

doi: 10.7690/bgzdh.2021.10.001

基于迁移学习的综合传动装置健康预测方法

肖 宇¹, 李英顺², 戴喜生¹, 刘胜永¹

(1. 广西科技大学电气与信息工程学院, 广西 柳州 545000;
2. 大连理工大学控制科学与工程学院, 辽宁 大连 116024)

摘要: 针对某型步战车综合传动装置变工况的工作特点, 提出一种基于迁移学习的健康预测方法。采用灰色关联分析(grey relational analysis, GRA)提取源域和目标域内时序退化特征作为各部件健康指标(health indicator, HI), 构建1维时序健康指标, 通过动态时间规整(dynamic time warping, DTW)运算得到目标域特征与健康指标的关联度, 提取源域与目标域的公共退化信息, 构建面向健康预测的支持向量回归(support vector regression, SVR)模型进行健康预测, 并以传动装置的变速结构为例进行验证。结果表明: 基于迁移学习的健康预测结果更贴合实际健康变化趋势, 有助于维修人员更为准确地判断传动装置的健康状态。

关键词: 变工况; 健康预测; 迁移学习; 灰色关联分析

中图分类号: TJ81 文献标志码: A

Health Prediction Method of Comprehensive Transmission Based on Transfer Learning

Xiao Yu¹, Li Yingshun², Dai Xisheng¹, Liu Shengyong¹

(1. School of Electrical & Information Engineering, Guangxi University of Science & Technology, Liuzhou 545000, China;
2. School of Control Science & Engineering, Dalian University of Technology, Dalian 116024, China)

Abstract: Aiming at the working characteristics of variable conditions of an integrated transmission device of certain type of infantry fighting vehicle(IFV) in fantry fighting vehicle, a health prediction method based on transfer learning is proposed. Use the grey relational analysis(GRA) to extract the time series degradation features in the source and target domains as health indicators(HI) of each component, construct a one-dimensional series of health indicators, through the dynamic time warping(DTW) operation, the correlation between the characteristics of the target domain and the health indicators is obtained, extract the public degradation information of the source and target domains, construct a support vector regression(SVR) model for health prediction for health prediction, and take the transmission structure of the transmission device as an example to verify. The results show that the health prediction results based on transfer learning are more in line with actual health trends, and help the maintenance staff more accurately judge the health status of the transmission device.

Keywords: variable condition; health prediction; transfer learning; grey relational analysis

0 引言

综合传动装置是集液力、液压、行星传动等多项传感技术于一体的高复杂电液系统^[1], 其性能状态直接决定步战车的机动能力, 进而影响其作战能力。该装置组成结构庞大且复杂, 各子系统间、各部件间的关联程度高, 发生故障后维修难度大、维修成本高, 因此对其实现健康预测十分必要。健康预测作为运行维修领域的新兴研究内容, 已成为领域研究热点之一, 受到了各国研究者的普遍关注。其目的在于实现对设备健康状态评估的同时, 对设备的健康状态进行有效预测, 在分析设备失效趋势的基础上来辨识设备早期性能退化的现象, 为设备

的预防性维修提供重要信息。

综合传动装置由于所处工作环境、路况等原因, 需频繁切换工况以保证正常运行, 且同一子系统或部件在不同工况性能衰退的过程也不相同, 致使数据特征的分布与传统数据特征独立分布的性质相背; 加之设备长期处于正常工作状态, 导致各工况的故障数据稀少或缺失; 因此寻求一种能使设备在不同工况下数据特征分布尽可能一致的方法, 以克服特征数据较少的问题, 同时提升健康预测的准确度。

迁移学习^[2]是能够将已有知识或经验用来解决新问题的一种机制, 能够提升历史信息的复用性,

收稿日期: 2021-06-07; 修回日期: 2021-07-20

基金项目: 国家自然科学基金项目(71801196); 辽宁省兴辽英才计划(XLYC1903015)

作者简介: 肖 宇(1989—), 男, 辽宁人, 硕士, 从事武器装备的健康预测、人工智能研究。E-mail: randolphxiao@sina.cn。

提高目标域的学习效果，适用于小样本环境，在语言处理^[3-4]、影像处理^[5]、医学检测^[6]、金融分析预测^[7]和设备预防性维修^[8]领域取得了良好效果。查阅已有文献，对综合传动装置健康预测问题的研究尚未深入，笔者利用灰色关联分析方法(GRA)提取源域和目标域中时序数据的性能退化特征序列，构建反映源域健康程度的 1 维健康指标(HI)；将退化特征作为迁移对象，运用动态时间规整^[9](DTW)确定目标域特征与 HI 的相似度，构建公共特征集合，实现性能退化信息从源域到目标域的迁移，最后将公共特征注入面向健康预测的支持向量回归^[10](SVR)模型，实现对未来的健康预测。笔者以某型步战车综合传动装置的变速机构为例，通过分析变速机构离合器的换挡特性^[11-12]，对所提方法进行分析验证。

