关联程度, 从而为指挥决策者提供决心依据。结合神经网络建立 GM(1,1)-RBF, DGM(2,1)-RBF 组合模型对战场态势要素进行预测。同时, 为提高模型预测性能, 使用改进的算法对组合模型中的单个模型进行了优化。仿真实验结果表明, 优化后的组合模型在预测精度及算法效率上均有明显提升。

关键词: 战场态势; 分析及预测; 灰色神经网络

中图分类号: V271.4; TP391.9 文献标志码: A 文章编号: 1671-637X(2015)12-0015-05

Battlefield Situation Analysis and Prediction Based on Grey Neural Network

WANG Jin-song, LI Zong-yu, SUI Lei
(PLA Information Engineering University, Zhengzhou 450001, China)

Abstract: It is difficult for the commander and decision-maker to obtain the related information from complicated battlefield situational elements for judging the trend of battlefield. Aiming at this problem, we regarded the battlefield situation as a grey system, used the grey system theory to classify the acquisition of situational elements, and analyzed the degree of correlation between the elements to provide the basis for the commander to make decision. The data of battlefield situational elements was predicted by establishing a combined model of GM(1.1)-RBF model and DGM(2,1)-RBF models. To increase the prediction performance, the improved algorithm was used to optimize the single model of the combined models. Simulation result shows that the optimized combined models has much higher prediction accuracy and efficiency.

Key words: battlefield situation; analysis and prediction; grey neural network

0 引言

战场态势要素分析及预测起源于美军提出的战场态势感知, 国外在这一领域研究起步较早, 发展比较迅速, 理论和系统的研究与开发取得了较大成果, 而国内这方面的研究还处于起步阶段, 研究的方法仍不具体。利用灰色系统理论建模可充分挖掘战场态势数据的灰色信息, 所需采集的数据少、计算量小, 而人工神经网络具有计算精度高、误差可控等优点^[1]。若能将这两种方法有效结合, 实现优势互补, 便可显著提高系统建模的效率和模型预测的精度。目前, 对灰色系统与神

经网络进行组合预测的方法在其他领域的运用研究中, 将 GM(1,1)模型与 BP, RBF 网络结合预测的应用较多^[2], 本文尝试将灰色预测模型与神经网络分别优化后再组合预测, 并与原组合模型进行了对比。

1 态势要素分析与处理

1.1 数据分类

影响战场态势的要素是多维的, 包括传感器采集的已知、未知以及无法明确判定的信息, 要素间不是独立存在而是相互影响、相互制约的, 灰色系统理论中的灰色关联分析方法, 可以对不完整的战场态势信息进行数据挖掘从而发现它们之间的关联性。例如, 作战效果作为战场态势要素的重要构成, 影响它的其他态势要素有很多, 在此选取美军某数字化师 10 次作战行动中具有代表意义的态势要素: P_1 (战斗损耗), P_2 (兵

收稿日期: 2015-01-21

修回日期: 2015-03-04

基金项目: 全军军事类研究生资助课题(13QJ003-22)

作者简介: 王劲松(1965—), 男, 河南确山人, 硕士, 教授, 硕导, 研究方向为指挥决策支持技术。

力编成), P_3 (兵力保障), P_4 (天候气象), P_5 (战术水平),将其作为对象分析研究它们与作战效果之间的关联度, $P_1 \sim P_5$ 的量纲依次为 $a_1 \sim a_5$,令 P_0 为作战效果,量纲为 a_0 ,具体数据见表1。

