

基于灰色模糊推理的油料消耗预测

吴书金, 汪涛, 全琪, 魏振堃, 程日

(陆军勤务学院 油料系, 重庆 401331)

摘要: 为了克服传统预测方法的弊端, 提出了基于灰色模糊推理的油料消耗预测方法; 首先, 构建了基于加权灰色关联分析的案例检索模型, 且运用信息熵理论确定灰色关联系数的权重; 其次, 构建了模糊集理论的案例检索模型, 且运用改进的层次分析法确定特征属性的权重; 最后, 基于上述 2 种检索结果, 运用灰色关联分析方法构建了组合检索模型, 并且基于检索结果对油料消耗进行预测。通过算例仿真, 证明了上述检索方法具有较高的准确度, 验证了预测方法的可行性和实用性。

关键词: 灰色关联分析; 模糊集; 案例检索; 油料; 消耗预测

POL Consumption Forecast Based on Grey Relevance and Fuzzy Reasoning

Wu Shujin, Wang Tao, Quan Qi, Wei Zhenkun, Cheng Ri

(Department of Petroleum Oil and Lubricants, Army Logistics Academy, Chongqing 401331, China)

Abstract: In order to overcome the drawbacks of traditional forecasting methods, a method of POL consumption forecasting based on weighted grey relational analysis and fuzzy case-based reasoning combined retrieval is proposed. Firstly, a case retrieval model based on weighted grey relational analysis is constructed, and the weight of grey relational coefficient is determined by using information entropy theory. Then, a case retrieval model based on fuzzy set theory is constructed, and the weight of feature attributes is determined by improved analytic hierarchy process. Finally, based on the above two retrieval models, a combined retrieval model is constructed by using grey relational analysis method, and the POL consumption is forecasted based on the retrieval results. A numerical example is given to demonstrate high accuracy of the retrieval method and the feasibility and practicability of the prediction method.

Keywords: grey relational analysis; fuzzy sets; case retrieval; petroleum; oil and lubricants; consumption forecast

0 引言

军用油料 (petroleum, oil and lubricants, POL) 作为武器装备的重要动力能源, 在部队遂行军事行动过程中发挥重要作用。油料消耗预测是组织油料保障的基础环节, 科学准确地预测部队油料消耗, 对油料保障任务的完成, 乃至对部队成功遂行军事行动都有比较重要的意义。

目前, 军内外学者的研究主要集中在单一兵种部队消耗油品数量的预测上, 通常采用的预测模型和方法包括神经网络预测模型、灰色预测模型、基于时间序列的预测模型、马尔科夫预测法以及将这些模型和方法中的两种或三种进行组合预测的方法^[1-2]。相对于单一的预测模型, 组合预测模型的预测精度较高。但是由于军事行动的突发性和对抗性, 当影响武器装备油料消耗的偶然性和不确定因素增多, 油料消耗的历史数据的随机波动也随之增大, 呈现出半结构性和非结构性的特征, 其规律性越来越弱, 上述方法预测的准确度就会出现较大波动, 就不再适用了。基于案例推理 (case-based reasoning, CBR) 适用于因果关系难以把握, 且未完全公式化的情况, 在通用问题求解、法律案例分析、设备故障诊断、辅助工程设计、辅助计划

制定等领域得到广泛应用^[3-4]。由于 CBR 在处理非结构性数据上存在较大优势, 后来也被应用到应急物资需求预测领域^[5]。灰色关联分析 (grey relational analysis, GRA) 是衡量系统间各因素之间的关联程度一种方法^[6], 那么在 CBR 的案例检索过程中, 就可以利用灰色关联模型来计算目标案例与源案例之间的相似度。模糊集 (fuzzy sets) 在处理不确定信息方面很强的表达能力^[7], 将模糊集与 CBR 相结合, 在案例检索中处理案例的不精确属性将变得容易。基于此, 本文将建立基于灰色关联和模糊集的组合检索模型对军事行动油料消耗预测进行研究。

