

doi: 10.11918/j.issn.0367-6234.2016.07.004

基于特征合成的周期性备件需求预测方法

林琳, 陈湘芝, 钟诗胜

(哈尔滨工业大学 机电工程学院, 哈尔滨 150001)

摘要: 针对工程机械备件需求预测准确性低的问题, 提出一种新的基于特征合成的周期性维修备件需求预测方法. 定义等间隔备件需求样本集的相似度模型, 采用优化算法确定最优备件需求周期长度, 并利用回归模型建立各周期内的备件需求模型; 提出基于特征合成的模型综合方法, 借鉴物理学中的矢量合成方法, 将多个历史备件周期需求模型特征矢量合成新的特征矢量, 利用新特征矢量还原获得最优的周期预测模型, 该模型综合考虑了各个历史备件周期预测模型, 使获得的备件周期预测模型具有更好的鲁棒性和泛化性. 采用人工数据和矿用圆环链的实际需求数据对该预测模型进行验证, 实验结果表明, 该模型具有良好的稳定性和准确性.

关键词: 需求预测; 维修备件; 特征合成; 周期提取; 周期需求建模

中图分类号: TP301; F272.1

文献标志码: A

文章编号: 0367-6234(2016)07-0027-06

Demand forecasting method for periodic spare parts based on feature synthesis

LIN Lin, CHEN Xiangzhi, ZHONG Shisheng

(School of Mechatronics Engineering, Harbin Institute of Technology, Harbin 150001, China)

Abstract: A novel approach for forecasting the periodic demand of spare parts based on feature synthesis is proposed to solve the problem of inaccurate prediction due to many influencing factors of the spare parts demand for construction machines and the demand cycle hard to be selected. The optimal demand cycle length is obtained with the optimization algorithm by defining a similarity measuring model of the spare parts demand sample sets under equal space, and the demand model for spare parts in every cycle period is built by the regression model. Then, a method is presented to integrate multiple cycle demand models of the spare parts into one according to the vector synthesis method in physics, so the optimal demand forecasting model for the spare parts with periodic pattern is obtained by reduction technology. The model synthetically considers the demand forecasting model for the spare parts in every historical cycle and it is great robust and generalized. The prediction model is verified by simulated datasets and the practical data of the demand of round link chains for mining, and experiment results prove that the model has good stability and accuracy.

Keywords: demand forecasting; spare parts; feature synthesis; period extraction; periodic requirement modeling

备件是大型机械设备正常运作的保障性物资, 必须保证适量且及时的备件供应, 高效的备件库存管理与供应对提高企业的经济效益具有重要意义^[1]. 其中, 备件需求量的确定是备件库存管理的前提. 影响备件需求的原因是多方面的, 除了备件的可靠性之外, 备件的使用、维护方式及维修策略等均可能影响备件的需求量. 受这些复杂关系的影

响, 不同备件的历史需求数据特征差异较大, 需要针对备件的需求模式研究合适的需求预测方法^[2]. 本文研究对象为需求模式呈周期性变化的备件, 即其历史需求时间序列中含有随机性成分和周期性成分. 需求时间序列中含有周期性成分和随机性成分时, 基于时间序列的预测方法一般分为2类, 第1类是使用ARIMA模型^[3], 这样就剔除了历史需求数据中的周期性成分, 从而遗漏了数据中的重要信息^[4]. 第2类是将周期性成分分离出来, 如Holt-Winters模型^[5]以及改进的Holt-Winters模型^[6-7]. 该方法对于初始参数值以及平滑常数的确定仍有一定的困难^[8]. Grubb等^[9]对Holt-Winters模型进行改

收稿日期: 2015-05-21

基金项目: 国家科技支撑计划(2015BAF32B01-4);

国家自然科学基金(U1533202)

作者简介: 林琳(1973—), 女, 教授, 博士生导师;

钟诗胜(1964—), 男, 教授, 博士生导师

通信作者: 林琳, waiwaiyl@163.com

进,通过使预测误差最小来获取最佳的平滑常数. Bermúdez 等^[10]则建立了用于更新季节指数的方程,以此为目标函数,并对平滑常数以及初始值进行优化. Abdesselam 等^[11]将模糊逻辑应用于 Holt-Winters 模型,并用实验证明了方法的可行性. 除此之外,针对周期型备件的需求预测,董笑晓^[12]提出移动平均周期系数法,即采用系数来表征时间序列中的周期性成分. Boylan 等^[13]针对历史需求数据不足这一问题,将 GSI (group seasonal indices) 和 ISI (individual seasonal indices) 方法结合起来用于预测需求. 对具有季节性的间断型需求, Gamberini 等^[14]比较了 Holt-Winters 和 ARIMA 模型的预测精度.

