

基于多维灰色模型及神经网络的销售预测^{*}

黄鸿云¹, 刘卫校², 丁佐华³

¹(浙江理工大学 图书馆, 浙江 杭州 310018)

²(浙江理工大学 理学院, 浙江 杭州 310018)

³(浙江理工大学 信息学院, 浙江 杭州 310018)

通讯作者: 丁佐华, E-mail: zouhuading@hotmail.com



摘要: 在时尚销售领域,如服饰、手袋、钱包等,准确的销售预测对企业非常重要.然而由于客户的需求受诸多因素的影响,要做到准确的销售预测一直是一个富有挑战性的问题.基于改进的多维灰色模型(GM(1,N))和神经网络(ANN)提出一种混合模型来预测销量,其中多维灰色模型对销售数据建模,神经网络对误差进行校正.该混合模型的优点是考虑了影响客户需求的因素与销量之间的关系.通过对阿里天猫销售数据来评估混合模型的表现,实验结果表明,所提出的混合模型的预测结果要优于其他几种销售预测模型.

关键词: 销售预测;神经网络;多维灰色模型;混合模型;实验评估

中图法分类号: TP183

中文引用格式: 黄鸿云,刘卫校,丁佐华.基于多维灰色模型及神经网络的销售预测.软件学报,2019,30(4):1031-1045. <http://www.jos.org.cn/1000-9825/5510.htm>

英文引用格式: Huang HY, Liu XW, Ding Z H. Sales forecasting based on multi-dimensional grey model and neural network. Ruan Jian Xue Bao/Journal of Software, 2019,30(4):1031-1045 (in Chinese). <http://www.jos.org.cn/1000-9825/5510.htm>

Sales Forecasting Based on Multi-dimensional Grey Model and Neural Network

HUANG Hong-Yun¹, LIU Wei-Xiao², DING Zuo-Hua³

¹(Library, Zhejiang Sci-Tech University, Hangzhou 310018, China)

²(School of Science, Zhejiang Sci-Tech University, Hangzhou 310018, China)

³(School of Informatics Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: Accurate sales forecasting is important to the fashion enterprise, such as apparel and accessories, handbags, wallets. However, it is a challenging problem since the requirements from consumers can be influenced by many factors. In this paper, the sales are forecasted based on an improved multidimensional grey model (IGM(1,N)) and artificial neural network (ANN), where the multi-dimensional grey model is used to model sales data while the neural network is used to correct the errors. The advantage of the proposed hybrid model is that it considers the relation between the sales and the factors that influence the customer requirements. The performance of the proposed hybrid model is evaluated with sales data from Ali-TianMao, and the experimental results demonstrate that the proposed hybrid model is superior to the existing sales forecasting models.

Key words: sales forecasting; neural network; multi-dimensional grey model; hybrid model; experimental evaluation

准确的销售预测对时尚行业来说意义重大.在时尚销售领域(如服饰、手袋、钱包等),受产品生命周期短、产品设计简单、经济环境和需求不确定性高等诸多因素影响,产品要随潮流变化不断更新以响应市场需求^[1],这会导致产品供应情况变化复杂,直接影响企业运营.因此,亟需寻找有效且准确的预测手段以帮助生产商可以

^{*} 基金项目: 国家自然科学基金(61751210, 61572441)

Foundation item: National Natural Science Foundation of China (61751210, 61572441)

收稿时间: 2017-09-03; 修改时间: 2017-09-30; 采用时间: 2017-11-07

根据预测结果灵活地调整生产计划,提高其对市场需求变化的反应速度,从而获得领先竞争优势和较高的经济利益.然而在零售领域,影响销售业绩的因素很多,如顾客行为、季节变化和节假日、商品广告投入、商家大型促销活动甚至一些经济政策、产业政策等.这些影响因素会大幅度增加产品需求的不确定性,进而给准确预测销售带来巨大的挑战.

目前已有的一些销售预测方法,如基于数学和统计学理论的经典方法^[2-6]、应用人工智能的现代启发式算法^[7-20].这些方法依赖于大量的历史数据、对数据波动敏感,故难以得到准确的预测结果.灰色模型可以在数据量有限的情况下得到较好的预测结果,但是传统的 GM(1,1)^[21-28]只能预测单维时间序列.由于商品的销售情况受到众多因素的影响,现有的销售预测方法都还未将众多因素的影响加入到预测模型中.为此,本文通过对传统的 GM(1,N)^[29-33]方法的改进(以下简称 IGM(1,N))来对受多因素影响的销售数据进行建模,并对 IGM(1,N)预测的残差进行两步的 ANN 预测以提高预测的精度.通过对“天猫”的 5 组数据进行实验,本文提出的混合算法的预测结果要优于 GM(1,1)算法、EELM 算法和 ARIMA 算法等一些常用算法.本文是对我们已有工作^[34,35]的扩展.

本文第 1 节是灰色关联度分析.第 2 节对已有的 GM(1,N)进行改进,得到 IGM(1,N)模型.第 3 节描述数据预处理.第 4 节介绍混合预测模型.第 5 节是实验和分析.第 6 节是相关工作介绍.第 7 节是全文总结.

1 灰色关联度分析

在实际的预测问题中,系统的发展趋势往往是诸多因素共同作用的结果,而且不同因素对系统发展趋势的影响是不同的,快速、有效地预测需要从这些众多的因素中找到对系统发展趋势影响较大的因素,灰色关联分析正是可以帮助找到对系统指标影响较大的因素,灰色关联度分析是灰色系统分析和灰色预测理论的基础^[29,30].在数理统计分析方法中也有许多分析方法可以进行这类分析,如回归分析、方差分析、主成分分析.但这些方法都存在如下缺点.

(1) 样本需服从一定典型的概率分布;(2) 分析需要大量数据作为基础,计算量大;(3) 可能会出现定性结果和量化结果不一致的情况.

对于销售预测领域来说,往往出现数据量有限、数据波动大和噪声大且通常不服从特定的概率分布的情况.采用上述方法难以实现有效预测.而灰色关联分析法对样本数据量没有严格要求,不要求数据具有典型分布规律,其结果与定性结果分析结果比较吻合.故本文采用灰色关联度来评估各个因素对销量的影响程度大小.灰色关联度分析主要分为以下几个步骤.