1 问题描述

基于迁移学习理论分析，在不同工况下对同一系统装置进行重复实验，可得到来自不同工况下各部件的监测数据集合。令某个工况下的监测数据为 $\{x_i^s\}_{i=1}^{n_s}$ ，其中包含 n_s 个样本，令样本 x_i^s 属于样本空间 χ^s ，并满足边缘概率分布 $P(\chi^s)$ ；另一工况下监测数据为 $\{x_i^t\}_{i=1}^{n_t}$ ，其中包含 n_t 个样本，令样本 x_i^t 属于样本空间 χ^t ，并满足边缘概率分布 $P(\chi^t)$ ；由于车辆行驶过程中路况变化等因素影响，导致运行工况不断变化，而在不同工况下设备部件运行数据分布差异较大，因此基于统计分析理论有 $P(\chi^s) \neq P(\chi^t)$ 。

系统设备从健康状态到发生故障的过程中，不同工况下，同类型号的部件性能退化趋势差异明显，因此需要在相近工况中寻找相关的退化信息，辅助建立预测模型；某一工况下，某部件运行数据样本空间为 χ^s ，该空间服从概率分布 $P(\chi^s)$ ， χ^s 和 $P(\chi^s)$ 共同构成源域 D^s ，有 $D^s = \{\chi^s, P(\chi^s)\}$ ，作为目标域健康预测的参考；另一工况下，部件运行数据样本空间为 χ^t ，该空间服从概率分布 $P(\chi^t)$ ， χ^t 和 $P(\chi^t)$ 共同构成目标域 D^t ，有 $D^t = \{\chi^t, P(\chi^t)\}$ ，目标域中数据样本具有数量少的特点，且要满足预测精准、快速的要求。

健康预测的本质是通过对过往数据的分析，从而实现健康程度的预测并分析其变化的回归问题。通过对源域数据的训练，能够构建出源域样本空间 χ^s 到健康程度显示空间 v^s 的映射关系 $f: \chi^s \mapsto v^s$ ，得到预测健康程度的模型。较少的目标域的数据样

本往往造成预测模型中的映射关系 $f: \chi^s \mapsto v^s$ 发生偏差，需要利用源域特征与健康程度之间关系所反映出的性能退化模式，以提升对目标域的预测精度。迁移学习理论能够匹配源域与目标域的数据分布，提取退化过程中的共用特征；运用从源域样本中提取的特征与健康程度显示空间之间所反应出的退化模式，协助提升目标域中部件健康预测精度。

2 健康预测方法的构建

2.1 基于灰色关联分析的健康指标建立

性能退化序列本身是一组时间序列，其对应的健康指标序列应具有明确的趋势表达性，以及对性能退化敏感的特性，且具有满足单调变化的性质。首先选用某工况的运行数据作为源域，采用灰色关联分析方法提取各部件时序退化特征，并构建设备整体的健康指标 HI。

灰色关联分析是根据各因素变化曲线的几何相似度，来判断各因素之间关联水平，进而描述和比较事务态势变化发展的方法，可用于分析各因素对结果影响度的大小，能够较好地处理随时间变化的综合评估问题。在状态评估^[13-14]、性能预测预报^[15-17]、决策分析^[18]等领域取得了广泛应用，且该方法具有对数据样本的数量和规律无严格要求、计算量小的优点。笔者通过灰色关联分析来比较所处工况标准数据序列与随时间变化的数据序列相似性的大小，来判断两者之间的关联程度，进而确定某时刻设备的健康水平。灰色关联分析的方法如下：

1) 标准序列的确定。

令各工况最佳状态指标序列为标准序列 $B_i = \{b_i(k) | i=1, 2, \dots, n; k=1, 2, \dots, m\}$ ，在第 i 工况下采集的第 j 个数据序列 $X_{i,j} = \{x_{i,j}(k) | i=1, 2, \dots, n; k=1, 2, \dots, m\}$ 称为比较序列，其中 n 为工况个数。