1 基于加权灰色关联分析的案例检索模型

CBR 是一种重要的机器学习方法, 它将目前面临的新问题称为目标案例, 将过去解决过的问题称为源案例。案例检索是 CBR 的关键环节, 即从案例库中检索出与目标案例相似度最高的源案例。灰色关联是指事物间的不确定关联, 灰色关联分析是一种通过灰色关联度来分析和确定系统因素间的影响程度的一种方法。其基本思想是: 以因素的数据序列为依据, 根据序列曲线几何形状的接近程度来判断因素间的关联程度。因此, 在案例检索中就可以利用案例间的灰色关联度来确定案例间的相似度^[8]。

本文采用案例的特征属性表示法, 将案例的特征属性组成一个集合, 即 $Case = \{Attribute 1, Attribute 2, \dots, Attribute n\}$ 。设案例库中有 n 个源案例, 每个案例有 m 条

收稿日期: 2019-06-18; 修回日期: 2019-07-19。

基金项目: 军队科研计划项目 (2016JY483)。

作者简介: 吴书金 (1989-), 男, 河南偃师人, 博士研究生, 主要从事油料勤务方向的研究。

特征属性, 目标案例特征属性数值序列 $X_T = (x_T(1), x_T(2), \dots, x_T(m))$, 源案例特征属性数值序列:

$$\begin{aligned} X_1 &= (x_1(1), x_1(2), \dots, x_1(m)) \\ X_2 &= (x_2(1), x_2(2), \dots, x_2(m)) \\ X_i &= (x_i(1), x_i(2), \dots, x_i(m)) \\ X_n &= (x_n(1), x_n(2), \dots, x_n(m)) \end{aligned}$$

那么, 在案例的第 j 条特征属性上, 目标案例与源案例的灰色关联系数可以表示为:

$$\gamma(x_0(j), x_i(j)) = \frac{\min_j \min_i |x_0(j) - x_i(j)| + \xi \max_j \max_i |x_0(j) - x_i(j)|}{|x_0(j) - x_i(j)| + \xi \max_j \max_i |x_0(j) - x_i(j)|} \quad (1)$$

其中: $\xi \in (0, 1)$ 为分辨系数, 通常取 $\xi = 0.5$ 。则目标案例与源案例的灰色关联度可以表示为:

$$\gamma'(X_T, X_i) = \frac{1}{m} \sum_{j=1}^m \gamma(x_T(j), x_i(j)) \quad (2)$$

以上是依据经典的邓氏关联度模型对目标案例和源案例灰色关联度的定义。然而, 在 CBR 中案例的特征属性的重要程度是不同的, 因此特征属性上的灰色关联系数对目标案例与源案例灰色关联度的影响程度也是不同的。设 ω_j 为第 j 条特征属性上目标案例与源案例灰色关联系数的权重, $\sum_{j=1}^m \omega_j = 1 (0 < \omega_j < 1)$ 。目标案例与源案例的加权灰色关联度可以表示为:

$$\gamma(X_T, X_i) = \sum_{j=1}^m \omega_j \gamma(x_T(j), x_i(j)) \quad (3)$$

显然, $\gamma(X_T, X_i)$ 满足灰色关联理论的四个公理, 即规范性、整体性、偶对称性和接近性。

文献 [9] 给出了基于灰熵的灰色关联系数权重确定方法, 但是该方法计算过程较为繁琐, 且当因素序列中点较多时, 求解高阶线性方程组的计算量将会非常大。本文结合案例检索的具体特点给出一种较为简洁的算法。

事实上, 目标案例与源案例在特征属性上的灰色关联系数仅与特征属性有关, 那么可以认为特征属性的权重即为对应的灰色关联系数的权重。根据信息熵理论, 特征属性取值分布差异越大, 即该特征属性蕴含的信息熵越高, 对案例分类的判定作用越大, 该特征属性的权重就越大; 反之, 则权重越小。

1) 归一化特征属性。第 j 条特征属性的归一化方程为:

$$x'_i(j) = \frac{x_i(j) - \min_i x_i(j)}{\max_i x_i(j) - \min_i x_i(j)}, i = 1, 2, \dots, n, j = 1, 2, \dots, m \quad (4)$$