表1 美军某数字化师10次行动态势要素数据

Table 1 Situational data of 10 times action of a U. S. digital division

	P_1/a_1	P_2/a_2	P_3/a_3	P_4/a_4	P_5/a_5	P_0/a_0
TIME1	1 408.58	2 195.42	88.56	0.73	1 536.03	72.29
TIME2	1 410.32	2 189.97	70.24	0.28	1 544.26	72.18
TIME3	1 425.78	2 187.20	85.38	0.82	1 559.34	72.27
TIME4	1 446.61	2 205.53	99.83	0.97	1 565.06	73.98
TIME5	1 457.98	2 232.77	90.56	0.82	1 588.38	74.95
TIME6	1 468.58	2 169.90	85.38	0.78	1 591.26	75.16
TIME7	1 449.03	2 183.28	99.83	0.98	1 592.34	76.77
TIME8	1 431.37	2 202.83	84.53	0.80	1 594.06	77.98
TIME9	1 416.35	2 212.75	85.38	0.28	1 597.78	78.94
TIME10	1 498.19	2 192.97	93.81	0.59	1 598.26	81.06

以表1中 P_0 为参考数列记为 $X_0 = \{x_0(k)\}, k = 1, 2, \dots, 10$,表中其他5个要素数据作为比较数列记为 $X_i = \{x_i(k)\}, i = 1, 2, \dots, 5, k = 1, 2, \dots, 10$ 。

1.2 关联分析

要素中单位不同、初值不同的数据要进行预处理,使其无量纲化、归一化。本文使用均值法对数据进行变换,过程如下

$$f(x_i(k)) = \frac{x_i(k)}{\bar{x}} = y_i(k) \quad \bar{x} = \frac{1}{n} \sum_{k=1}^n x_i(k) \quad (1)$$

式中: $i = 0, 1, \dots, 5; n = 10; x_i(k)$ 为比较数列在 k 时刻的数; $y_i(k)$ 为比较数列在 k 时刻经均值变化后的数据。 x_0 与 y_i 在 k 时刻的绝对差为 $\Delta k = |x_0(k) - y_i(k)|$,两极最小差 $m = \min_i \min_k |x_0(k) - y_i(k)|$,两极最大差 $M = \max_i \max_k |x_0(k) - y_i(k)|$,从而得到 x_0 与 y_i 在 k 时刻的关联系数为

$$\zeta_i(k) = \frac{m + \rho M}{|x_0(k) - y_i(k)| + \rho M} \quad (2)$$

式中, ρ 为分辨系数, $\rho \in [0, 1]$,其值越小分辨率越高,这里取值 $\rho = 0.5$ 。

将作战效果与其他要素数列代入关联度公式

$$r_i = \frac{1}{n} \sum_{k=1}^n \zeta_i(k) \quad n = 10 \quad (3)$$

使用 Matlab 计算,结果显示 $r_5 > r_2 > r_3 > r_4 > r_1$,但应当指出的是 $\Delta k = |x_0(k) - y_i(k)|$ 并不能区分出要素间是正关联或是负关联,在此引入

$$\sigma_i = \sum_{k=1}^n k x_i(k) - \sum_{k=1}^n x_i(k) \sum_{k=1}^n \frac{k}{n} \quad i = 1, 2, \dots, n \quad (4)$$

将数据代入上式,若 $\sin \sigma_0 = \sin \sigma_i, i = 1, \dots, 5$,则 x_0 与 x_i 为正关联关系,若 $\sin \sigma_0 = -\sin \sigma_i$,则 x_0 与 x_i 为负

关联关系,经计算, P_0 与 P_2, P_3, P_5 之间存在正关联,与 P_1, P_4 之间存在负关联。

2 灰色神经网络预测及仿真

不同的模型在组合使用时有自身的适用范围, $G(1,1)$ 模型适用于指数性较强或成单调变化的数据预测^[3], $DGM(2,1)$ 模型适用于呈非单调震荡变化、动态性强或具有饱和性质的S型数列的预测^[4]。

2.1 GM(1,1)-RBF 预测实验

该模型预测的思想是将模型拟合时产生的误差数列输入神经网络进行回归训练,得到预测误差数列,然后将模型的预测值与误差值相加得到新的预测值^[5],模型拓扑图见图1。




图1 GM(1,1)-RBF模型拓扑图

Fig.1 GM(1,1)-RBF model topology

P_5 (战术水平)的数列特征适合使用 $GM(1,1)$ -RBF模型进行预测,建模过程如下所述。

1) 建立 $GM(1,1)$ 模型,取数列 $X_5^{(0)} = x_5^{(0)}(k), k = 1, \dots, 10$,计算级比

$$\lambda(k) = \frac{x^{(0)}(k-1)}{x^{(0)}(k)} \quad k = 2, \dots, 10 \quad (5)$$