2) 数据的无量纲处理。

由于设备运行参数数据的量纲不同，因此要对采样数据进行无量纲处理。常用的无量纲处理方法有均值化法和初值法，分别如式(1)、式(2)：

$$x'_{i,j}(k) = x_{i,j}(k) / \left(\sum_{k=1}^m x_{i,j}(k) / m \right); \quad (1)$$

$$x'_{i,j} = x_{i,j}(k) / x_{i,j}(0). \quad (2)$$

式中： $i=1, 2, \dots, n; k=1, 2, \dots, m, n$ 为工况个数； $x_{i,j}(0)$ 为第 i 工况下标准指标序列的第 j 个指标的标准值。

3) 关联系数的计算。

计算各工况下采样数据序列与所属工况下指标

数据序列所对应元素差的绝对值, 即 $\Delta_{i,j}(k)=|x'_{i,j}(k)-b'_i(k)|$, 其中 $b'_i(k)$ 为去量纲后的指标数据值; 分别找出两极最大差 $\Delta(\max)=\max_j \max_k \Delta_{i,j}(k)$ 和两极最小差 $\Delta(\min)=\min_j \min_k \Delta_{i,j}(k)$, 得到采样序列中各因素关联系数为:

$$\zeta_{i,j}(k)=\frac{\Delta(\min)+\rho\Delta(\max)}{\Delta_{i,j}(k)+\rho\Delta(\max)}。 \quad (3)$$

式中 $\rho \in (0, \infty)$, 称为分辨系数, 通常取 $\rho=0.5$ 。

4) 求出关联度。

每个采样序列与所属工况标准序列的关联度由采样序列中各因素的关联系数综合水平决定, 求出其平均值即可得到采样序列与所属工况标准序列的关联度:

$$\gamma_{i,j}=\frac{1}{j} \sum_{j=1}^n \zeta_{i,j}(k)。 \quad (4)$$

5) 健康度。

关联度与关联系数值越接近 1, 表明与标准序列及其指标的相似度越高, 说明该时刻健康状态和指标健康程度越好, 反之越差。笔者将指标的关联系数特征抽象为时序下部件的健康指标 $h_{i,j}$, 将关联度抽象为系统设备整体的健康指标 HI。

6) 关联系数特征值的转换。

以变速机构为例, 变速机构挡位固定时, 有 2 个离合器处于充油状态, 另外 3 个离合器处于泄压状态; 基于同型部件性能的一致性, 各工况下离合器充油与泄压理想值均一致, 提取某工况下各离合器的数据进行灰色关联分析, 得到 1 挡工况下临界故障时的健康指标特征向量: $H_1=[0.670\ 5\ 0.339\ 1\ 0.670\ 5\ 0.339\ 1\ 0.339\ 1]$, 变速机构临界故障健康指标为 $HI_f=0.471\ 6$ 。

为预防故障的突发性影响, 令离合器充油工况时临界故障关联系数特征为 $h_c=0.7$, 泄压工况时临界故障关联系数特征 $h_x=0.35$, 变速机构临界故障特征值 $HI_f=0.5$; 即低于上述数值则认为部件和系统进入故障模式。

第 i 工况下第 j 个离合器充油工况关联系数特征值为 $h_{i,j}^c$, 泄压工况关联系数特征值为 $h_{i,j}^x$, 充油工况时关联系数特征值与泄压工况时关联系数特征值转换公式为:

$$h_{i,j}^c=h_{i,j}^x(1-h_c)+h_c; \quad (5)$$

$$h_{i,j}^x=h_{i,j}^c(1-h_x)+h_x。 \quad (6)$$

2.2 迁移公共特征空间的建立

为提升不同工况下剩余寿命预测的准确性, 在提取不同领域公共特征的同时, 不能忽略性能退化过程在时序数据上的表征, 因此提取能够反映出性能趋势变化且同时能满足单调条件的公共特征十分关键。2.1 节中构建的 HI 能够反映出性能的退化趋势, 计算目标域每个部件的特征与 HI 的相似度, 根据相似程度的大小提取与 HI 相近的特征, 构成公共特征集, 从而实现退化趋势特征的迁移。DTW 能够用来度量 2 个长度不一致数列的相似程度, 因此采用 DTW 计算所提取特征与 HI 的相似程度, 构建出公共特征空间。方法如下:

1) 令目标域提取的关联指标特征集合为 $T=[T_1, T_2, \dots, T_m]$, 目标域内第 i 个部件的特征序列 $T_i=[t_1, t_2, \dots, t_n]$, m 为目标域内子系统包含部件的个数, n 为所提取的特征数量, t_j 为第 i 个部件退化序列中的第 j 个特征, $j=1, \dots, n$ 。

2) 计算 t_j 与健康指标 HI 的 DTW 距离, 第 i 个部件的性能特征与 HI 的相似向量为 $G_i=[g_1, g_2, \dots, g_n]^T$, 得到目标域各部件与 HI 的相似度矩阵为 $G=[G_1, G_2, \dots, G_m]$ 。

3) 相似度高则 g_i 越小, 所对应的重要程度越大。将各个特征按照重要程度进行排序, 并补充特征, 确定使预测误差最小的特征个数, 得到公共特征集 $R=[R'_1, R'_2, \dots, R'_m]$ 。

2.3 健康预测模型的建立

将 R 作为输入, 对应时刻的指标值作为输出, 构建 SVR 回归模型, 基于小样本环境条件下的考虑, 在取得公共敏感特征集的基础上, 运用 SVR 在小样本数据下所具有的良好泛化能力, 构建出结构风险最小化的回归模型, 避免迁移过程中过度学习的出现。健康预测流程如图 1 所示。

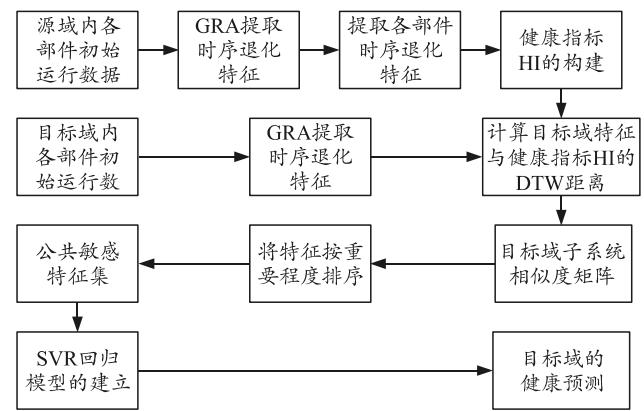


图 1 健康预测流程

3 实验分析

以某型步战车综合传动装置的变速机构为例，探究所构建健康预测方法的有效性。变速机构由 6 个离合器构成：C1、C2、C3、CL、CH、CR，综合传动装置采用液压换挡方式，执行液压换挡时，液压油经过系统操纵阀回路经定压阀进出换挡油缸，对离合器进行充放油，实现离合器的结合与分离。通过离合器的组合变换实现挡位切换（见表 1），进而实现战车速度的变化，其中 CR 为倒挡离合器，本文中仅讨论变速工况，不讨论倒车情况，离合器油压工作曲线如图 2 所示。

表 1 挡位与离合器组合对照

离合器	挡位						
	1	2	3	4	5	6	-1
CL	•				•		
CH		•		•			
CR						•	
C1	•		•				
C2		•		•			
C3			•		•		•

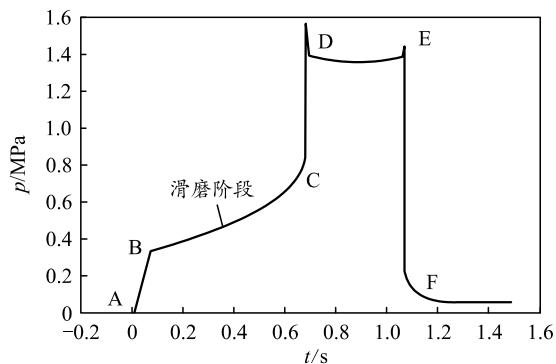


图 2 离合器油压工作特性曲线

每个离合器还分为充油和泄压 2 个工况。当离合器结合时，充油油压偏低会导致主被动摩擦片结合不充分而导致打滑，引发挡位错乱；偏高会引起摩擦片结合过紧引起挡位卡涩。另外，离合器会因为离合器泄压放油后残存的油压，导致主被动摩擦片不能彻底分离，发生“带排”现象，对离合器和结合轴造成损伤。如上图，离合器工作时充油压力在 1.3~1.6 MPa 范围，泄压后油压在 0~0.2 MPa 范围（信号输出显示为 1~6 V 电压信号）。离合器的结合与分离过程中，油压信号可反映离合器的健康程度，据此对油压信号进行特征提取分析，进而对变速机构的健康情况进行预测。