2) 求期望和标准差。第 j 条特征属性的期望 $\mu_j =$

$$\frac{1}{n} \sum_{i=1}^n x'_i(j), \text{ 标准差 } \sigma_j = \sqrt{\frac{1}{n} \sum_{i=1}^n (x'_i(j) - \mu_j)^2}.$$

3) 确定标准差权重。第 j 条特征属性的权重, 即:

$$\omega_j = \frac{\sigma_j}{\sum_{j=1}^m \sigma_j} \quad (5)$$

至此, 得到目标案例与源案例的加权灰色关联度序列 $S_{GRA} = (\gamma(X_T, X_1), \gamma(X_T, X_2), \dots, \gamma(X_T, X_n))$, $\max_i \gamma(X_T, X_i) (i = 1, 2, \dots, n)$ 对应的第 i 个源案例即为与目标案例相似度最高的案例。

2 基于模糊集的案例检索模型

最近相邻法是比较常用的一种案例检索方法, 是一种基于距离的度量方法。在将特征属性数值化后, 并确定特征属性权重, 即可求出目标案例与案例库中源案例特征属性之间的距离。根据距离的大小来确定案例间的相似度, 即距离越小, 相似度越大。但是在实际应用中, 特征属性的类型各异, 存在部分不精确和数值化较为困难的属性^[10]。因此, 单独使用最近相邻法进行案例检索, 其准确度将无法得到保证^[11]。本文将模糊集理论和最近相邻法结合起来, 对案例进行模糊化描述, 用模糊集间的贴进度来表示案例间的相似度, 构建案例检索模型。

2.1 案例的模糊化描述

对目标案例和源案例进行模糊化描述, 确定各个特征属性对案例的隶属度。模糊集和隶属度的定义如下: 设 X 是一个非空经典集合, 映射 $\tilde{A}: X \rightarrow [0, 1]$, 即 $\forall x \in X, x \rightarrow \mu(x)$, 则称 $\tilde{A} = \{ \langle x, \mu(x) \rangle \mid x \in X \}$ 是 X 上的模糊集。 $\mu(x)$ 称为 x 对 \tilde{A} 的隶属度。

CBR 中案例的模糊化描述如下: 案例库中的源案例表示为 $\tilde{c}_i (i = 1, 2, \dots, n)$, 其特征属性集 $f = \{f_1, f_2, \dots, f_m\}$, $\mu_{c_i}(f_j)$ 表示特征属性 $f_j (j = 1, 2, \dots, m)$ 对案例 \tilde{c}_i 的隶属度, 则案例库中案例 \tilde{c}_i 对应的特征向量集为:

$$V_{c_i} = \{ \langle f_1, \mu_{c_i}(f_1) \rangle, \langle f_2, \mu_{c_i}(f_2) \rangle, \dots, \langle f_m, \mu_{c_i}(f_m) \rangle \} \quad (6)$$

目标案例 \tilde{T} 的特征向量集为:

$$V_{\tilde{T}} = \{ \langle f_1, \mu_{\tilde{T}}(f_1) \rangle, \langle f_2, \mu_{\tilde{T}}(f_2) \rangle, \dots, \langle f_m, \mu_{\tilde{T}}(f_m) \rangle \} \quad (7)$$

2.2 模糊集间的贴进度

计算目标案例与源案例之间的贴进度, 用贴进度表示案例间的相似度, 实现目标案例与源案例的模糊匹配。

设模糊集 $\tilde{A}, \tilde{B}, \tilde{C} \in \tilde{\psi}(X)$, $\tilde{\psi}(X)$ 为 X 上所有模糊集的集合。若映射 $N: \tilde{\psi}(X) \times \tilde{\psi}(X) \rightarrow [0, 1]$ 满足以下条件:

$$N(\tilde{A}, \tilde{A}) = 1, N(X, \varphi) = 0;$$

$$N(\tilde{A}, \tilde{B}) = N(\tilde{B}, \tilde{A});$$

若 $\tilde{A} \subseteq \tilde{B} \subseteq \tilde{C}$, 则 $N(\tilde{A}, \tilde{C}) \leq N(\tilde{A}, \tilde{B}) \wedge N(\tilde{B}, \tilde{C})$;