第 1 步:确定参考数列和比较序列.本文选择销量作为参考序列,记为 $x_0=\{x_0(1),x_0(2),\dots,x_0(n)\}$,选择其他影响因素为比较列,记为

$$x_i=\{x_i(1),x_i(2),\dots,x_i(n)\}, i=1,2,\dots,m \quad (1)$$

第 2 步:无量纲化处理参考序列和比较序列,这里采用初值化的变换方法,变换后的序列记为

$$Y_i=x_i/x_i(1)=(y_i(1),y_i(1),\dots,y_i(n)), i=0,1,2,\dots,m \quad (2)$$

第 3 步:计算灰色关联度,各个比较列与参考列的灰色关联系数如公式(3)所示:

$$\xi_i(k)=\frac{\min_i \min_k |y_0(k)-y_i(k)| + \rho \max_i \max_k |y_0(k)-y_i(k)|}{|y_0(k)-y_i(k)| + \rho \max_i \max_k |y_0(k)-y_i(k)|} \quad (3)$$

式中, $\min_i \min_k |y_0(k)-y_i(k)|$ 称为两级最小差, $\max_i \max_k |y_0(k)-y_i(k)|$ 称为两级最大差; ρ 称为分辨系数,一般取 0.5.根据 $k=1,2,\dots,n$ 处的关联系数,就可以得到参考序列和比较序列的灰色关联度:

$$r_i=\frac{1}{n} \sum_{k=1}^n \xi_i(k) \quad (4)$$

已知阈值 r_0 ,本文取 $r_0=0.60$,提取 $R'=\{r|r_i \geq r_0\}$ 的特性作为建模的变量.

第 4 步:由观察对象的关联序的情况可以得到观察对象的综合评价结果.

2 GM(1,N)及其改进

2.1 GM(1,N)算法

系统的发展往往受到众多因素的影响,将影响因素加入到预测过程中,可以利用 GM(1,N)进行预测,下面介绍 GM(1,N)的主要建模过程^[28,29].

设原始非负序列 $X_1^{(0)} : X_1^{(0)} = \{x_1^{(0)}(1), x_1^{(0)}(2), \dots, x_1^{(0)}(i), \dots, x_1^{(0)}(n)\}$ 为系统特征序列,而

$$\begin{aligned} X_2^{(0)} &= \{x_2^{(0)}(1), x_2^{(0)}(2), \dots, x_2^{(0)}(i), \dots, x_2^{(0)}(n)\}, \\ X_3^{(0)} &= \{x_3^{(0)}(1), x_3^{(0)}(2), \dots, x_3^{(0)}(i), \dots, x_3^{(0)}(n)\}, \\ &\vdots \\ X_N^{(0)} &= \{x_N^{(0)}(1), x_N^{(0)}(2), \dots, x_N^{(0)}(i), \dots, x_N^{(0)}(n)\} \end{aligned}$$

为相关因素序列,对系统特征序列和相关因素序列进行累加生成(AGO),则生成的相应的新的数据序列可以表示为

$$X_i^{(1)} = \left\{ x_i^{(1)}(j) \mid x_i^{(1)}(j) = \sum_{k=1}^j x_i^{(0)}(k), j = 1, 2, \dots, n \right\} \quad (5)$$

其中, $i=1, 2, \dots, N$, 式(5)为 $X_i^{(0)}$ 的 1-AGO 序列,相应的灰色微分方程为

$$\frac{dx_i^{(1)}(t)}{dt} + b_1 x_1^{(1)}(t) = b_2 x_2^{(1)}(t) + b_3 x_3^{(1)}(t) + \dots + b_N x_N^{(1)}(t), t = 1, 2, \dots, n \quad (6)$$

利用最小二乘法对序列参数进行估计得到:

$$[b_1, b_2, \dots, b_n]^T = (B^T B)^{-1} B^T Y_R \quad (7)$$

式(7)中有

$$B = \begin{bmatrix} -\frac{1}{2}(x_1^{(1)}(1) + x_1^{(1)}(2)) & x_2^{(1)}(2) & x_3^{(1)}(2) & \dots & x_N^{(1)}(2) \\ -\frac{1}{2}(x_1^{(1)}(2) + x_1^{(1)}(3)) & x_2^{(1)}(3) & x_3^{(1)}(3) & \dots & x_N^{(1)}(3) \\ \dots & \dots & \dots & \dots & \dots \\ -\frac{1}{2}(x_1^{(1)}(n-1) + x_1^{(1)}(n)) & x_2^{(1)}(n) & x_3^{(1)}(n) & \dots & x_N^{(1)}(n) \end{bmatrix} \quad (8)$$

$$Y_R = [x_1^{(0)}(2), x_1^{(0)}(3), \dots, x_1^{(0)}(n)]^T$$

对累加序列的预测可以表示为

$$\hat{x}_1^{(0)}(t) = \left(\hat{x}_1^{(0)}(1) - \frac{1}{b_1} \sum_{i=2}^n b_i x_i^{(1)}(t) \right) \times e^{b_1(t-1)} + \frac{1}{b_1} \sum_{i=2}^n b_i x_i^{(1)}(t), t = 2, 3, \dots, n + f \quad (9)$$

这里 f 表示要预测的项数.取 $\hat{x}_1^{(0)}(1) = \hat{x}_1^{(1)}(1) = \hat{x}_1^{(1)}(1)$, 还原值为

$$\hat{x}_1^{(0)}(t) = \hat{x}_1^{(1)}(t) - \hat{x}_1^{(1)}(t-1), t = 2, 3, \dots, n + f.$$

2.2 对GM(1,N)的改进

我们对 GM(1,N)算法进行两个方面的改进.一是通过引入临时常数可以解决验证 GM(1,N)所要满足的平滑条件.二是将 GM(1,1)中的控制参数引入到 GM(1,N)中,提高了模型的准确度.改进后的模型称为(IGM(1,N)).下面对这两点具体加以说明.

(1) 在 GM(1,N)的预测过程中往往要求序列满足一定的平滑条件,表示为:

设 $X_1^{(0)} = \{X_1^{(0)}(1), X_1^{(0)}(2), \dots, X_1^{(0)}(i), \dots, X_1^{(0)}(n)\}$ 为系统特征序列,并且假设这个序列为非负序列,对系统特征

序列做 1-AGO 操作,得到 $X_1^{(1)} = \left\{ X_1^{(1)}(j) \mid X_1^{(1)}(j) = \sum_{k=1}^j X_1^{(0)}(k), j=1,2,\dots,n \right\}$, 在执行灰色预测之前, $X_1^{(0)}$ 和 $X_1^{(1)}$ 需要满足一定的平滑和指数平滑条件,表示为式(10)所示:

$$\begin{cases} 0 \leq \rho(k) = \frac{x_1^{(0)}(k)}{x_1^{(1)}(k)} \leq 0.5, & \text{quasi-smoothchecking} \\ 0 \leq \sigma(k) = \frac{x_1^{(1)}(k)}{x_1^{(1)}(k-1)} \leq 1.5, & \text{quasi-exponentialchecking} \end{cases} \quad (10)$$