本文提出对备件实际需求数据按其周期长度进行分段,然后对各段进行多项式拟合以提取周期项,为消除随机因素的影响,对各个周期段的多项式函数进行合成得到新的多项式函数,以此来计算下一个周期的需求量预测值.

1 周期长度检测

通常备件的需求数据虽然呈现出一定的周期性,但是其周期性并不是表现为以周期间隔的需求数据相等,而是具有相似的波动形式. 假定时间序列 $X = (x_1, x_2, \dots, x_n)$, 对于时间序列中以周期间隔的两个数据,如果有 $x_{i+T} = x_i + \varepsilon_i$, 其中 ε_i 为独立的随机变量,则说明该时间序列是周期为 T 的隐周期序列^[15]. 为获得隐周期时间序列的周期长度,一般是将时间序列等分成 N 段,分别比较各段时间序列的相似度,如果平均相似度满足一定的阈值,则说明时间序列存在该长度的周期. 因此,为检测时间序列的周期,最重要的是解决如何准确的度量时间序列的相似度这一问题.

1.1 时间序列的相似性度量

在相似性度量的研究中,大部分采用欧式距离来度量两个时间序列的相似性,距离度量值越小,则两个时间序列越相似. 对于两个等长的时间序列 $H = (h_1, h_2, \dots, h_m)$ 和 $L = (l_1, l_2, \dots, l_m)$, H 是目标时间序列, L 是需要进行相似度测量的时间序列,则这两个时间序列之间的欧式距离定义为

$$d(H, L) = \frac{1}{m} \sqrt{\sum_{i=1}^m (h_i - l_i)^2}. \quad (1)$$

但是,式(1)只是表征了两个时间序列在距离上的接近程度,并未体现其动态变化趋势. 两个数据的相似性也表现为它们的整体波动趋势一致,具有一定的相关性,因此可以用相关系数作为相似性度量的另一个量值. 当相关系数 > 0 时,表现为正相关,即 H 上升, L 也上升, H 下降, L 也下降,此时具有

较大的相似度. 当相关系数 < 0 时,表现为负相关,此时,两序列相似度较小. 在计算相似度时,需要同时考虑两时间序列的欧式距离和相关系数. 因此,对两个长度相等的时间序列 $H = (h_1, h_2, \dots, h_m)$ 和 $L = (l_1, l_2, \dots, l_m)$, 其相似性度量函数为

$$f(H, L) = d(H, L) - \rho_{HL}. \quad (2)$$

式中 ρ_{HL} 为表示时间序列 H 和 L 的相关系数.

用式(2)计算两个时间序列的相似度,当 $f(H, L) \leq \alpha$ 时,则认为两个时间序列具有相似性.

1.2 基于相似度的周期长度检测

给定时间序列 $X = (x_1, x_2, \dots, x_n)$, 设序列 $H = (x_i, x_{i+1}, \dots, x_{i+T-1})$ 为原始时间序列中的 T 片段,则序列集合 $\{(x_{1+K*T}, x_{2+K*T}, \dots, x_{(K+1)*T}) \mid K = 0 \sim [n/T]\}$ ($[\bullet]$ 表示取整) 为时间序列 X 的 T 片段集合,计为 X_T . 对于时间序列 $X = (x_1, x_2, \dots, x_n)$, 当时间长度为 T 时,时间序列 X 按照时间长度 T 分段后,该时间序列的 T 片段集合 X_T 的平均相似度为

$$F(T) = \frac{2}{[n/T]([n/T] - 1)} \sum_{H_i, H_j \in X_T} f(H_i, H_j), \quad (3)$$

那么 X 的周期 \bar{T} 的计算公式为

$$\bar{T} = \min \{F(T) \mid T = a \sim b \text{ 且 } F(T) \leq \alpha\}. \quad (4)$$

式中: $a = 1, b = [n/2]$, 阈值 α 为均值或中值的 10% 左右.