检验其是否在 $(e^{-\frac{2}{n}}, e^{\frac{2}{n}})$ 的覆盖区域内($n = 10$),若在,则可使用;若不在,则取常数 c 做平移处理,模型的时间响应函数为

$$\hat{x}^{(1)}(k) = -a \left(x^{(0)}(1) - \frac{b}{a} \right) e^{-a(k-1)} + \frac{b}{a} \quad k = 2, \dots, 10 \quad (6)$$

将式(6)还原得预测数列函数,即

$$\hat{x}^{(0)}(k) = -a \left(x^{(0)}(1) - \frac{b}{a} \right) e^{-a(k-1)} \quad k = 2, \dots, 10 \quad (7)$$

计算误差序列 $\varepsilon(k), k = 1, \dots, 10$ 。

2) 建立误差序列的RBF网络逼近模型,对 $\varepsilon(k)$ 进行误差回归训练,得到预测误差序列 $\hat{\varepsilon}^{(0)}(k)$,并将其与 $\hat{x}^{(0)}(k)$ 相加得到新的预测数列 $\hat{x}_1^{(0)}(k) = \hat{x}^{(0)}(k) + \hat{\varepsilon}^{(0)}(k)$ 。

3) 计算残差绝对值

$$\delta_5(k) = |x_5^{(0)} - \hat{x}_5^{(0)}(k)| \quad (8)$$

残差相对误差值为

$$\omega_5(k) = \frac{x_5^{(0)} - \hat{x}_5^{(0)}(k)}{x_5^{(0)}(k)} \quad k = 1, \dots, 10 \quad (9)$$

RBF 网络参数设置如下：网络层数为 3，最大神经元数为 25，散布常数为 1，训练目标为 0.001，两次间隔显示添加神经元个数为 2，仿真实验结果见表 2。

表 2 GM(1,1)-RBF 预测模型实验数据

Table 2 GM(1,1)-RBF model predictive experimental data

	预测值	残差相对误差	残差绝对值
TIME1	1 543.91	0.000 572	0.88
TIME2	1 543.71	0.000 356	0.55
TIME3	1 560.25	0.000 583	0.71
TIME4	1 566.39	0.000 849	1.33
TIME5	1 589.02	0.000 402	0.64
TIME6	1 590.83	0.000 270	0.43
TIME7	1 593.32	0.000 615	0.98
TIME8	1 594.92	0.000 539	0.86
TIME9	1 599.29	0.000 945	1.51
TIME10	1 599.33	0.000 669	1.07

由表 2 可得残差绝对值平均值和残差相对误差平均值为： $\bar{\delta}_5 = 0.896$ ， $\bar{\omega}_5 = 0.000 580$ 。

2.2 DGM(2,1)-RBF 预测实验

建模原理：取原始数列 $X^{(0)} = (x^{(0)}, x^{(1)}, \dots, x^{(n)})$ 中部分数列建立 DGM(2,1) 模型，假设构建模型组所需的最少数据为 m 个，原始非负数列中 $n \geq m$ ，由此便形成了 $n - m + 1$ 个模型，即 $DGM(2,1)_{n-k+1}, \dots, DGM(2,1)_n$ ，记为 $DGM(2,1)_{\text{partial-data}}$ 模型组^[6]，以模型组拟合的向量 $x_{bp}(k)$ 为学习样本，以原始序列 $X^{(0)}$ 为导师值训练网络达到误差精度后停止，再将 $DGM(2,1)_{\text{partial-data}}$ 的预测向量 $x_{bp}(t)$ ($t = n + 1, n + 2, \dots$) 耦合输入网络，从而得到原始数列的预测值^[7]，图 2 为模型拓扑图。