其中, $k=4,5,\dots,n$ 在 GM(1,N)中对原始特征序列加入因子 c ,使得新序列满足式(10),有

$$\left. \begin{aligned} X_{1S}^{(0)} &= \{ X_{1S}^{(0)}(1), X_{1S}^{(0)}(2), \dots, X_{1S}^{(0)}(i), \dots, X_{1S}^{(0)}(n) \}, \\ X_{1S}^{(0)}(k) &= X_1^{(0)}(k) + c, k=1,2,\dots,n, c \geq 0, \\ X_{1S}^{(1)} &= (X_{1S}^{(1)}(1), X_{1S}^{(1)}(2), \dots, X_{1S}^{(1)}(n)), \\ X_{1S}^{(1)}(k) &= \sum_{i=1}^k X_{1S}^{(0)}(i), k=1,2,\dots,n \end{aligned} \right\} \quad (11)$$

从式(11)可以清楚地发现, $X_{1S}^{(0)} \geq X_1^{(0)}, X_{1S}^{(0)} \geq 0$, 必须找到合适的 c 满足式(10),具体表达形式如下:

$$\begin{cases} 0 \leq \rho_S(k) = \frac{x_{1S}^{(0)}(k)}{x_{1S}^{(1)}(k)} \leq 0.5, & \text{quasi-smoothchecking} \\ 0 \leq \sigma_S(k) = \frac{x_{1S}^{(1)}(k)}{x_{1S}^{(1)}(k-1)} \leq 1.5, & \text{quasi-exponentialchecking} \end{cases} \quad (12)$$

将式(11)带入到式(12)可以得到:

$$\begin{cases} c \geq 0 \\ c \geq \max \left\{ \frac{2x_1^{(0)}(k) - x_1^{(1)}(k-1)}{k-3} \right\}, k=4,5,\dots,n \end{cases} \quad (13)$$

c 只要满足式(13)就可以满足式(12),可以总结出在对序列加上合适的 c 之后,就可以满足式(12)的要求条件.

(2) 把 GM(1,1)模型的控制参数引入到 IGM(1,N)中,对已加入合适影响因子 c 的式(10)中序列 $X_{1S}^{(1)}$ 建立灰微分方程表示为

$$\frac{dx_{1S}^{(1)}(t)}{dt} + b_1 x_{1S}^{(1)}(t) = b_2 x_2^{(1)}(t) + b_2 x_2^{(1)}(t) + \dots + b_n x_n^{(1)}(t) + \mu, t=1,2,\dots,n \quad (14)$$

利用最小二乘法对参数进行估计,得到

$$[b_1, b_2, \dots, b_n, \mu]^T = (B^T B)^{-1} B^T Y_R \quad (15)$$

这里有:

$$B = \begin{bmatrix} -\frac{1}{2}(x_{1S}^{(1)}(1) + x_{1S}^{(1)}(2)) & -\frac{1}{2}(x_2^{(1)}(1) + x_2^{(1)}(2)) & -\frac{1}{2}(x_3^{(1)}(1) + x_3^{(1)}(2)) & \dots & -\frac{1}{2}(x_n^{(1)}(1) + x_n^{(1)}(2)) & 1.0 \\ -\frac{1}{2}(x_{1S}^{(1)}(2) + x_{1S}^{(1)}(3)) & -\frac{1}{2}(x_2^{(1)}(2) + x_2^{(1)}(3)) & -\frac{1}{2}(x_3^{(1)}(2) + x_3^{(1)}(3)) & \dots & -\frac{1}{2}(x_n^{(1)}(2) + x_n^{(1)}(3)) & 1.0 \\ \dots & \dots & \dots & \dots & \dots & 1.0 \\ -\frac{1}{2}(x_{1S}^{(1)}(n-1) + x_{1S}^{(1)}(n)) & -\frac{1}{2}(x_2^{(1)}(n-1) + x_2^{(1)}(n)) & -\frac{1}{2}(x_3^{(1)}(n-1) + x_3^{(1)}(n)) & \dots & -\frac{1}{2}(x_n^{(1)}(n-1) + x_n^{(1)}(n)) & 1.0 \end{bmatrix} \quad (16)$$

$$Y_R = [x_1^{(0)}(2), x_1^{(0)}(3), \dots, x_1^{(0)}(n)]^T \quad (17)$$

在初始条件 $\hat{x}_{1S}^{(0)}(1) = \hat{x}_{1S}^{(1)}(1) = \hat{x}_{1S}^{(0)}(1)$ 下,对累加序列进行预测,可以得到:

$$\hat{x}_{1S}^{(1)}(t) = x_1^{(0)}(1)e^{-h(t-1)} + \frac{1}{2} \times e^{-h(t-1)} \times \left(\sum_{i=2}^N b_i x_i^{(0)}(1) + \mu \right) + \sum_{\tau=2}^{t-1} \left(e^{-h(t-\tau)} \times \left(\sum_{i=2}^N b_i x_i^{(0)}(\tau) + \mu \right) \right) + \frac{1}{2} \times \left(\sum_{i=2}^N b_i x_i^{(0)}(t) + \mu \right) \quad (18)$$

其中, $t=2,3,\dots,n+1,f$ 表示预测的项数. 得到对序列 $X_{1S}^{(0)}$ 的预测还原值表示为

$$\hat{x}_{1S}^{(0)}(t) = \hat{x}_{1S}^{(1)}(t) - \hat{x}_{1S}^{(1)}(t-1), t=2,3,\dots,n+1 \quad (19)$$

则最终对序列 $X_1^{(0)}$ 的每一项的预测表示为

$$\hat{x}_1^{(0)}(t) = \hat{x}_{1S}^{(0)}(t) - c, t=2,3,\dots,n+1 \quad (20)$$

式(20)即为最终的预测结果.

3 数据处理

3.1 对数据的收集

本文的数据来自阿里巴巴-天猫提供的公开数据源,为阿里巴巴在线销售数据,对每个商品包括众多维度,如日期、商品 ID、浏览次数、流量人次、收藏夹人次、加购人次、拍下笔数、拍下金额、拍下件数、成交笔数、成交件数、直通车引导浏览次数、淘宝客引导浏览次数、搜索引导浏览次数、聚划算引导浏览次数、非聚划算支付笔数、非聚划算支付件数等共 31 个维度.

3.2 对数据的预处理

销售预测受诸多因素影响,在预测中使用的原始数据存在数据噪声,即存在许多极端或者异常数据,而数据噪声会导致最终预测结果产生较大偏差.通过数据预处理可以使得监督学习算法获得良好的预测结果.所以,在对销售数据进行预测之前,对数据进行有效的预处理尤为重要.数据预处理的过程主要包括检测和消除异常值、插值缺失值、规范化数据、对数据维度的降低等.