3.1 构建源域 HI

健康预测目的在于识别早期的故障，进而对性能退化趋势进行预测，选取变速机构故障前 2 个连

续工况的数据作为分析样本，其中 3 挡行进工况各离合器最后的 100 个数据样本作为源域，4 挡行进工况各离合器最后的 100 个数据样本作为目标域，其中包含少量健康数据和全部退化数据，运用 GRA 提取源域的 100 维时序特征。如图 3 和图 4 所示，为了更加直观地表达提取特征随着离合器退化所表现出的趋势性，选取各部件的特征进行展示。通过计算得到 1 维变速机构的 HI 特征，即源域 HI。鉴于构造的迁移模型目的在于迁移设备的退化信息，为避免数据中局部扰动对构建整体趋势的影响，对 HI 特征曲线进行平滑处理，构建出如图 5 所示的充油离合器特征。由图 5 可见，平滑的 HI 具有良好的趋势性和单调性，能够识别设备早期的性能退化趋势，具有较好的敏感性。

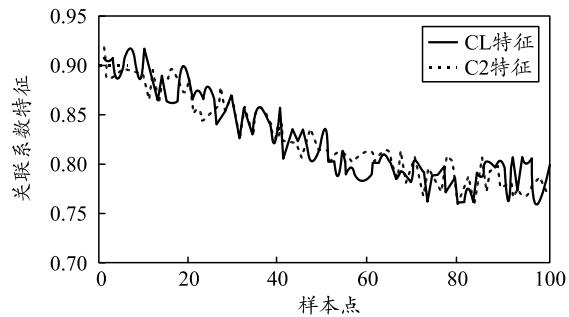


图 3 充油离合器特征趋势

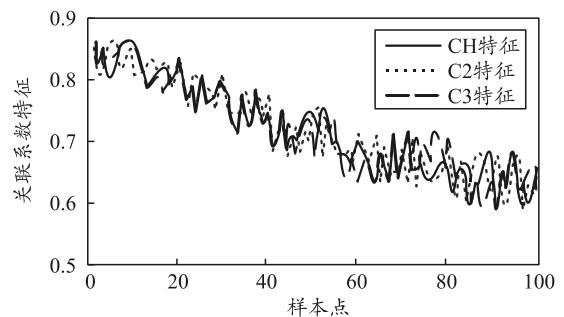


图 4 泄压离合器特征趋势

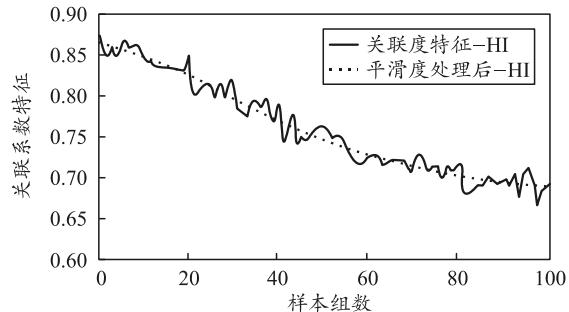


图 5 变速机构 HI 趋势及平滑处理后趋势

3.2 公共特征空间选取

为预测验证需要，选取目标域各部件的特征，运用 2.2 节中所提方法，对提取的各离合器关联系

数特征进行选择, 运用 DTW 计算每一个特征与 HI 的相似程度, 相似程度越高表明该特征有越高的重要性, 重要性偏低的特征在时序上与 HI 走势偏差较大, 因此剔除此类特征, 仅选取重要性较高的特征建立公共特征集 R , 输入 SVR 模型进行预测。

3.3 离合器的健康预测

选取目标域 CH 和 C2 离合器作展示, 仅对迁移算法和未迁移算法的预测进行比较, 分析预测效果如图 6 和图 7 所示, 未迁移算法是将 3 挡和 4 挡工况所提取特征直接用于目标工况离合器的健康预测。对比发现本文中采用迁移学习的方法能更好地贴合实际的退化趋势, 预测效果更好。为验证方法的整体有效性, 再对第 4 挡工况下其余处于泄压状态的离合器分别采用迁移方法和未迁移方法进行预测, 得到累计误差和平均误差百分比如表 2 所示, 可见采用迁移方法取得了更小的预测误差, 表明迁移学习可以有效提取不同工况下的趋势退化信息作为公共信息, 有效解决变工况条件下的健康预测问题, 一定程度上提升健康预测的精度。