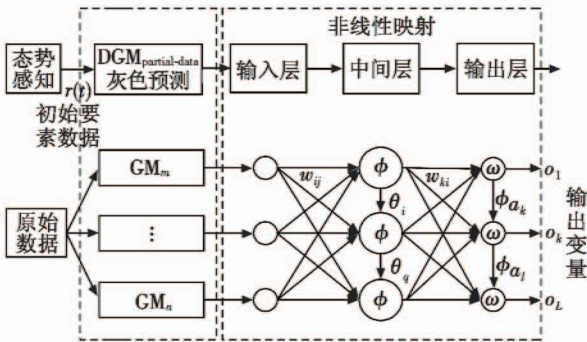


图 2 DGM(2,1)-RBF 模型拓扑图
Fig.2 DGM(2,1)-RBF model topology

态势要素 P_1 (战斗损耗) 向来是作战指挥中非常重要的态势要素，如何控制损耗、提升作战效能、降低己方损失是指挥决策者关心的重大问题^[8]，战斗损耗在初期作战范围限于局部时处于低值，当随着作战范围逐渐扩大敌我投入部署的兵力加大、战术水平等要素实力逐渐相当时数值呈上升趋势，但随着作战进程推演，战斗局势逐渐明朗，损耗达到峰值后会逐渐下降， P_1 的原始数列数据特征反映了这种客观特征，适

用于 DGM(2,1)-RBF 模型预测，建模过程如下：

- 1) 取原始 $x_1^{(0)}(k)$ 前 6 项作为训练值，后 4 项为检验值， m 取 3，这样便形成了 $k = 3, \dots, 6$ 的 3 组 $DGM(2,1)_{\text{partial-data}}$ 模型组，拟合得到向量 $x_{bp}(k)$ ；
- 2) 将拟合向量 $x_{bp}(k)$ 作为学习样本输入 RBF 网络，以原始数列 $x_1^{(0)}(k)$ ($k = 1, \dots, 6$) 为导师值训练，达到误差精度后停止，并将预测向量 $x_{bp}(k)$ ($k = 7, \dots, 10$) 输入网络得到模型预测值 $\hat{X}(k)$, $k = 7, \dots, 10$ ；
- 3) 计算残差绝对值 $\delta_1(k)$ ，相对误差 $\bar{\omega}_1(k)$ 。

Matlab 仿真实验结果见表 3。

表 3 DGM(2,1)-RBF 模型的预测实验数据

Table 3 DGM(2,1)-RBF model predictive experimental data

	预测值	残差相对误差	残差绝对值
TIME1	1 407.21	0.000 972	1.37
TIME2	1 411.02	0.000 496	0.72
TIME3	1 426.12	0.000 238	0.34
TIME4	1 447.31	0.000 483	0.70
TIME5	1 458.37	0.000 267	0.49
TIME6	1 469.05	0.000 251	0.47
TIME7	1 448.72	0.000 213	0.31
TIME8	1 432.94	0.000 257	1.57
TIME9	1 418.01	0.001 172	1.66
TIME10	1 500.21	0.001 348	2.02

由表 3 可得，残差绝对值平均值 $\bar{\delta}_1 = 0.763$ ，残差相对误差平均值 $\bar{\omega}_1 = 0.000 554$ 。

3 优化模型预测实验及对比

为了提高模型预测精度，先对灰色模型优化，再对 RBF 网络的中心参数优化，优化后将两个模型组合对数据进行预测。

3.1 灰色模型的优化

1) 在对 GM(1,1) 的优化上，采用动态优化关键参数的方法^[9]，在首次预测后将预测数据补充进原始数列 $X^{(0)}$ 中，同时将 $x^{(0)}(1)$ 剔除，并重新计算发展系数 a 及背景值 u ，进而建立新的 GM(1,1) 模型，直至符合目标值^[10]。