3.2.1 检测和消除数据异常值

异常值数据是数据集中偏离大部分数据的数据.在数据预测过程中,异常值需要剔除并作为缺失值来处理.本文在对很多时尚类历史数据加以分析的基础上得出:当销售数据 S_i 与同类的销售数据序列 S 满足如下条件时:

$$abs(S_i - mean(S)) > n \times std(S) \quad (21)$$

即认定该销售数据 S_i 为异常数据.其中, $mean(S)$ 表示数列 S 的平均值; $std(S)$ 表示数列 S 的标准差; $abs(\cdot)$ 表示数列 S 的绝对值.本文将 n 设置为 3.

3.2.2 插值缺失数据

在大多数真实的原始数据源中,不可避免地会出现数据缺失.缺失数据需要插值处理以保证数据的完整性.本文中利用缺失数据前后相邻的 5 项数据的平均值来代替缺失值.

3.2.3 数据标准化和去标准化

数据标准化可以加快数据运算速度,并且通过数据标准化可将通常量纲不同的数据变化到相同量纲内.本文采用极差法用于标准化的输入和输出.例如,有数据 S_i , 则其标准化过程如下:

$$S'_i = \frac{S_i - \min(S)}{\max(S) - \min(S)} \quad (22)$$

去标准化的过程表示如下:

$$S_i = S'_i \times (\max(S) - \min(S)) + \min(S) \quad (23)$$

3.2.4 数据的降维

在完成对数据进行异常值检测、插值缺失值、数据标准化之后,还有必不可少的一步就是数据的降维.原始数据中,总共包含 31 个维度,在这些维度中有些维度与销量的关联度不大,有些维度之间有很强的关联性,这样的情况都有可能对最终的运算结果产生很大影响.另外,维度过多会影响算法模型的计算精度并加大多维灰

色预测算法和神经网络算法的计算量.所以本文通过灰色关联度方法选择出对销量有较大影响的维度,同时去除彼此之间有较强相关性的维度.最终将这些对销量影响大且因素之间相关度弱的维度加入到预测模型中.

4 混合智能模型与预测




Fig.1 Forecasting process diagram of hybrid intelligent algorithm

图1 混合智能算法的预测过程图

果序列表示为 ε_{ANN} .

第3步:计算出残差序列 ε 与 B-P 反向传播网络预测结果序列 ε_{ANN} 的差值序列 ε_2 , 其中, $\varepsilon_2 = \varepsilon - \varepsilon_{ANN}$. 由于销售序列不仅受到其他相关因素的影响, 销量情况的趋势走向还体现在历史的销量情况的变化上. 因此在这一步, 以历史的销售残差 ε_2 作为影响因素序列对 ε_2 进行 B-P 反向传播网络预测, 预测的结果表示为 ε_{2ANN} .

第4步:将第1步~第3步的预测结果相加, 得到最后的预测结果序列, 表示为 pre_S , 这里, $pre_S = S_{IGM} + \varepsilon_{ANN} + \varepsilon_{2ANN}$.

这里需要指出的是, 虽然以往也有一些算法将线性算法和非线性算法相结合(例如文献[16])对时间序列进行预测, 但是一方面应该注意的是仅考虑一次的残差预测可能是不够的, 比如本文实验步骤中 ε_2 是不应该忽略掉的. 另外, 传统销售预测模型往往只是利用销量序列这样的单变量序列对以后销量进行预测, 销量是多因素影响的结果, 在实际预测过程中应该更多地考虑其他因素的影响, 所以, 考虑单变量因素的影响往往是不够的, 在第5节的实验结果分析部分也可以看到混合智能算法的预测精度要优于利用单变量进行预测的精度.

5 实验与分析

本节将会对利用传统 GM(1,1)算法、EELM 算法、ARIMA 算法、本文中改进的 IGM(1,N)算法和混合智能算法对 5 组真实的销售数据进行预测, 通过对原始销量序列的展示、各种算法对销量序列的预测情况以及利用上文所提到的 MAPE、RMSE、MAE 这 3 种误差评定方式对各种算法的预测结果进行评定.

5.1 实验数据

本文中采用的数据主要来自阿里巴巴-天猫的公开销售数据, 每个数据集对应的产品类型不同, 数据集对应的时间和跨度也各有不同, 具有一定的代表意义. 另外, 本文采用的数据具有多个维度, 文中采用的 5 个数据集的原始销量序列如图 2~图 6 所示. 由图 2~图 6 中展示的销量序列情况来看, 对原始的序列做第 3.2 节阐述的数据预处理工作很有必要. 实验过程还需要进行一定的降维预处理工作才能够将数据加入到预测模型中, 这样可以

本文提出的混合智能算法, 在通过灰色关联分析得到对销量影响较大的因素后, 将这些因素加入 IGM(1,N)算法中对销量进行预测; 对实际值与 IGM(1,N)算法所得到的预测结果的残差结合对销量有影响力的因素利用 B-P 神经网络进行第 1 次的残差预测, 最后一步通过利用对残差预测结果与实际的残差的差值加入相应的时间点得到残差情况作为维度, 对残差的残差进行预测. 混合智能算法的过程如图 1 所示.

下面对整个混合智能算法的预测过程作具体描述.

第 1 步: 这里将待预测的销售序列表示为 S , 利用本文提出的 IGM(1,N)算法, 以销量为系统特征序列, 灰色关联度分析得到的其他因素序列作为相关因素序列, 对销量进行预测. 对销量的预测结果序列表示为 S_{IGM} .

第 2 步: 计算出序列 S 和序列 S_{IGM} 之间的残差 ε , 其中, $\varepsilon = S - S_{IGM}$. 利用 B-P 反向传播网络对序列进行预测, 这里, 在利用 B-P 反向传播网络对序列进行预测的过程中加入了如第 1 步中相同的因素进行分析预测. 将序列 ε 的 B-P 反向传播网络预测结果序列表示为 ε_{ANN} .

提高模型预测的精度和效率.通过灰色关联度分析,在数据集 1~数据集 5 上,浏览次数、收藏数、直通车浏览次数、淘宝客浏览次数、搜索引导浏览次数、聚划算引导的人数、淘宝客浏览次数、搜索引导浏览人数,这些维度和销量都具有较强的关联度,且关联度大于 0.60.故在 5 组实验中都加入了这几个维度.通过对 5 组真实的销售数据集进行预测,分析、比较了几种方法对销售数据预测的性能.