对于周期 \bar{T} 的求解,当时间序列比较长时,此时给出的周期长度取值范围比较大,若采用穷举法来试探出周期长度,计算量就比较大,需要给出优化算法来近似求出周期长度. 周期长度的取值在 a 和 b 之间,因此其搜索方向已经确定,当采用可变的步长进行搜索时,能较快地搜索出周期长度的值. 以式(4)为目标函数,则搜索步骤为:

1) 设定步长 h , 在区间 $[a, b]$ 之间以步长 h 进行搜索,即令 $T_n = a + n * h$ (其中 $n = 1, 2, \dots, [(b - a)/h]$), 代入式(3)中并比较 $F(T_n)$ 的大小;

2) 根据目标函数(式(4))选出相对较优的前 m 个时间长度 T_n , 重新标记为 T_1, T_2, \dots, T_m ;

3) 分别以 T_1, T_2, \dots, T_m 为中心, 搜索宽度为中心左右两边各 $h/2$ 的范围, 以步长 $h/4$ 在中心左右两边分别进行搜索, 即令 $T_n = T_m + n * h/4$ (其中 $n \in [-2, 2], n$ 为整数), 代入式(3)中并比较 $F(T_n)$ 的大小;

4) 根据目标函数(式(4))选出相对较优的前 l ($l < m$) 个时间长度 T_n , 重新标记为 T_1', T_2', \dots, T_l' ;

5) 以同样方式进行搜索,直到步长缩减为 1, 根据目标函数(式(4))选出最优的 T 值,即为时间序列的周期长度 \bar{T} .

2 预测模型的建立

由前文得到时间序列的周期长度,则可以将整个时间序列按照其周期长度划分成各个周期段. 各个周期段内的函数解析表达式未知,只是已知其上 m 个数据点 $(x_i, y_i), i \in [1, m]$, 为提取各个周期段内的周期函数,需对已知的各个周期内的数据点进行函数拟合. 对于各个周期段内的历史需求数据,由于各个周期内的备件需求受到的外界因素影响是不一样的,因此,由拟合函数所提取的周期项并不能代表整个时间序列上的周期趋势. 为消除随机因素的影响,可将各个周期段内的拟合函数进行合成,得到一个新的拟合函数,综合所有周期内的需求趋势,以此作为整个时间序列上的周期项表达式.

2.1 多项式函数拟合

各个周期段内的离散数据点比较少,而多项式拟合方法简单有效,应用广泛,本文采用多项式拟合离散需求数据. 设 φ 为所有次数不超过 $n(n \leq m)$ 的多项式构成的函数类,对数据点 $(x_i, y_i)(i \in [1, m])$ 拟合,即求

$$p(x) = \sum_{k=0}^n a_k x^k \in \varphi, (k = 0, 1, \dots, n),$$

使得

$$I = \sum_{i=0}^m [p(x_i) - y_i]^2 = \sum_{i=0}^m \left(\sum_{k=0}^n a_k x_i^k - y_i \right)^2$$

最小.

上述问题的求解最终可转换为求极值的问题,最后可以求解出参数 $a_k(k = 0, 1, \dots, n)$ 的值,得到拟合多项式的表达式:

$$p(x) = a_n x^n + a_{n-1} x^{n-1} + \dots + a_1 x + a_0. \quad (5)$$

2.2 拟合多项式函数的合成

空间中任意多个向量采取两两合成的方法最终可以合成一个向量,由多个函数最终合成为一个函数也可以借鉴向量合成的思想. 对于时间序列中任意两个周期段内的多项式拟合函数,获取函数的特征集合,函数的特征即为能够将函数区分开来的对象,可以利用向量合成的方式将多个函数特征集合成为一个新的特征集合,合成的新特征集合再还原成一个新的多项式拟合函数,这就将多个函数合成转换为对函数特征集合的合成.

2.2.1 多项式函数的特征集合

各周期段内的离散数据点均采用多项式进行拟合,拟合函数的表达式为 $p(x) = \sum_{k=0}^n a_k x^k$, 则各周期段的拟合函数可以认为是以 $x^k(k = 0, 1, \dots, n)$ 为基函数的线性加权求和. 当各个周期段对离散数据点

的拟合采用相同的拟合次数时,可以认为拟合各周期段离散数据点的函数表达式形式相同,区别各个周期段拟合函数的特征量即为基函数的系数,因此可以将基函数的系数视作函数的特征量.