则称 $N(\tilde{A}, \tilde{B})$ 为模糊集 \tilde{A}, \tilde{B} 的贴进度。贴进度的计算公式为:

$$N(\tilde{A}, \tilde{B}) = \frac{\int_X (\tilde{A}(x) \wedge \tilde{B}(x)) dx}{\int_X (\tilde{A}(x) \vee \tilde{B}(x)) dx} \quad (8)$$

若 X 为有限集合 $X \{x_1, x_2, \dots, x_l\}$ 时, 那么:

$$N(\tilde{A}, \tilde{B}) = \frac{\sum_{k=1}^l (\mu_{\tilde{A}}(x_k) \wedge \mu_{\tilde{B}}(x_k))}{\sum_{k=1}^l (\mu_{\tilde{A}}(x_k) \vee \mu_{\tilde{B}}(x_k))} \quad (9)$$

一般情况下，案例各个特征属性的重要程度是不同的，因此要赋予各个特征属性不同的权重。设特征属性 f_1, f_2, \dots, f_m 的权重分别为 $\lambda_1, \lambda_2, \dots, \lambda_m$ ，且满足 $\sum_{j=1}^m \lambda_j = 1, j = 1, 2, \dots, m$ ，则模糊集 \tilde{A}, \tilde{B} 的贴程度应表示为：

$$N(\tilde{A}, \tilde{B}) = \frac{\sum_{j=1}^m \lambda_j (\mu_{\tilde{A}}(f_j) \wedge \mu_{\tilde{B}}(f_j))}{\sum_{j=1}^m \lambda_j (\mu_{\tilde{A}}(f_j) \vee \mu_{\tilde{B}}(f_j))} \quad (10)$$

2.3 特征属性的权重。

本文引入改进的层次分析法 (analytic hierarchy process, AHP) 方法，其具体步骤如下：

1) 通过专家打分法得到特征属性权重的判断矩阵：

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1j} & \dots & a_{1m} \\ a_{21} & a_{22} & \dots & a_{2j} & \dots & a_{2m} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ a_{i1} & a_{i2} & \dots & a_{ij} & \dots & a_{im} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ a_{m1} & a_{m2} & \dots & a_{mj} & \dots & a_{mm} \end{bmatrix},$$

其中： $a_{ij} = \begin{cases} 1 & i \text{ 比 } j \text{ 重要} \\ 0 & i \text{ 和 } j \text{ 同等重要} \\ -1 & j \text{ 比 } i \text{ 重要} \end{cases}$

2) 计算判断矩阵 \mathbf{A} 的最优传递矩阵 \mathbf{B} ，其元素 $b_{ij} =$

$$\frac{1}{m} \sum_{k=1}^m (a_{ik} + a_{kj});$$

3) 将最优传递矩阵 \mathbf{B} 转换为一致性矩阵 \mathbf{C} ，其元素 $c_{ij} = e^{b_{ij}}$ ；

4) 计算出一致性矩阵 \mathbf{C} 的特征值，最大特征值所对应的特征向量即为特征属性的权值向量。

2.4 案例间的相似度

计算案例间的相似度，求得相似度最高的源案例。目标案例 \tilde{T} 与源案例 \tilde{c}_i 的相似度可以表示为：

$$N(\tilde{T}, \tilde{c}_i) = \frac{\sum_{j=1}^m \lambda_j (\mu_{\tilde{T}}(f_j) \wedge \mu_{\tilde{c}_i}(f_j))}{\sum_{j=1}^m \lambda_j (\mu_{\tilde{T}}(f_j) \vee \mu_{\tilde{c}_i}(f_j))}, \quad i = 1, 2, \dots, n, j = 1, 2, \dots, m \quad (11)$$

至此，得到目标案例与源案例的相似度序列 $S_{FS} = (N(\tilde{T}, \tilde{c}_1), N(\tilde{T}, \tilde{c}_2), \dots, N(\tilde{T}, \tilde{c}_n))$ ， $\max_i N(\tilde{T}, \tilde{c}_i)$ ($i = 1, 2, \dots, n$) 对应的第 i 个源案例即为与目标案例相似度最高的案例。