Fig.2 The sale sequence for Dataset 1
图 2 数据集 1 销量序列




Fig.3 The sale sequence for Dataset 2
图 3 数据集 2 销量序列




Fig.4 The sale sequence for Dataset 3
图 4 数据集 3 销量序列




Fig.5 The sale sequence for Dataset 4
图 5 数据集 4 销量序列




Fig.6 The sale sequence for Dataset 5
图 6 数据集 5 销量序列

5.2 实验结果误差的评定

为了评估我们提出的混合智能算法的性能,本文将比较混合智能算法的预测结果和 EELM、ARIMA、GM(1,N)等算法的预测结果.因为可能有很多种预测对象、数据尺度和模型,故没有一种误差评定方法是适应于所有模型的^[33].为了避免只用一种误差评定方式可能带来评定偏差,我们使用 3 种误差评定方式对误差进行评定,这 3 种误差评定方式分别为标准误差(有时也称作均方根误差、RMSE)、平均绝对百分误差(MAPE)和平均绝

对误差(MAE)^[36]这3种误差的表达公式分别如下所示.

标准误差的计算表达式为

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (observed_t - predicted_t)^2} \quad (24)$$

平均绝对百分误差的计算表达式为

$$MAPE = \left(\sum_{t=1}^n \left| \frac{observed_t - predicted_t}{observed_t} \right| \right) \quad (25)$$

平均绝对误差的计算表达式为

$$MAE = \frac{\sum_{t=1}^n |observed_t - predicted_t|}{n} \quad (26)$$

其中, $observed_t$ 表示观测到的第 t 项值; $predicted_t$ 表示预测的第 t 项的值.

5.3 对数据集1的预测

对数据集1的销量序列进行预处理后得到销量序列,如图7所示,这组实验中,共有440条数据.图8所示为利用GM(1,1)算法、EELM算法、ARIMA算法、本文中改进的IGM(1,N)算法和混合智能算法对图5所示虚线以后的20天销量数据进行预测得到的结果.




Fig.7 The sale sequence after pre-processed Dataset 1
图7 数据集1预处理后销量序列图

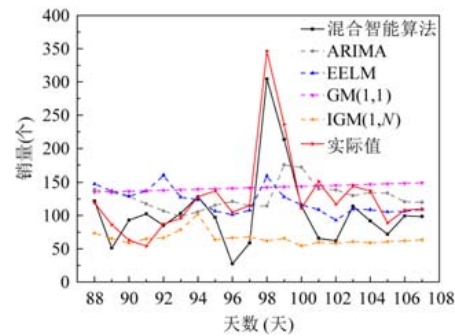


Fig.8 The comparison of algorithms on Dataset 1
图8 各种算法对数据集1的销量预测表现对比

图8可以看出,混合智能算法对销量数据的预测与实际销量情况最贴近,且与实际销量的趋势走向更加一致.同样可以发现,GM(1,1)和IGM(1,N)对销量的预测结果虽然在一个相对稳定的误差范围内,但这两种算法与实际销量偏离较大.EELM算法和ARIMA算法对销量预测的走向预测要劣于混合智能算法.

表1为各种算法对数据集1的销量进行预测的3种误差评定方式的误差比较.表中加黑字体部分表示各种预测算法预测结果利用一种误差评判方法进行评判的误差最小值.

Table 1 The forecasting performance of different algorithm in Dataset 1

表1 各种算法在数据集1的表现比较

	混合智能算法	ARIMA	EELM	GM(1,1)	IGM(1,N)
MAPE(%)	28.1	28.0	33.7	41.0	41.5
RMSE	39.6	61.9	60.6	63.4	88.36
MAE	31.0	37.5	41.3	45.4	62.4

从表1可以看出,混合智能算法对数据集1的预测表现要优于其他几种模型.混合智能算法的MAPE为28.1%,与MAPE最小的ARIMA算法的28%很相近,但是混合智能算法对数据集1的预测RMSE和MAE误差要小于其他模型很多.通过对这3种误差评定方法的比对可以得到,混合智能算法在数据集1上对销量的预测表现最好.

结合图 8 和表 1,可以总结出混合智能算法在数据集 1 上的表现要优于其他几种算法。

5.4 对数据集2的预测

对数据集 2 的销量序列进行预处理后得到销量序列如图 9 所示,这组实验中,共有 248 条数据,图 10 所示为利用 GM(1,1)算法、EELM 算法、ARIMA 算法、IGM(1,N)算法和混合智能算法对图 9 中虚线以后的 20 条销量数据进行预测得到的结果。

由图 10 可以发现,ARIMA、GM(1,1)、IGM(1,N)这 3 种算法对数据集 2 销量的预测结果都处在一个相对稳定的范围内,但与实际的销量之间都存在一定的偏差,EELM 算法的预测值与实际值偏差较大,混合智能算法可以很好地预测销量情况,与实际销量的偏差较小。




Fig.9 The sale sequence for pre-processed Dataset 2
图 9 数据集 2 预处理后销量序列图

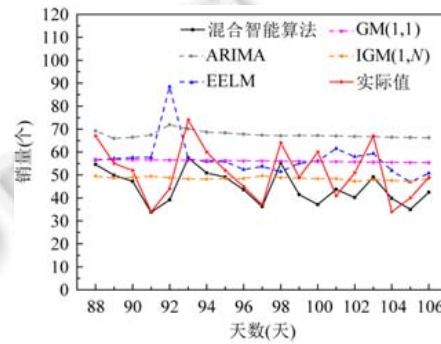


Fig.10 The comparison of algorithms on Dataset 2
图 10 各种算法对数据集 2 的销量预测表现对比

表 2 为各种算法对数据集 2 的销量进行预测的 3 种误差评定方式的误差比较.表中加黑字体部分表示各种预测算法的预测结果利用一种误差评判方法进行评判的误差最小值。

由表 2 可以发现,IGM(1,N)对数据集 2 的预测误差小于 GM(1,1)的预测误差,说明在数据集 2 上,IGM(1,N)的表现优于 GM(1,1).以 RMSE 为评判标准,EELM 算法的误差为 12.0,要略低于混合智能算法的 12.7.但是,用 MAPE 和 MAE 作为误差评定标准,混合智能算法的预测误差明显小于其他几种预测算法.其中,混合智能算法的预测 MAPE 为 13.8%,MAE 为 7.67.通过这 3 种误差评定方法可以看出,混合智能算法随数据集 2 的销量预测误差变化始终最小。

Table 2 The forecasting performance of different algorithm in dataset 2

表 2 各种算法在数据集 2 的表现比较

	混合智能算法	ARIMA	EELM	GM(1,1)	IGM(1,N)
MAPE(%)	13.8	40.4	24.0	23.6	19.0
RMSE	12.7	19.4	12.0	12.1	12.5
MAE	7.67	16.7	11.57	10.6	9.6

结合图 10 和表 2 可以总结出,混合智能算法的预测结果更加契合数据集 2 的销量情况,并且误差更小,所以混合智能算法在数据集 2 上的表现要优于其他几种算法。

5.5 对数据集3的预测

对数据集 3 的销量序列进行预处理后得到的销量序列如图 11 所示,这组实验中,共有 113 条数据.图 12 所示为利用 GM(1,1)算法、EELM 算法、ARIMA 算法、IGM(1,N)算法和混合智能算法对图 11 中虚线以后的 20 条销量数据进行预测得到的结果。