以 $f(x) = \sum_{i=1}^n h_i \bar{x}_i + h_0$ 为参照,式(5)建立了一个 n 维坐标空间中的超平面, x^k 相当于坐标空间中第 i 维坐标 \bar{x}_i , 系数 a_k 相当于坐标值 h_i , 常量 h_0 为平移量. 在表达式(5)中,取系数 a_k 为函数特征,周期段的多项式函数的特征集合为 $\{a_n, a_{n-1}, \dots, a_0\}$. 对各周期段多项式函数的合成可以通过对多项式函数特征集合的合成来实现.

2.2.2 基于特征集合合成的函数合成

对于两个函数的合成过程,以多项式次数为 3 时的两个周期函数为例进行解释,过程如图 1 所示.

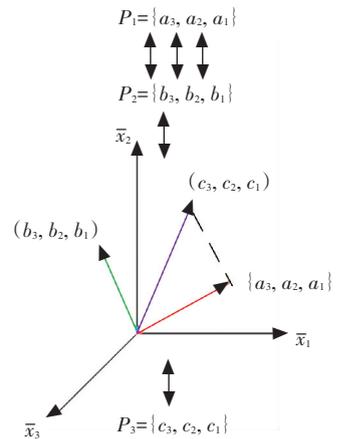


图 1 特征集合合成过程

第 1 个和第 2 个周期段内的数据点经拟合后得到的多项式函数表达式分别为

$$p_1(x) = a_3 x^3 + a_2 x^2 + a_1 x^1 + a_0,$$

$$p_2(x) = b_3 x^3 + b_2 x^2 + b_1 x^1 + b_0.$$

这两个函数的特征集合分别为

$$P_1 = \{a_3, a_2, a_1, a_0\},$$

$$P_2 = \{b_3, b_2, b_1, b_0\}.$$

系数 a_k 和 $b_k(k = 1, 2, 3)$ 相当于坐标空间中第 i 维坐标 \bar{x}_i 上的坐标值,按照向量合成模式,则新合成的特征集合为对应的坐标值之和取平均. 设新的特征集合为

$$P_3 = \{c_3, c_2, c_1, c_0\}, c_k = (a_k + b_k)/2, (k = 0, 1, 2, 3).$$

最后根据合成的新特征集合还原成新的多项式函数为

$$p_3(x) = c_3 x^3 + c_2 x^2 + c_1 x^1 + c_0.$$

考虑到历史需求数据信息对预测未来周期段内的备件需求量的作用是不一样的,对于新合成函数特征值的计算采用加权求和法,而不是求和取平均,即 $c_k = w_1 a_k + w_2 b_k$, 其中 $0 < w_1 < 1, 0 < w_2 < 1$, 且 $w_1 + w_2 = 1$. 权重一般比较难以确定,并且权重的取

值直接影响模型的预测精度,需要慎重选择. 因此,在本文中,以历史需求数据的预测值和实际值的平均相对误差最小为优化目标,建立式(6)所示的优化模型:

$$\begin{aligned} \min ac &= \frac{1}{n} \sum_{i=1}^n \frac{|y_i'(w_1) - y_i|}{y_i}, \\ \text{s.t. } w_1 &\in (0, 1). \end{aligned} \quad (6)$$

式中: y_i 为实际需求数据, $y_i'(w_1)$ 为对应的预测值,采用应用较广的遗传算法求解权重.

3 实验验证

3.1 人工数据验证

试验所采用的数据由 SinSeries 数据产生器产生,该数据产生器为

$$x_i = A \times \sin(t/T) + B + \varepsilon_i, \quad \varepsilon_i \sim N(\mu_i, \sigma_i).$$

式中: μ_i, σ_i 为随机数, $A = 80, T = 3, B = 300, \mu = 0, \sigma = 20$. 截取 x_i 中的 45 个数据作为样本数据. 周期长度的取值范围为 1 ~ 23, 阈值为均值的 10%, 用 1.2 节中的周期长度检测算法计算得到序列的周期长度为 9. 将样本数据分成 5 个数据段, 以前面 4 个周期段的数据建立备件需求预测模型, 用该预测模型计算第 5 个周期段的需求. 当 $n = 6$ 时, 计算得到的第 4 个周期段的需求预测值与实际值的误差最小, 因此选择拟合多项式 $n = 6$. 以第 4 个周期段的预测值的平均相对误差最小为优化函数, 采用遗传算法确定权值为 $w_1 = 0.41, w_2 = 0.29, w_3 = 0.30$. 确定多项式拟合次数和权值后, 则可建立需求预测模型.