3 组合检索模型和油料消耗预测模型

加权灰色关联分析检索模型完全以影响案例灰色关联度的客观因素为基础，而模糊案例检索模型在客观数据的

基础上，引入了相当部分的主观因素，即专家知识和经验。军事行动油料消耗受到较多不确定因素的影响，因此专家知识和经验在油料消耗预测中发挥着一定因素。所以，单纯以客观因素确定灰色关联度，难免会有所偏差；相反，引入过多的主观因素，相似度的准确度也会出现较大波动。本文尝试将两种模型进行组合，充分利用两者的优点，弱化两者的缺点，即将加权灰色关联度和相似度进行赋权组合，得到一个新的表征参数，即组合相似度。设组合相似度序列为 S_{COM} 。

将 S_{FS} 归一化到 S_{GRA} 水平，得到新的相似度序列 S'_{FS} ， S'_{FS} 的元素：

$$S'_{FSi} = (\max_i \gamma(X_T, X_i) - \min_i \gamma(X_T, X_i)) \cdot \frac{N(\tilde{T}, \tilde{c}_i) - \min_i N(\tilde{T}, \tilde{c}_i)}{\max_i N(\tilde{T}, \tilde{c}_i) - \min_i N(\tilde{T}, \tilde{c}_i)} + \min_i \gamma(X_T, X_i) \quad i = 1, 2, \dots, n \quad (12)$$

令最优序列 S_{MAX} 的元素：

$$S_{MAXi} = \max(\gamma(X_T, X_i), N(\tilde{T}, \tilde{c}_i)), i = 1, 2, \dots, n \quad (13)$$

式 (13) 表示取加权灰色关联度和相似度中的较大值作为 S_{MAX} 的元素。

依据式 (2) 可以分别求得序列 S_{GRA}, S'_{FS} 与 S_{MAX} 的灰色关联度 $\gamma'(S_{MAX}, S_{GRA})$ 、 $\gamma'(S_{MAX}, S'_{FS})$ ，则组合相似度序列 S_{COM} 的元素：

$$S_{COMi} = \frac{\gamma'(S_{MAX}, S_{GRA})}{\gamma'(S_{MAX}, S_{GRA}) + \gamma'(S_{MAX}, S'_{FS})} \gamma(X_T, X_i) + \frac{\gamma'(S_{MAX}, S'_{FS})}{\gamma'(S_{MAX}, S_{GRA}) + \gamma'(S_{MAX}, S'_{FS})} N(\tilde{T}, \tilde{c}_i) \quad i = 1, 2, \dots, n \quad (14)$$

式 (14) 中 S_{COMi} 表示目标案例与第 i 个源案例的组合相似度， $\max_i S_{COMi}$ ($i = 1, 2, \dots, n$) 对应的第 i 个源案例即为与目标案例组合相似度最高的案例。

综合基于加权灰色关联分析的检索模型、基于模糊集的检索模型和组合检索模型的检索结果，可以确定与目标案例相似度最高的源案例，进而求出目标案例的油料消耗。设最佳相似案例的油料消耗量为 φ_h ，关键特征属性值为 R_h ，目标案例的关键特征属性值为 R_T ，那么根据相似性原理，目标案例的油料消耗量为：

$$\varphi_T = \frac{R_T}{R_h} \varphi_h \quad (15)$$

基于加权灰色关联分析和模糊案例推理组合检索的油料消耗预测方法的基本流程图如图 1 所示。其中，最优相似案例即为与目标案例相似度最高的源案例。

4 算例仿真

军事行动油料消耗案例的特征属性由影响油料消耗的各项因素构成，如表 1 所示。其中，行动样式为无序枚举型属性值，地理环境和用油装备使用强度为有序枚举型属性值，持续时间、基数量、油料战损率以及油料自然损耗