由图 12 可以看出,相比于 GM(1,1),IGM(1,N)对数据 3 的销量的预测结果更加接近实际销量情况.EELM 和 ARIMA 算法的预测值与实际的销量值都有一定的偏差,混合智能算法对销量的预测最接近实际的销量值。

表 3 为各种算法对数据集 3 的销量进行预测的 3 种误差评定方式的误差比较.表中加黑字体部分表示各种

预测算法的预测结果利用一种误差评判方法进行评判的误差最小值.表 3 中,通过比较 3 种误差评定方式的误差,在数据集 3 销量预测上,算法 GM(1,1)和 IGM(1,N)表现相近;混合智能算法预测 MAPE 为 23%、MAE 为 10.6,相对于其他几种算法,误差最小;其 MAE 为 15.0,与其他几种算法相近.由表 3 中的误差比对结果可以总结出,混合智能算法对数据集 3 的预测要略优于其他几种预测算法.




Fig.11 The sale sequence for pre-processed Dataset 3
图 11 数据集 3 预处理后销量序列图




Fig.12 The comparison of algorithms on Dataset 3
图 12 各种算法对数据集 3 的销量预测表现对比

Table 3 The forecasting performance of different algorithm in Dataset 3

表 3 各种算法在数据集 3 的表现比较					
	混合智能算法	ARIMA	EELM	GM(1,1)	IGM(1,N)
MAPE(%)	23.0	30.0	34.5	24.0	28.3
RMSE	15.0	12.6	13.7	14.4	13.0
MAE	10.6	11.1	12.0	10.6	10.9

总结图 12 和表 3 可以得出,在数据集 3 的销量预测上,混合智能算法的预测表现得要略优于其他几种算法.

5.6 对数据集 4 的预测

对数据集 4 的销量序列进行预处理后得到的销量序列如图 13 所示,这组实验中,共有 171 条数据,图 14 所示为利用 GM(1,1)算法、EELM 算法、ARIMA 算法、本文改进的 IGM(1,N)算法和混合智能算法对图 13 中虚线以后的 20 条销量数据进行预测得到的结果.

图 14 中,GM(1,1)对销量的预测始终保持在一个相对稳定的水平上,与实际销量曲线有较大的偏离,IGM(1,N)相比 GM(1,1),与实际销量曲线更接近,预测效果更好.EELM 预测曲线相比 ARIMA 和混合智能算法,偏离实际销量曲线较大.混合智能算法能够更好地预测数据集 4 的销量走势变化,更接近实际销量曲线.

表 4 为各种算法对数据集 4 的销量进行预测的 3 种误差评定方式的误差比较.表中加黑字体部分表示各种预测算法的预测结果利用一种误差评判方法进行评判的误差最小值.

表 4 中,对数据集 4 的销量预测,IGM(1,N)表现得优于 GM(1,1)算法,混合智能算法和 ARIMA 算法的误差小于另外 3 种算法,混合智能算法的 MAPE 为 27.5%小于 ARIMA 的 34.3%.其他两项误差评定指标值略大于 ARIMA 算法,这是由于智能混合算法对数据集 4 进行预测时,155 天的预测结果与实际值偏差较大,故根据 RMSE 和 MAE 计算公式评估误差时会出现整体误差增大的情况.但从整体上看,绝大多数数据点的预测值均与实际值较为接近,这也表明,采用单一评定误差方式难以准确评估预测算法的预测表现.

Table 4 The forecasting performance of different algorithm in Dataset 4

表 4 各种算法在数据集 4 的表现比较					
	混合智能算法	ARIMA	EELM	GM(1,1)	IGM(1,N)
MAPE(%)	27.5	34.3	41.5	87.3	42.2
RMSE	18.9	13.4	15.8	27.4	31.8
MAE	12.0	11.11	14.3	24.4	22.5

结合图 12 和表 4,混合智能算法和 ARIMA 算法对数据集 4 的销量预测优于另外 3 种算法,混合智能算法

的预测结果更接近于实际的销量曲线,误差相对较小,略优于 ARIMA 算法的预测表现.




Fig.13 The sale sequence for pre-processed Dataset 4
图 13 数据集 4 预处理后销量序列图

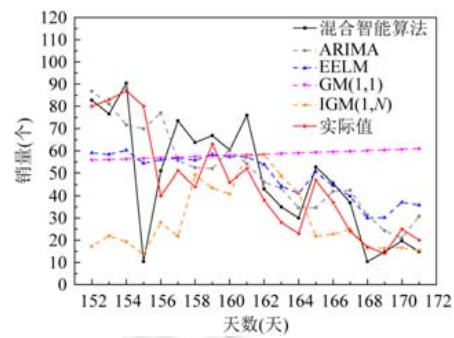


Fig.14 The comparison of algorithms on Dataset 4
图 14 各种算法对数据集 4 的销量预测表现对比

5.7 对数据集5的预测

对数据集 5 的销量序列进行预处理后得到的销量序列如图 15 所示,这组实验中,共有 107 条数据,图 16 所示为利用 GM(1,1)算法、EELM 算法、ARIMA 算法、IGM(1,N)算法和混合智能算法对图 14 中虚线以后的销量数据进行预测得到的结果.

由图 16 可以发现,GM(1,1)算法对数据集 5 的销量预测偏离实际销量的曲线较大,IGM(1,N)对销量的预测表现优于 GM(1,1)算法.EELM 和 ARIMA 的预测曲线与实际销量曲线仍有一定偏离.混合智能算法对数据集 5 的销量预测表现明显优于其他几种算法.




Fig.15 The sale sequence pre-processed Dataset 5
图 15 数据集 5 预处理后销量序列图




Fig.16 The comparison of algorithms on Dataset 5
图 16 各种算法对数据集 5 的销量预测表现对比

表 5 为各种算法对数据集 5 的销量进行预测的 3 种误差评定方式的误差比较.表中加黑字体部分表示各种预测算法的预测结果利用一种误差评判方法进行评判的误差最小值.由表 5 可以发现,混合智能算法的预测 MAPE 略大于 IGM(1,N),总体误差要小于其他算法误差.显然,IGM(1,N)的预测性能优于 GM(1,1).由图 16 和表 5 可以总结出,混合智能算法对数据集 5 的销量预测要明显优于其他几种算法.