对周期段 2, 3, 4 的离散数据进行拟合, 得到各段的拟合多项式函数, 表 1 中第 2~4 行分别是这 3 个周期段拟合多项式函数的特征值. 通过加权合成方式得到新的特征值为 $d_n = 0.41a_n + 0.29b_n + 0.3c_n$, 即表 1 中第 5 行所示数据.

表 1 多项式函数的特征值

n	a_n	b_n	c_n	d_n
6	-0.11	-0.02	-0.07	-0.07
5	3.24	0.62	2.19	2.17
4	-36.45	-7.50	-27.57	-25.39
3	199.08	46.28	170.40	146.17
2	-548.98	-151.45	-535.87	-429.77
1	-742.74	260.52	813.43	624.10
0	-70.78	153.78	-142.89	-27.29

用新合成的特征值还原成多项式函数, 以此作为预测模型用于预测第 5 个周期段的数据, 预测结果如图 2 所示. 实验表明, 预测值与实际值的平均相对误差为 7.4%.

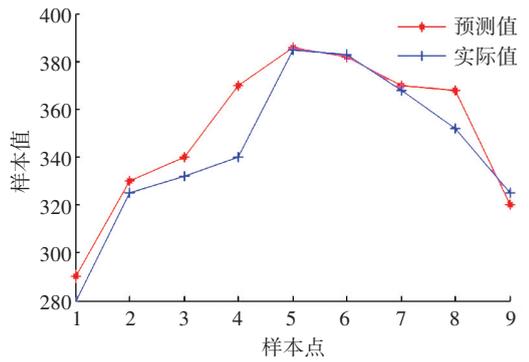


图 2 预测值与实际值比较

3.2 备件需求预测验证

运用该方法对矿用高强度圆环链的需求进行预测, 并与文献[12]中的移动平均周期系数法进行对比分析. 圆环链为采煤机的备件, 实验数据来自文献[16], 为 2007 年 1 月~2010 年 12 月计 4 年的数据.

已知备件历史需求数据, 周期长度 T 的取值范围为 1 - 24, 阈值 α 为备件需求数据均值的 10%, 通过 1.2 节的周期长度检测算法计算得出备件需求时间序列的周期为 12. 按照周期长度将样本数据分成 4 个周期段, 以前面 3 个周期段的数据建立备件需求预测模型, 使用所建立的预测模型计算最后 12 个月的备件需求量, 并和需求实际值进行对比. 在建立周期需求预测模型时, 需要确定的参数为多项式的拟合次数 n , 拟合次数 n 可以通过实验获得. 遍历拟合次数 n 可能的值, 选择使得第 3 个周期段的预测值和实际值的预测误差最小的拟合次数, 以此作为最佳的多项式拟合次数. 表 2 列出了各数值对应的预测误差, 可以看出, 当多项式次数为 $n = 11$ 时, 预测误差最小, 因此, 采用多项式回归模型拟合备件需求数据时, 多项式次数为 $n = 11$.

表 2 各多项式次数对应的预测误差

n	6	7	8	9	10	11	12	13	14	15
误差/%	42.0	28.0	28.5	21.9	10.6	8.4	8.6	8.5	23.00	41.3

对第 1, 2 周期段的离散需求数据分别进行多项式拟合, 提取其特征集合, 集合中的元素分别设为 a_n 和 b_n , 采用加权求和的方式来合成新的特征集合, 即 $d_n = w_1a_n + w_2b_n$, 其中, $0 \leq w_1 \leq 1, 0 \leq w_2 \leq 1, w_1 + w_2 = 1$, 式(6)为优化目标, y_i 为第 3 个周期段的需求数据, 并采用遗传算法求解 w_1 和 w_2 . 设置遗传算法的初始种群为 80, 迭代次数为 80, 适应度函数为式(6), 交叉概率为 0.3, 变异概率为 0.7, 编码方式为浮点数编码、选择方式为比例选择, 交叉方式为线性交叉, 变异方式为扰动变异. 遗传算法求解结果如图 3 所示, 求得 $w_1 = 0$, 则 $w_2 = 1$.