2) 在对 DGM(2,1) 模型的优化上，采取最优初始条件的方法，DGM(2,1) 模型的白化方程为

$$\frac{d^2 x^{(1)}}{dt^2} + a \frac{dx^{(1)}}{dt} = b \quad (10)$$

参数列向量为 $\hat{u} = (a, b)^T$ ， \hat{u} 最小二乘满足 $\hat{u} = (B^T B)^{-1} B^T Y$ ，在原始序列向量 $X^{(0)} = (x^{(0)}, \dots, x^{(m)}, \dots, x^{(n)})$ (n 为观察次数， m 为构建模型组所需的最少数据) 的初始条件选择上，并不取 $x^{(0)}(1) = \hat{x}^{(1)}(1) = \hat{x}(1)$ ，而是令 $\hat{x}^{(1)}(m) = x^{(1)}(m)$ ，根据经验 $n = 7$ ，对 $m = 1, \dots, 7$ 均用 DGM(2,1) 模型预测，求出平均相对误差，取误差最小的值所对应的 m 值为初始条件，得

到改进的 DGM(1,1) 预测方程,即

$$\hat{x}^1(k+1) = \left(\frac{b}{a^2} - \frac{x^{(0)}(m)}{a}\right)e^{-ak} + \frac{b}{a}(k+1) + \left(x^{(0)}(m) - \frac{b}{a}\right)\frac{1+a}{a} \quad (11)$$

对式(11)做一次累减还原得到预测值

$$\hat{x}^{(0)}(k+1) = \alpha^{(1)}\hat{x}^{(1)}(k+1) = \hat{x}^{(1)}(k+1) - \hat{x}^{(1)}(k) \quad (12)$$

3.2 神经网络的优化

3.2.1 使用退火算法优化

RBF 网络输出函数为

$$f(x) = \sum_{i=1}^n h_i(x)w_i = \sum_{i=1}^n \exp\left(-\frac{\|x_i - c_i\|^2}{2\sigma_i^2}\right)w_i \quad (13)$$

式中: $i=1, \dots, n$; w_i 为中间层与输出层连接权值; c_i 为径向基函数中心向量; σ_i 为宽度向量; n 为中心数, 可见网络预测精度的关键不在函数形式, 而是中心参数设置。使用退火算法对 RBF 网络中心参数优化, 优化后即全局最优参数, 适应度函数选网络输出端均方误差

$$F = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M (Z'_{ij} - Z_{ij})^2 \quad (14)$$

式中: Z'_{ij} 为实际输出; Z_{ij} 为期望输出; M 为网络输出单元数; N 为训练样本数。

优化具体步骤如下所述。

1) 随机选择一个初始状态向量 ω_1, c_1, σ_1 , 并将原始数据的前 6 项作为训练样本, 后 4 项为校验样本输入网络, 由输出 f_1 计算误差 F_1 。在此状态下, 给网络一个最小随机扰动 $\Delta\omega_1, \Delta c_1, \Delta\sigma_1$, 由 f_2 计算 F_2 , 计算增量 $\Delta E = F_1 - F_2$ 。

2) 若 $\Delta E < 0$, 接受 f_2 为状态值, 中心参数修改为 $\omega_1 + \Delta\omega_1, c_2 + \Delta c_1, \sigma_3 + \Delta\sigma_1$, 若 $\Delta E > 0$ 则按照概率

$$P = \min[1, \exp[-\Delta E/(Kt)]] \quad (15)$$

接受新的状态及参数, K 为 Boltzmann 常数, 这里取 1。

3) 重复前两个步骤, 直至 $T=0$ 或退火次数达到上限, 随即停止过程。

实验使用 Matlab 程序, 令初始温度为 $T=100$, 降温函数采用指数降温 `temperatureexp`, 算法终止条件中 `StallIterLim` 设为 500, `TolFun` 设置为极小值, 使算法迭代在 `MaxIter` 为 500 后停止, 用主函数 `simulannealbnd` 求解, RBF 网络学习速率 $\alpha=0.025$, 并使用激活函数 Sigmoid 训练。