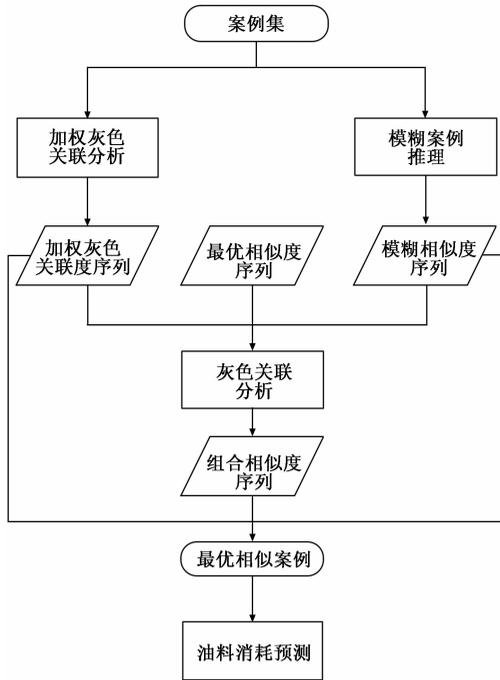


图 1 油料消耗预测流程图

率为数字型属性值。

表 1 军事行动油料消耗案例特征属性

编码	特征属性	属性取值
1	行动样式	跨区机动(0)、进攻作战演习(1)、防御作战演习(2)、非战争军事行动(3)
2	地理环境	山地(1)、高原(2)、丘陵(3)、平原(4)
3	持续时间	行动持续时间(h)
4	基数量	全部用油装备加满油的总吨位(t)
5	用油装备使用强度	高(1)、中(2)、低(3)
6	油料战损率	战损率(%)
7	油料自然损耗率	自然损耗率(%)

现以 XX 战区陆军第 XX 集团军某旅奉命赴 XXX 训练基地参加进攻作战演习的油料保障为目标案例, 进行算例仿真。设旅级部队油料保障案例库中有 5 个源案例, 分别记为 $\tilde{c}_1, \tilde{c}_2, \tilde{c}_3, \tilde{c}_4, \tilde{c}_5$, 每个案例用 7 条特征属性表示, 分别记为 $f_1, f_2, f_3, f_4, f_5, f_6, f_7$ 。目标案例 \tilde{T} 与源案例的特征属性值如表 2 所示。

表 2 案例的特征属性值

案例	f_1	f_2	f_3	f_4	f_5	f_6	f_7	消耗量(t)
\tilde{c}_1	1	4	128	180	1	9.3	0.8	410.34
\tilde{c}_2	1	2	144	122	1	7.9	0.5	350.90
\tilde{c}_3	2	3	96	156	2	8.1	0.7	299.06
\tilde{c}_4	1	4	112	152	1	8.3	0.7	340.02
\tilde{c}_5	0	4	72	176	3	0	0.8	252.98
\tilde{T}	1	3	108	158	1	7.7	0.7	

具有丰富的旅级部队油料保障经验的专业技术人员和指挥决策人员, 对案例的特征属性进行处理, 并且构造合

适的隶属度函数, 得到目标案例和源案例特征属性的模糊矩阵, 如表 3 所示。这是求解相似度序列的基础。

表 3 特征属性对案例的隶属度

案例	f_1	f_2	f_3	f_4	f_5	f_6	f_7
\tilde{c}_1	0.90	0.60	0.90	0.40	0.75	0.50	0.10
\tilde{c}_2	0.85	0.80	0.95	0.20	0.70	0.40	0.05
\tilde{c}_3	0.70	0.65	0.70	0.30	0.55	0.45	0.10
\tilde{c}_4	0.90	0.55	0.80	0.30	0.70	0.45	0.10
\tilde{c}_5	0.50	0.60	0.65	0.35	0.40	0.00	0.10
\tilde{T}	0.85	0.70	0.75	0.30	0.65	0.35	0.10