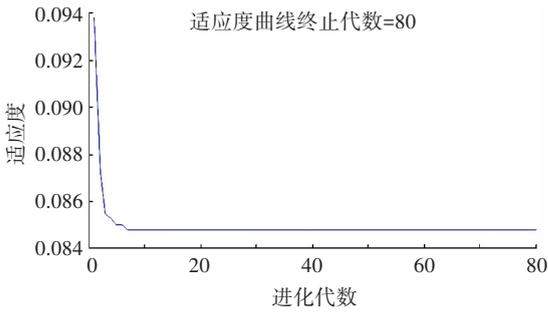


图 3 遗传算法求解结果

以上过程通过对前 3 个周期段的数据分析确定了预测模型的多项式拟合次数 $n = 11$, 权值 $w_1 = 0$, $w_2 = 1$. 当这些参数确定后, 则可以建立周期型需求模式的备件需求预测模型. 对第 2、3 个周期段内的离散数据进行多项式拟合, 提取多项式函数的特征集合, 特征集合中的元素分别设为 a_n' 和 b_n' , 如表 3 所示.

表 3 各周期段多项式函数的特征值表

n	$a_n' \times 10^3$	$b_n' \times 10^2$	$d_n' \times 10^2$
9	0	-0.1	-0.1
8	0.3	1.3	1.3
7	-3.0	-13.8	-13.8
6	22.6	103.3	103.3
5	-117.1	-535.3	-535.3
4	414.7	1 910.8	1 910.8
3	-976.5	-4 564.7	-4 564.7
2	1 439.4	6 845.0	6 745.0
1	-1 176.3	-5 677.3	-5 677.3
0	397.3	1 946.0	1 946.0

采用加权求和的方式来合成新的特征集合, 即 $d_n' = w_1 a_n' + w_2 b_n'$, 故 $d_n' = b_n'$. 合成后的特征值如表 3 中第 4 行所示.

合成得到的新的特征集合还原成新的多项式函数, 此多项式函数即为需求预测模型, 各周期段的加权合成过程如图 4 所示. 应用该模型计算 2010 年 12 个月的备件需求量数据, 预测结果如图 5 所示, 可以看出预测值比较接近实际值.

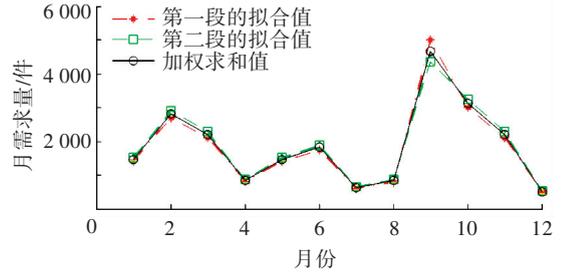


图 4 周期段的加权合成

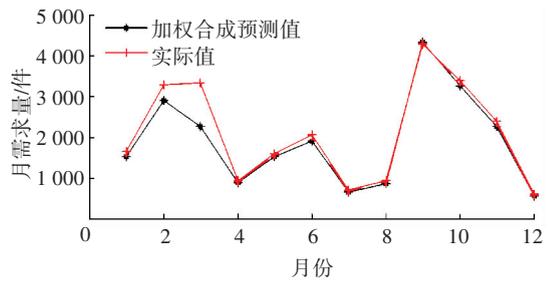


图 5 多项式拟合模型的预测结果

本文所述预测模型与移动平均周期系数法的预测结果比较如表 4 所示.