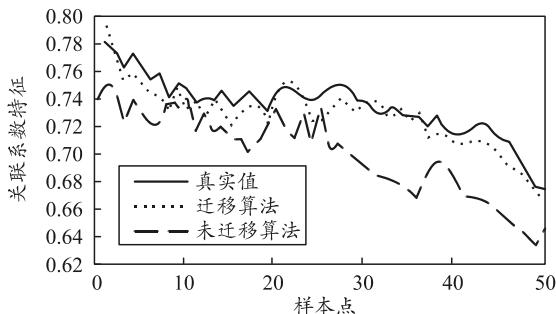


图 6 第 4 挡工况下 C2 离合器预测结果

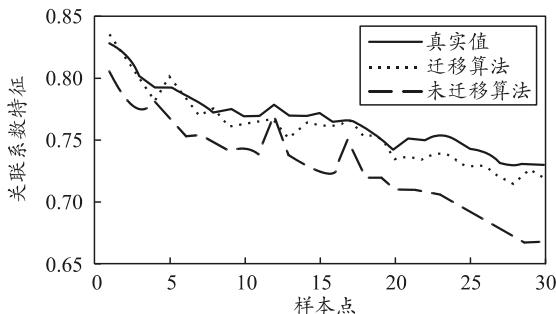


图 7 第 4 挡工况下 CH 离合器预测结果

表 2 目标域各离合器预测误差对比

离合器	累计误差		平均误差百分比/%	
	未迁移方法	文中方法	未迁移方法	文中方法
CL	2.202 1	0.607 8	5.48	1.35
CH	0.037 1	0.008 9	4.90	1.17
C1	1.107 2	0.288 3	5.39	1.21
C2	1.747 5	0.433 3	4.48	1.18
C3	1.198 2	0.254 3	4.51	1.25
平均值	1.048 6	0.318 3	4.46	1.25

4 结束语

针对某型步战车综合传动装置变工况的工作特点, 提出一种基于迁移学习的健康预测方法。采用灰色关联分析法对不同工况的时序数据进行特征提取, 并通过源域特征构建出系统设备整体的健康指标 HI, 有效地展现了设备整体在时序上的退化趋势, 通过目标域特征与设备整体的健康指标 HI 关联分析, 提取不同工况下性能退化的公共特征, 提高了数据复用性, 克服了数据样本数量不足情况下的健康预测问题。对比发现: 迁移学习方法较未迁移方法能更为准确地预测出部件已进入故障状态的时段, 帮助维修人员更准确地判断设备健康状态, 延长部件的使用寿命, 利于进行视情维修。

参考文献:

- [1] 闫清东, 张连第, 赵毓芹, 等. 坦克构造与设计: 上册 [M]. 北京: 北京理工大学出版社, 2006: 160–176.
- [2] PAN J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010(10): 1345–1359.
- [3] 王宇飞, 苏依拉, 赵亚平, 等. 基于参数迁移的蒙汉神经机器翻译模型[J]. 计算机应用与软件, 2020, 37(9): 81–87.
- [4] 赵鹏飞, 李艳玲, 林民. 面向迁移学习的意图识别研究进展[J]. 计算机科学与探索, 2020, 14(8): 1261–1274.
- [5] 肖儿良, 周莹, 简献忠. 迁移学习与 GAN 结合的医学图像融合模型[J]. 小型微型计算机系统, 2020, 41(9): 1972–1978.
- [6] JEONG Y B, KIM J H, CHAE H D, et al. Deep learning-based decision support system for the diagnosis of neoplastic gallbladder polyps on ultrasonography: Preliminary results[J]. Scientific Reports, 2020, 10(1): 7700.
- [7] 谢飞, 潘北啸. 基于迁移学习的 LSTM 互联网金融指数高精度预测方法[J]. 西南民族大学学报(人文社科版), 2020, 41(7): 129–134.
- [8] 王凯, 李元辉. 迁移学习在机械设备预测性维护领域的应用综述[J]. 中国仪器仪表, 2019(12): 64–68.
- [9] KEOGH E J, PAZZANI M J. Derivative dynamic time warping[C]//SIAM international conference on data mining. Chicago, IL, USA: SIAM, 2001: 1–11.
- [10] ASHOK K P, SNEHAMOY C, AMIT K G. Development of a machine vision system using the support vector machine regression (SVR) algorithm for the online prediction of iron ore grades[J]. Earth Science Informatics, 2019, 12(2): 197–210.

(下转第 9 页)