

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

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

平均绝对百分误差的计算表达式为

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

平均绝对误差的计算表达式为

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

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.

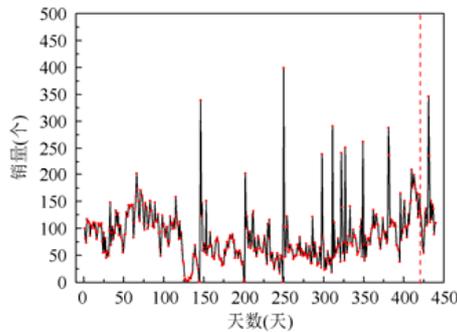


Fig.7 The sale sequence after pre-processed Dataset 1
图 7 数据集 1 预处理后销量序列图

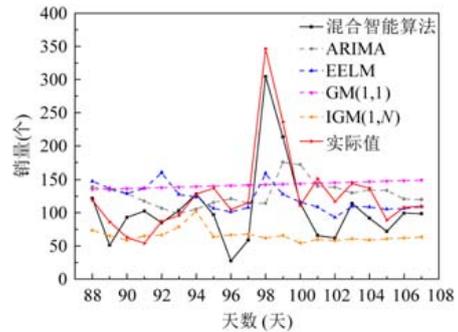


Fig.8 The comparison of algorithms on Dataset 1
图 8 各种算法对数据集 1 的销量预测表现对比

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。

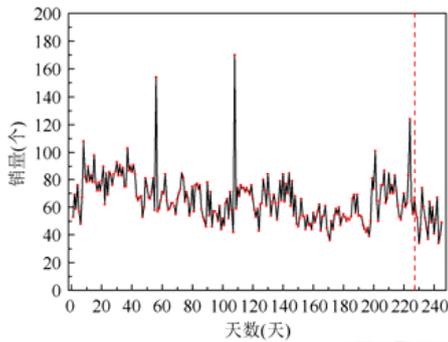


Fig.9 The sale sequence for pre-processed Dataset 2
图 9 数据集 2 预处理后销量序列图

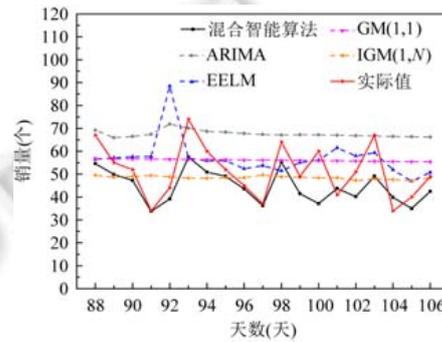


Fig.10 The comparsion of algorithms on Dataset 2
图 10 各种算法对数据集 2 的销量预测表现对比

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.

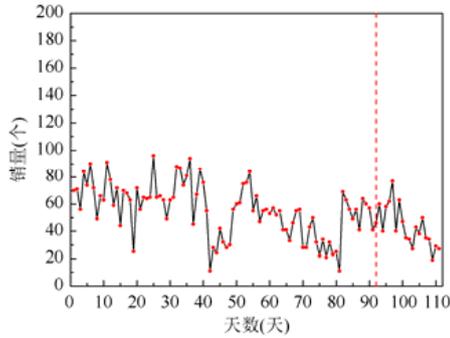


Fig.11 The sale sequence for pre-processed Dataset 3
图 11 数据集 3 预处理后销量序列图

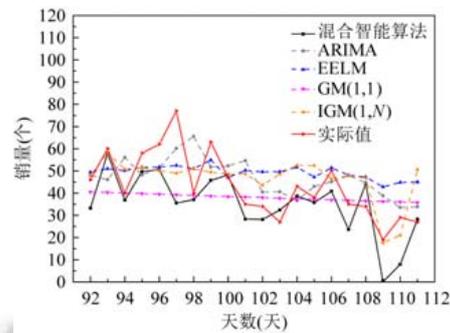


Fig.12 The comparison of algorithms on Dataset 3
图 12 各种算法对数据集 3 的销量预测表现对比

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.

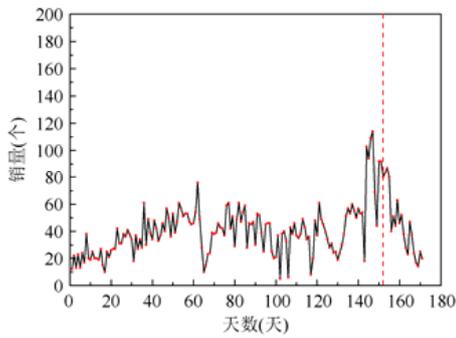


Fig.13 The sale sequence for pre-processed Dataset 4
图 13 数据集 4 预处理后销量序列图

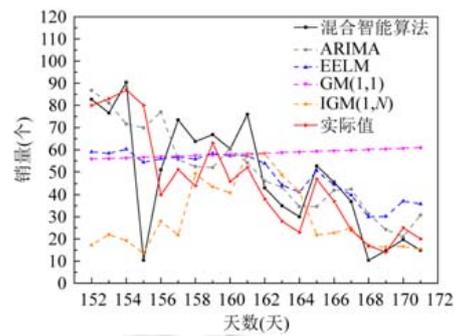


Fig.14 The comparison of algorithms on Dataset 4
图 14 各种算法对数据集 4 的销量预测表现对比

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.

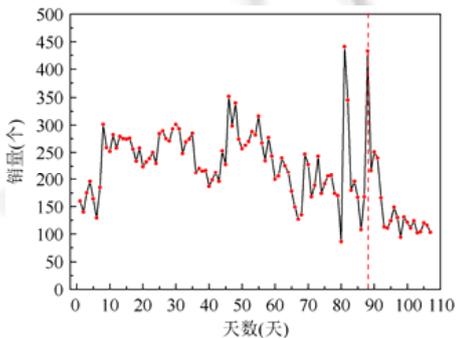


Fig.15 The sale sequence pre-processed Dataset 5
图 15 数据集 5 预处理后销量序列图

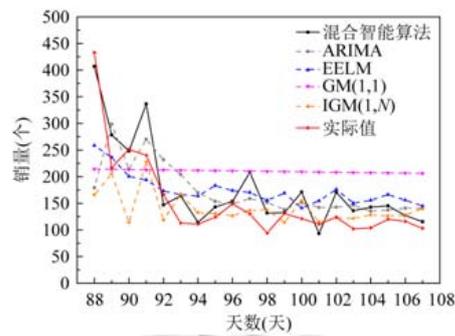


Fig.16 The comparison of algorithms on Dataset 5
图 16 各种算法对数据集 5 的销量预测表现对比

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.