表 4 两种预测模型结果对比

月份	实际值/件	移动平均周期系数法			多项式拟合		
		备件预测值/件	绝对误差/件	相对误差/%	备件预测值/件	绝对误差/件	相对误差/%
1	1 650	1 456	194	11.8	1 520	130	7.9
2	3 300	2 789	511	15.5	2 900	400	12.1
3	3 350	2 194	1 156	34.5	2 280	1 070	31.9
4	940	850	90	9.6	879	61	6.5
5	1 600	1 462	138	8.6	1 520	80	5.0
6	2 070	1 824	246	11.9	1 900	170	8.2
7	700	631	69	9.9	651	49	7.0
8	940	838	102	10.9	868	72	7.7
9	4 300	4 656	356	8.3	4 342	42	1.0
10	3 400	3 122	278	8.2	3 257	143	4.2
11	2 390	2 187	209	8.7	2 280	110	4.6
12	610	517	93	15.3	542	68	11.2

从表 4 中的数据可以计算出,移动平均周期系数法的预测值与实际值的平均绝对误差为 286.8,平均相对误差为 12.8%. 多项式拟合模型的预测值与实际值的平均绝对误差为 199.6,平均相对误差为 8.9%. 因此可以看出本文提出的预测模型的预测效果更好.

4 结论与展望

1) 针对需求模式为周期型的维修备件需求预测问题,本文提出了一种新的需求预测方法. 用预测模型对人工数据和矿用圆环链的需求量进行预测,实验结果表明,该预测方法具有较高的预测精度.

2) 维修备件的种类非常多,对于不同种类的维修备件,其需求数据的波动形式会有较大区别,有时其周期成分比较弱,可能会被随机成分遮掩,此时,本文所提的预测方法并不适用. 因此,针对不同形式的维修备件需求数据,探讨新的建模方法,仍然是今后需要深入研究的工作.

参考文献

- [1] 王林, 富庆亮, 曾宇容. 基于遗传和差分进化算法的备件库存协同控制模型[J]. 计算机集成制造系统, 2010, 16(10): 2257-2264.
- [2] NEZIH A. Service parts management: demand forecasting and inventory control [M]. New York: Springer Verlag GMBH, 2011: 89-101.
- [3] 王振龙. 时间序列分析[M]. 北京: 中国统计出版社, 2000: 45-50.
- [4] 采峰, 曾凤章. 产品需求量非平稳时序的 ANN-ARMA 预测模型[J]. 北京理工大学学报, 2007, 27(3): 277-282.
- [5] WINTERS P R. Forecasting sales by exponentially weighted moving averages[J]. Management Science, 1960, 6(3): 324-342.
- [6] VINKO L, MARIJA A. Forecasting electricity consumption by using Holt-Winters and seasonal regression models[J]. Economics and Organization, 2011, 8(4): 421-431.
- [7] LEE M H, NOR M E, SUHARTONO, et al. Fuzzy time series: an application to tourism demand forecasting[J]. American Journal of Applied Sciences, 2012, 9(1): 132-140.
- [8] BERMÚDEZ J D, SEGURA J V, VERCHER V E. A decision support system methodology for forecasting of time series based on soft computing[J]. Computational Statistics & Data Analysis, 2006, 51(1): 177-191.
- [9] GRUBB H, MASON A. Long lead-time forecasting of UK air passengers by Holt-Winters methods with damped trend [J]. International Journal of Forecasting, 2001, 17(1): 71-82.
- [10] BERMÚDEZ J D, SEGURA J V, VERCHER V E. Holt-winters forecasting: an alternative formulation applied to UK air passenger data [J]. Journal of Applied Statistics, 2007, 34(9): 1075-1090.
- [11] ABDESSELAM M, KARIM A N M, KAYS H M E, et al. Forecasting demand: development of a fuzzy growth adjusted Holt-Winters approach [J]. Advanced Materials Research, 2014, 903: 402-407.
- [12] 董笑晓. 基于需求预测的轨道交通备件库存控制研究 [D]. 上海: 上海交通大学, 2012: 30-34.
- [13] BOYLAN J E, CHEN H, MOHAMMADIPOUR M, et al. Formation of seasonal groups and application of seasonal indices[J]. Journal of the Operational Research Society, 2014, 65(2): 227-241.
- [14] GAMBERINI R, LOLLI F, RIMINI B, et al. Forecasting of sporadic demand patterns with seasonality and trend components: an empirical comparison between Holt-Winters and (s) ARIMA methods [J/OL]. Mathematical Problems in Engineering, 2010. DOI: 10.1155/2010/579010.
- [15] 李晓光, 宋宝燕, 于戈, 等. 基于小波的时间序列流伪周期检测方法[J]. 软件学报, 2010, 21(9): 2161-2172.
- [16] 李志. 基于支持向量机的兖矿集团备件需求研究[D]. 青岛: 中国海洋大学, 2012: 38.

(编辑 杨波)