Table 5 The forecasting performance of different algorithms on Dataset 5

表 5 各种算法在数据集 5 的表现比较

	混合智能算法	ARIMA	EELM	GM(1,1)	IGM(1,N)
MAPE(%)	23.1	31.2	34.3	66.2	21.7
RMSE	40.7	71.4	58.2	95.5	71.6
MAE	31.8	48.9	48.6	85.9	39.3

总结对数据集 1~数据集 5 的销量预测情况可以发现,混合智能算法对销量的预测表现不仅更稳定,与真实

的销量曲线更接近,预测误差更小,所以可以得出,混合智能算法的预测结果要优于 ARIMA、EELM、GM(1,1)、IGM(1,N)这几种算法的结论。

6 相关工作讨论

目前,销售预测方法主要分为 3 种。

(1) 基于数学和统计学理论的经典方法。例如,国外学者 Box 和 Jenkins^[1]在 1970 年提出自动回归滑动平均预测模型(ARIMA),它能够较好地对时间序列进行线性拟合;之后,Brown^[2]提出了指数平滑法。这种方法的原理是任一期的指数平滑值都是本期实际观察值与前一期指数平滑值的加权平均。1980 年,Sims 等人^[3]提出向量自回归模型,这种模型以强相关性的经济变量构建向量系统。1986 年,Bollerslev^[3]提出 GARCH 模型,这种模型是广义 ARCH 模型,是 ARCH 模型的拓展。2017 年, Van Calste 等人^[3]在 ARIMA 算法的基础上提出了一种利润驱动顺序识别算法 ProfARIMA。该算法通过建立基于利润率、销量和预测准确性的利润方程以实现销售预测。

缺点:现实中,商品销量和影响因素之间的关系相当复杂,销售的数据往往不对称,变化大。指数平滑法、回归算法和 ARIMA 算法都是基于 Box 和 Jenkins 的方法,且这两种方法都是应用线性函数进行时间序列建模,但线性模型很难捕捉部分现实时间序列中一些极端和非对称周期问题,易受数据的不规则性、易变性影响,故难以得到准确的预测结果,所以并不适用于实际销售预测。

(2) 应用人工智能的现代启发式算法。自 1987 年 Lapedes 和 Farber^[4]首次应用神经网络进行预测以来,人工神经网络已被作为一种通用的非线性函数逼近工具,以其良好的非线性特点、灵活而有效的自组织学习方法以及完全分布的存储结构、良好的泛化能力等特点,在预测领域中显示了很大的优势。Cortes 和 Vapnik^[5]等人于 1995 年首先提出了支持向量机算法。这种算法在解决小样本、非线性及高维模式识别中表现出许多特有的优势,并能够推广应用到函数拟合等其他机器学习问题中。Huang^[7]在 2004 年提出了一种极限学习机(简称 EELM)模型,是一种新型的前馈神经网络,这种模型相对于传统的神经网络具有学习速度更快的特点。Sun 等人^[8]介绍了极限学机(ELM)在销售预测中的应用,随后提出扩展的极限学习机(EELM)算法,多次实验表明这种算法相比原始的 ELM 算法更加稳定;Fan 等人利用 Bass 模型和倾向性分析(sentiment analysis)对线上评论进行分析,以提高销售预测的准确率。

缺点:启发式算法通常可以有效解决这些问题,预测结果相对较好。但是,这些算法预测的准确度很大程度上取决于它们的实验目标、应用领域以及是否具有大量可靠、能反映客观事实的历史数据。在历史数据量有限的情况下,很难得到理想的预测结果。

(3) 灰色预模型。Hsu 和 Chen^[18]提出灰色预模型,如 GM(1,1),在数据有限情况下可得到较好的预测结果,但 GM(1,1)不够稳定。谢乃明、刘思峰^[19]提出离散灰色模型(DGM(1,1)),解决了 GM(1,1)不稳定的问题。Xia 和 Wong^[20]提出季节性离散灰色预测模型(SDGM),用于解决时尚产品预测存在的季节性和数据有限问题,但是 SDGM 算法需要至少 3 年的历史数据,对于销售周期快的时尚产品(例如服装)来说,产品的销售周期可能最多两年并且时尚销售领域销售波动很大,利用几年前的销售数据对单个产品的预测也是不太现实的,因而无法进行销售的短期预测。

缺点:无法做到对受多因素影响的销售序列进行有效预测,对异常数据不敏感。

7 结论

本文基于改进的多维灰色模型(GM(1,N))和神经网络(ANN)提出了一种新模型以预测销量。实验结果表明,本文中的混合算法对销售序列的预测要优于 GM(1,1)算法、EELM 算法、ARIMA 算法、IGM(1,N)算法。表现在以下几个方面。其一,结合不同算法对销量序列的预测曲线可以发现,混合智能算法的预测曲线与实际值更加接近;其二,通过 3 种误差评定方式的评定,从几组实验来看,混合智能算法的总体误差要小于其他几种算法;其三,相比于其他几种算法在几组实验中表现得不够稳定,混合智能算法对销售序列的预测效果更加稳定,更适合销售序列的预测。

将来的工作包含两个方面.第一,进一步考虑异常数据对销售的影响.在第 3.2.1 节中,我们对异常数据进行了消除并作为缺省值处理,虽不失为一种处理方法,但不够准确,需要对异常数据重新建模,对其行为进一步加以研究.第二,我们需要更多数据集来验证所提方法的有效性,从而能够真正地在实际中用于对时尚销售的预测.目前,我们针对已有数据进行预测,未来的工作将针对新品种在市场上的销售进行预测.

References:

- [1] Ren S, Chan HL, Ram P. A comparative study on fashion demand forecasting models with multiple sources of uncertainty. *Annals of Operations Research*, 2017,257:335–355.
- [2] Box JEP, Jenkins GM. Time series analysis, forecasting and control. *Journal of the Operational Research Society*, 1971,22(2): 199–201.
- [3] Gardner ES. Exponential smoothing: The state of the art. *Journal of Forecasting*, 1985,4(1):1–28.
- [4] Zhang SQ. Bayesian vector autoregression (BVAR) quarterly forecast model. *The Journal of Quantitative & Technical Economics*, 1998,(9):29–33 (in Chinese with English abstract).
- [5] Bollerslev T. Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 1986,31(3):307–327.
- [6] Van Calster T, Baesens B, Lemahieu W. ProfARIMA: A profit-driven order identification algorithm for ARIMA models in sales forecasting. *Applied Soft Computing*, 2017, 775–785. [doi: 10.1016/j.asoc.2017.02.011]
- [7] Lapedes AS, Farber RF. Nonlinear signal processing using neural networks: Prediction and system modeling. Technical Report, Los Alamos Laboratory, 1987.
- [8] Cortes C, Vapnik VN. Support vector networks. *Machine Learning*, 1995,20(3):273–297.
- [9] Huang GB, Zhu QY, Siew CK. Extreme learning machine: A new learning scheme of feedforward neural networks. In: *Proc. of the Int'l Joint Conf. on Neural Network*. 2004,2(2):985–990.
- [10] Sun ZL, Choi TM, Au KF, *et al.* Sales forecasting using extreme learning machine with applications in fashion retailing. *Decision Support Systems*, 2008,46(1):411–419.
- [11] Adya M, Collopy F. How effective are neural networks at forecasting and prediction? A review and evaluation. *Journal of Forecasting*, 1998,17(5-6):481–495.
- [12] Bodyanshiy Y, Popov S. Neural network approach to forecasting of quasiperiodic financial time series. *European Journal of Operational Research*, 2006,175(3):1357–1366.
- [13] Stubbings P, Virginas B, Owusu G, *et al.* Modular neural networks for recursive collaborative forecasting in the service chain. *Knowledge-Based Systems*, 2008,21(6):450–457.
- [14] Huang K, Yu TH. Ratio-based lengths of intervals to improve fuzzy time series forecasting. *IEEE Trans. on Systems Man & Cybernetics (Part B Cybernetics)*, 2006,36(2):328–40.
- [15] Li S, Cheng Y. Deterministic fuzzy time series model for forecasting enrollments. *Computers & Mathematics with Applications*, 2007,53(12):1904–1920.
- [16] Chang P, Fan CLC. Data clustering and fuzzy neural network for sales forecasting in printed circuit board Industry. In: *Proc. of the IEEE Symp. on Computational Intelligence & Data Mining*. 2007,22(5):107–113.
- [17] Wong W, Alice EB, Chu WC. Adaptive time-variant models for fuzzy-time-series forecasting. *IEEE Trans. on Systems Man & Cybernetics (Part B Cybernetics)*, 2010,40(6):1531–1542.
- [18] Zhang GP. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 2003,50(1):159–175.
- [19] Wong WK, Guo ZX. A hybrid intelligent model for medium-term sales forecasting in fashion retail supply chains using extreme learning machine and harmony search algorithm. *Int'l Journal of Production Economics*, 2010,128(2):614–624.
- [20] Fan ZP, Che YJ, Chen ZY. Product sales forecasting using online reviews and historical sales data: A method combining the Bass model and sentiment analysis. *Journal of Business Research*, 2017,74:90–100.
- [21] Hsu C, Chen C. Applications of improved grey prediction model for power demand forecasting. *Energy Conversion and Management*, 2003,44(14):2241–2249.
- [22] Xie NM, Liu SF. Discrete GM(1,1) and mechanism of grey forecasting model. *Systems Engineering—Theory & Practice*, 2005,(1): 93–99 (in Chinese with English abstract).
- [23] Xia M, Wong WK. A seasonal discrete grey forecasting model for fashion retailing. *Knowledge-Based Systems*, 2014,57(2): 119–126.
- [24] Liu JS. *Enterprise Management Strategy*. Beijing: Tsinghua University Press, 1995 (in Chinese).

- [25] Julong D. Control problem of grey systems. System Control Letter, 1982,1(5):25-32.
- [26] Liu SF, Deng JL. The range suitable for GM(1,1). Systems Engineering—Theory & Practice, 2000,20(5):121-124 (in Chinese with English abstract).
- [27] Deng JL, *et al.* Essential Topics on Grey Systems: Theory and Applications. Beijing: China Ocean Press, 1988 (in Chinese).
- [28] Lin Y, Valencia J. Grey analysis of Colombian migration. In: Proc. of the 2007 IEEE Int'l Conf. on Grey Systems and Intelligent Services. 2007. 15-20.
- [29] Liu SF, Dang YG, Fang ZG. The Theory and Applications of Gray Systems. 3rd ed., Beijing: Science Press, 2004 (in Chinese).
- [30] Xie NM. Research on sequence operators and grey model of prediction [MS. Thesis]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2005. 1-4 (in Chinese with English abstract).
- [31] Dong WH, Liu J, Ding JL. Optimization Techniques and Math Models. Beijing: Tsinghua University Press, 2010. 281-297 (in Chinese).
- [32] Liu SF, Cai H, Yang YJ, Cao Y. Advance in grey incidence analysis modelling. Systems Engineering—Theory & Practice, 2013, 33(8):2042-2046 (in Chinese with English abstract).
- [33] Hyndman RJ, Koehler AB. Another look at measures of forecast accuracy. Monash Econometrics & Business Statistics Working Papers, 2006,22(4):679-688.
- [34] Liu WX. The research on the sales forecasting Based on multi-dimensional grey model and neural network [MS. Thesis]. Hangzhou: Zhejiang Sci-Tech University, 2016 (in Chinese with English abstract).
- [35] Liu WX. The research on the fashion sales forecasting based on a hybrid model with gray prediction model and artificial neural network. Computer Applications, 2016,36(12):3378-3384 (in Chinese with English abstract).
- [36] Wei D, Leung SYS, Kwong CK. A multiobjective optimization-based neural network model for short-term replenishment forecasting in fashion industry. Neurocomputing, 2015,151:342-353.

附中文参考文献:


- [4] 张思奇. 贝叶斯向量自回归(BVAR)季度预测模型. 数量经济技术经济研究, 1998,(9):29-33.
- [22] 谢乃明, 刘思峰. 离散 GM(1,1)模型与灰色预测模型建模机理. 系统工程理论与实践, 2005,(1):93-99.
- [24] 刘冀生. 企业经营战略. 北京: 清华大学出版社, 1995.
- [26] 刘思峰, 邓聚龙. GM(1,1)模型的适用范围. 系统工程理论与实践, 2000,20(5):121-124.
- [27] 邓聚龙. 灰色系统基本方法. 武汉: 华中科技大学出版社, 2005.
- [29] 刘思峰, 党耀国, 方志耕. 灰色系统理论及其应用. 第3版, 北京: 科学出版社, 2004.
- [30] 谢乃明. 序列算子与灰色预测模型研究[硕士学位论文]. 南京: 南京航空航天大学, 2005.1-4.
- [31] 董文华, 刘进, 丁建立, 等. 最优化技术与数学建模. 北京: 清华大学出版社, 2010.281-297.
- [32] 刘思峰, 蔡华, 杨英杰, 曹颖. 灰色关联分析模型研究进展. 系统工程理论与实践, 2013,33(8):2042-2046.
- [34] 刘卫校. 基于多维灰色模型与神经网络的销售预测模型研究[硕士学位论文]. 杭州: 浙江理工大学, 2016.
- [35] 刘卫校. 基于离散灰色预测模型与神经网络混合智能模型的时尚销售预测. 计算机应用, 2016,36(12):3378-3384.



黄鸿云(1977—),女,江苏苏州人,馆员,主要研究领域为软件工程.



丁佐华(1964—),男,博士,教授,博士生导师,CCF高级会员,主要研究领域为软件工程,人工智能.



刘卫校(1990—),女,硕士,主要研究领域为数据挖掘,大数据处理.