4.1 案例组合检索

(1) 求解加权灰色关联度序列。对于无序枚举型特征属性, 在计算灰色关联系数时, 属性值相同时, 灰色关联系数为 1; 不同时, 系数为 0。对于有序枚举型特征属性, 按照处理数字型特征属性的方式进行处理, 按照上文给出的方法求解灰色关联系数。依据式 (1)、(3)、(5) 以及表 2, 可得灰色关联度序列:

$$S_{GRA} = (0.6598, 0.6312, 0.7545, 0.8593, 0.3595)。$$

(2) 求解相似度序列。依据改进的 AHP、式 (11) 以及表 3, 可得相似度序列:

$$S_{FS} = (0.8341, 0.8471, 0.8588, 0.9048, 0.6942)。$$

(3) 求解组合相似度序列。依据式 (12)、(13)、(14) 以及加权灰色关联度序列和相似度序列的结果, 可得归一化后的相似度序列和组合相似度分别为:

$$S'_{FS} = (0.6914, 0.7224, 0.7501, 0.8593, 0.3595),$$

$$S_{COM} = (0.6770, 0.6806, 0.7521, 0.8593, 0.3595)。$$

将序列 S_{GRA} 、 S_{FS} 、 S'_{FS} 和 S_{COM} 绘于图 1 中, 分析图 1 可以得到以下结论: 由于采用了不同的检索方法, 数据的量纲存在差异, S_{GRA} 和 S_{FS} 序列在各元素的量值上存在较大的差别, 所以要将 S_{FS} 归一化到 S_{GRA} 水平, 两种检索模型的结果才有可比性; 3 种检索模型的检索结果基本趋于一致, 即案例 4 与目标案例的相似度最大, 同时也存在差异, 即在加权灰色关联度检索模型中, 案例 1 与目标案例的相似度要高于案例 2, 在模糊案例检索模型中, 案例 2 与目标案例的相似度要高于案例 1, 而在组合检索模型中, 案例 1、2 与目标案例的相似度基本一致; 组合检索模型的检索结果对另外两种检索模型的检索结果进行了综合。

4.2 油料消耗量预测

上文求得案例 4 与目标案例的相似度最高, 选取基数量作为军事行动油料消耗的关键特征属性, 由表 2 可得, 案例 4 的油料消耗量 $\varphi_4 = 340.02 \text{ t}$, 基数量 $R_4 = 152 \text{ t}$, 目标案例的基数量 $R_T = 158 \text{ t}$, 那么, 依据式 (15) 可得目标案例的油料消耗量

$$\varphi_T = 353.44 \text{ t}。$$

这里预测的是军事用油装备主油的总消耗量, 如果需要预测主油中各油品以及附油的消耗量, 依据此法也可求得。

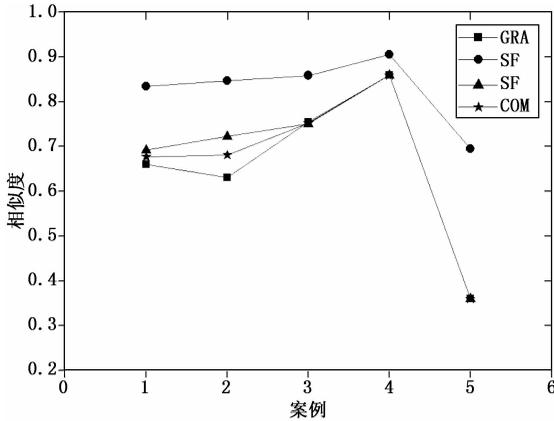


图 2 案例检索结果对比

4.3 预测结果的对比

为了方便对比,将神经网络、灰色理论、时间序列、灰色神经网络、时间序列和灰色理论等预测方法与本文预测方法的准确率,共同列于表 4 中。

表 4 预测准确率的对比

预测方法	准确率(%)
神经网络	66.71
灰色理论	79.22
时间序列	81.46
灰色神经网络	76.55
时间序列和灰色理论	87.37
灰色关联和模糊推理	91.33

通过对比和分析,可以得出结论:基于灰色关联和模糊推理的预测方法准确率要更高;在传统预测算法中,组合预测算法准确率比单一算法要高;传统预测算法准确率的波动性较大。这主要是由于算例中的历史数据偏少,数据的结构性特征减弱,随机性增强,有些算法如果能够获得数据的结构性特征,就表现出较高的准确率;反之,准确率就很低。

5 结论

灰色关联分析和模糊集理论在处理受不确定因素影响的问题上都存在着一定的优势。基于加权灰色关联分析的案例检索模型,在客观数据的基础上,以案例间的加权灰色关联度为依据进行案例检索。基于模糊集的案例检索模