将优化后的 GM(1,1), DGM(2,1) 模型与优化后的 RBF 网络进行组合, 对 $X_5^{(0)}, X_1^{(0)}$ 进行预测, 实验结果见表 4、表 5。

由表 4 可得, 优化后的 $\bar{\delta}'_5 = 0.642, \bar{\omega}'_5 = 0.000417$ 均小于优化前 $\bar{\delta}_5, \bar{\omega}_5$ 。由图 3 可看出, 优化后的模型残

差相对误差小于优化前的值, 说明模型在优化后对 P_5 数据的预测值与 P_5 的原始数据拟合程度要高于优化前。

表 4 GM(1,1)-RBF 模型优化后的预测实验数据

Table 4 The predictive experimental data of optimized

GM(1,1)-RBF model

	优化后预测值	优化后残差相对误差	优化后残差绝对值
TIME1	1 536.89	0.000 559	0.86
TIME2	1 543.91	0.000 226	0.35
TIME3	1 559.92	0.000 371	0.58
TIME4	1 565.84	0.000 498	0.78
TIME5	1 587.93	0.000 283	0.45
TIME6	1 591.46	0.000 125	0.20
TIME7	1 591.51	0.000 521	0.67
TIME8	1 593.39	0.000 420	0.67
TIME9	1 598.73	0.000 594	0.95
TIME10	1 599.17	0.000 569	0.91




图 3 GM(1,1)-RBF 模型优化前后的残差相对误差值对比

Fig. 3 GM(1,1)-RBF model relative residual error before and after optimization

表 5 DGM(2,1)-RBF 模型优化后的预测实验数据

Table 5 The predictive experimental data of optimized

DGM(2,1)-RBF model

	优化后预测值	优化后残差相对误差	优化后残差绝对值
TIME1	1 409.62	0.000 312	0.88
TIME2	1 409.68	0.000 453	0.55
TIME3	1 426.01	0.000 160	0.23
TIME4	1 447.23	0.000 347	0.62
TIME5	1 457.74	0.000 164	0.24
TIME6	1 468.22	0.000 245	0.36
TIME7	1 448.87	0.000 110	0.16
TIME8	1 430.39	0.000 184	0.96
TIME9	1 417.72	0.000 967	1.47
TIME10	1 497.14	0.000 700	1.05

由表 5 可得, 优化后的 $\bar{\delta}'_1 = 0.403, \bar{\omega}'_1 = 0.000414$, 小于优化前的 $\bar{\delta}_1, \bar{\omega}_1$ 。由图 4 可看出, 优化后的 DGM(2,1)-RBF 模型的残差相对误差小于优化前的值, 说明优化后模型对 P_1 的预测值与 P_1 原始数据的拟合程度要高于优化前模型预测值, 但应当指出退火算法在优化复杂神经网络时存在迭代次数过久、优化效率较低等问题。




图 4 DGM(2,1)-RBF 模型优化前后的残差相对误差值对比

Fig.4 DGM(2,1)-RBF model relative residual error before and after optimization

3.2.2 使用混合粒子群算法优化

使用混合粒子群算法对中心参数优化收敛度好,较退火算法耗费系统资源少,通过使用交叉、变异算子避免传统粒子算法聚集早熟现象,并克服了其收敛速度慢的缺点^[11]。

粒子的全局速度更新式为

$$G_i(k+1) = wv_i + c_1r_1(p_{si}^k - x_i^k) + c_2r_2(p_g^k - x_i^k) \quad (16)$$

局部速度更新式为

$$L_i(k+1) = wv_i + c_1r_1(p_{si}^k - x_i^k) + c_2r_2(p_{ii}^k - x_i^k) \quad (17)$$

位置更新式为

$$x_i^{k+1} = x_i^k + rv_i^{k+1} \quad (18)$$

式中: p_{si}^k 为历史搜索最优解; p_g^k 为全局最优解; p_{ii}^k 为邻域历史最优解; k 为迭代次数。

将式(16)、式(17)结合得到混合粒子速度更新式

$$H_i(k+1) = uG_i(k+1) + (1-u)L_i(k+1) \quad (19)$$

位置更新式

$$x_i^{k+1} = x_i^k + H_i(k+1) \quad (20)$$

适应度函数仍为网络输出端均方误差。

优化步骤如下:

1) 随机初始化粒子群,求出适应度函数值,计算 p_{si}^k, p_g^k 的值进而得出全局速度更新 G_i 的值,再通过 p_{si}^k, p_{ii}^k 求出局部速度更新 L_i 的值;

2) 通过式(19)计算出混合粒子速度更新值;

3) 按照变异概率 Y_1 随机对粒子部分维度标量变异操作,交叉、变异完成后,计算粒子群中的全局最优解 p_g^k 与粒子邻域历史最优解 p_{ii}^k ,重新计算适应度值,若满足最大迭代次数或误差要求后终止。

使用 Matlab 程序模拟,种群规模设为 1000,惯性因子 w 从 0.95 线性递减到 0.35,学习因子 $C_1 = C_2 = 2.2$,约束因子 $r = 0.735$, u 从 0.9 线性递减到 0,邻域采用随机环形法,交叉概率为 0.7,变异概率为 0.001,粒子维度为 30,算法迭代次数为 $k = 70$ 。

优化后将其分别与 DGM(2,1),GM(1,1)模型组合对 P_1, P_5 预测,实验结果显示优化后 $\bar{\delta}_1'' = 0.291, \bar{\omega}_1'' =$

$0.000352, \bar{\delta}_5'' = 0.481, \bar{\omega}_5'' = 0.000397$,小于未优化及退火算法优化后的数据。实验结果表明,该优化方法在较好地提高了预测精度的同时效率更高。

以上 4 组实验结果表明,单项模型优化后再进行组合,在态势要素预测精度上有较大提高,预测值与原始数列的拟合程度更高,在对简单神经网络优化时可选择退火算法,对复杂网络进行优化时宜选择混合粒子群算法。

4 结束语

灰色系统理论可对战场态势要素数据进行关联判断,找出主要和次要因素,为指挥决策者提供参考,组合模型在预测时应针对不同数据特征的态势要素使用适合的模型及组合方式,本文选用了 GM(1,1),DGM(2,1)两个模型,采用串联方式组合预测,又对组合模型优化后重新进行了预测。实验结果表明,其效果明显好于优化前,灰色神经网络理论对于指挥辅助决策技术、信息化战场态势信息分析及预测的研究具有较高价值。

参考文献

- [1] 马亚明,华一新,张亚军. 战场态势信息数据模型研究[J]. 系统仿真学报,2009,21(4):948-953. (MA Y M, HUA Y X, ZHANG Y J. Study on data model of battlefield situation information [J]. Journal of System Simulation, 2009, 21(4):948-953.)
- [2] 李玲玲,单锐,崔红芳. 改进 GM(2,1)模型的 MATLAB 实现及其应用[J]. 数学的实践与认识,2011,41(20):32-38. (LI L L, SHAN R, CUI H F. The application of the improved GM(2,1) grey model using MATLAB [J]. The Practice of Mathematics and Understanding, 2011, 41(20):32-38.)
- [3] 刘丽桑,彭侠夫,周结华. 两种改进的 GM(2,1)模型及其在船舶横摇预报中的应用[J]. 厦门大学学报:自然科学版,2011,50(3):48-53. (LIU L S, PENG X F, ZHOU J H. Two improved model of GM(2,1) and its application in ship rolling forecast [J]. Journal of Xiamen University: Natural Science, 2011, 50(3):48-53.)
- [4] FANG L, WANG C L, MA G Q. A framework for network security situation awareness based on knowledge discovery [C]//Proceedings of the 2010 2nd International Conference on Computer Engineerinand Technology, Piscataway: IEEE, 2010:226-231.
- [5] JAJODIA S, LIU P, SWARUP V, et al. Cyber situational awareness issues and research [M]. Berlin: Springer, 2014: 126-231.