型,在客观数据以及专家知识和经验的基础上,以案例间的模糊相似度为依据进行案例检索。为了充分利用上述 2 种检索模型的优点,依据上述 2 种检索模型的检索结果,运用灰色关联分析等方法,构建了组合检索模型。综合 3 种检索结果,得到与目标案例相似度最高的源案例,再运用油料消耗预测模型,最终得到目标案例的油料消耗量。上述预测方法,充分利用客观数据以及专家知识和经验,3 个检索结果相互印证,提高了案例检索的精度,保证了油料消耗预测结果的准确度。专家知识和经验等主观因素引入对提高检索结果的可靠性有一定帮助,但如何控制主观因素的准确度,以及客观因素与主观因素的比例是今后值得研究的问题。

参考文献:

[1] 夏秀峰,刘权羲. 基于灰色神经网络的装甲部队油料消耗预测[J]. 火力与指挥控制, 2014, 39 (9): 91-95.

[2] 张敬祎,练 萌,龚 杰. 基于时间序列与灰色理论的油料组合预测方法[J]. 兵器装备工程学报, 2018, 39 (1): 132-135.

[3] 耿志强,景邵星,白 菊,等. 基于 MWSPCA-CBR 的智能预警方法研究及其在石化工业中的应用[J]. 化工学报, 2019, 70 (2): 152-160.

[4] 郭 渊,周敬勇. 集成本体和 CBR 的数据挖掘建模技术及其在工艺规划中应用研究[J]. 机械科学与技术, 2017, 36 (4): 579-585.

[5] Fdez-Riverola F, Corchado J M. CBR based system for forecasting red tides[J]. Knowledge-Based Systems, 2003, 16 (5-6): 321-328.

[6] 邓聚龙. 灰理论基础[M]. 武汉: 华中科技大学出版社, 2002.

[7] Atanassov K. Intuitionistic fuzzy sets[J]. Fuzzy Sets and Systems, 1986, 20 (2): 87-96.

[8] 陶维成,党耀国. 基于灰色关联聚类的协同过滤推荐算法[J]. 运筹与管理, 2018, 27 (1): 84-88.

[9] 王正新,党耀国,曹明霞. 基于灰熵优化的加权灰色关联度[J]. 系统工程与电子技术, 2010, 32 (4): 774-776.

[10] Liu W, Hu G, Li J. Emergency resources demand prediction using case-based reasoning[J]. Safety Science, 2012, 50 (3): 530-534.

[11] 田振浩,邢清华,李龙跃. 基于混合相似度的反导作战案例检索方法[J]. 装甲兵工程学院学报, 2016, 30 (6): 55-59.

Health Management Applications of the SSME Real-time Vibration Monitoring System[R]. AIAA, 2000.

[12] 李艳军. 新一代大推力液体火箭发动机故障检测与诊断关键技术研究[D]. 长沙: 国防科学技术大学, 2014.

[13] 吴建军. 液体火箭发动机故障检测诊断理论与方法: Theory and method of fault detection and diagnosis for liquid-propellant rocket engines[M]. 北京: 国防工业出版社, 2013.

[14] 陈 果. 基于遗传算法的 ARMA 模型定阶新技术[J]. 机械工程学报, 2005 (1): 41-45.

[15] 杨叔子,吴 雅. 时间序列分析的工程应用[M]. 武汉: 武汉华中理工大学出版社, 1991.

(上接第 7 页)

[8] Duyar A, Merrill W. Fault diagnosis for the Space Shuttle main engine[J]. Journal of Guidance Control & Dynamics, 1992, 15 (2): 384-389.

[9] Williams R B, Parlos A G. Adaptive State Filtering for Space Shuttle Main Engine Turbine Health Monitoring[J]. Journal of Spacecraft and Rockets, 2003, 40 (1): 101-109.

[10] Lee G. A, Lunde K. J, Williams R. Air testing of an SSME turbopump using rapid prototyping technology[A]. 30th AIAA/ASME/SAE/ASEE Joint Propulsion Conference[C]. 1994.

[11] Fiorucci T. R, Lakin D. R, Reynolds T. D. Advanced Engine