

邵知宇, 薛美玲, 何聪, 等. 基于 MTL 和 AM 的水泵机电运行参数趋势预测[J]. 南水北调与水利科技(中英文), 2024, 22(5): 959-966, 977. SHAO Z Y, XUE M L, HE C, et al. Prediction model for pump unit operating parameters based on multi-task learning and attention mechanism[J]. South-to-North Water Transfers and Water Science & Technology, 2024, 22(5): 959-966, 977. (in Chinese)

# 基于 MTL 和 AM 的水泵机电运行参数趋势预测

邵知宇<sup>1</sup>, 薛美玲<sup>2</sup>, 何聪<sup>3</sup>, 李精伟<sup>1</sup>, 唐鸿儒<sup>1</sup>

(1. 扬州大学电气与能源动力工程学院, 江苏 扬州 225009; 2. 江苏省江都水利工程管理处, 江苏 扬州 225006;  
3. 南京电子设备研究所, 南京 210007)

**摘要:** 针对复杂工况下水泵机电运行参数趋势预测的问题, 建立基于多任务学习 (multi-task learning, MTL) 和注意力机制 (attention mechanism, AM) 的水泵机电运行参数趋势预测模型。充分利用历史工况数据, 使用多任务学习分析方法, 寻找历史工况数据的共同特征; 在预测新工况数据变化趋势时, 引入注意力机制动态分配共同特征映射时的权重系数, 突出关键共同特征, 提升模型的预测精度; 根据模型监测统计量阈值分析, 建立机组运行监测多级预警模型, 优化运维管理策略。以某泵站机组实际运行工况数据进行测试并与不同模型计算结果进行对比分析, 结果表明: 与传统单任务学习和静态共同特征映射权重的模型相比, 基于多任务学习和注意力机制的模型, 其统计量  $T^2$  和  $Q$  均未超过 95% 和 99% 的控制限, 表明该预测模型具有很好的稳定性和准确性。

**关键词:** 趋势预测; 水泵机组; 多任务学习; 注意力机制; 状态监测; 多级预警

**中图分类号:** TV675 **文献标志码:** A **DOI:** 10.13476/j.cnki.nsbdqk.2024.0095

泵站水泵机电运行参数趋势预测主要是基于泵站水泵机组的多种实时运行参数, 如电流、电压、功率和温度等, 对可能影响泵站水泵机组健康安全运行的重要参数进行实时分析和趋势预测, 进而提前识别机组可能出现的故障隐患, 用于设备故障诊断和维修管理<sup>[1]</sup>。泵站机组作为泵站的核心组成部分, 直接关系到饮用水的稳定供给、农业灌溉和工业用水的安全保障。然而, 泵站系统运行过程中面临的设备老化、环境变化、操作管理等因素, 可能导致设备故障、系统性能下降, 进而造成资源浪费、人员伤亡和设备损害等事故。因此, 为保障泵站水泵机组设备连续、安全、稳定地运行, 减少设备故障发生率, 提高运维巡检效率和优化管理策略, 建立模型对运行参数变化趋势进行预测和故障诊断报警, 具有十分重要的应用价值。

为保障泵站设备安全稳定运行, 研究者在泵站机组设备状态监测和运行参数数据分析和预测方面展开了大量工作。在泵站设备状态监测方面, 水泵站的状态监测方法主要有 3 种方式, 分别是基于

模型的方法、基于信号分析的方法和基于数据驱动的方法<sup>[2]</sup>。基于模型的方法根据机组设备运行机理建立精确的物理模型, 通常可以保证较高的精度<sup>[3-4]</sup>, 但对于复杂场景下的机组运行, 难以建立精确的物理模型<sup>[5]</sup>。另外, 由于使用过程中磨损等原因, 运行模型参数会发生变化, 固定的运行模型可能会导致故障误报漏报。基于信号分析的方法通过处理分析采集的信号数据来检测潜在的故障, 对信号质量敏感, 受噪声、干扰的影响较大, 通常需要专门的传感器和硬件设备, 会增加运行成本<sup>[6-7]</sup>, 且有些关键信号不易或不可采集, 因此该方法应用范围受限<sup>[8]</sup>。基于数据驱动的方法<sup>[9-11]</sup> 在目前泵站设备状态监测研究中应用最广泛, 该方法利用数据的内在特征进行运行状态监测, 泛化能力强, 能够适应各种系统和设备的差异, 模型移植相对简便, 减少成本<sup>[12]</sup>。基于数据驱动的状态监测方法, 又分为基于机器学习<sup>[13]</sup>的方法和基于统计分析<sup>[14]</sup>的方法。其中: 基于机器学习的方法通常需要建立复杂的网络结构, 确定大量的超参数, 但解释模型内部的决策过程较为困难,

收稿日期: 2024-06-18 修回日期: 2024-08-11 网络出版时间: 2024-09-05

网络出版地址: <https://link.cnki.net/urlid/13.1430.tv.20240904.1636.002>

基金项目: 国家自然科学基金青年基金项目(62103358); 江苏省高效节能大型轴流泵站工程研究中心开放课题资助项目(ECHEAP017)

作者简介: 邵知宇(1992—), 男, 河南南阳人, 讲师, 博士, 主要从事机器人传感与控制、泵站信息化等研究。E-mail: zhiyushao@yzu.edu.cn

通信作者: 唐鸿儒(1964—), 男, 江苏淮安人, 教授, 博士, 主要从事泵站信息化、泵站设备故障诊断等研究。E-mail: yztanghr@163.com

在数据量过少的情况下容易出现过拟合的问题,且对计算的硬件设施有一定要求;而基于统计分析的方法依赖数据的分布特性进行统计分析,通过建立变量之间的关系,根据计算的统计量对设备的运行状况进行监测。

在泵站设备运行参数分析研究方面,过去的研究主要采用传统统计方法,如均值、方差分析等,但这些方法在处理复杂、时变的泵站系统时存在一定的局限。近年来,数据分析技术在水利工程领域的应用取得显著进展,特别是机器学习技术成为泵站数据分析的重要工具,支持向量机、随机森林、神经网络等方法通过对非线性关系和多变量间的复杂关联的处理,提高了数据分析的精度。同时,针对泵站的时序数据,时间序列分析方法如自回归求和移动平均(autoregressive integrated moving average, ARIMA<sup>[15]</sup>)模型、指数平滑法(exponential smoothing<sup>[16]</sup>)等被广泛应用,用于捕捉数据的趋势和季节性变化,以实现长期运行状态的预测和分析。如薛萍等<sup>[17]</sup>利用反向传播神经网络(back propagation neural network, BPNN)设计了泵站前池水位预测模型,满足了泵站前池的水位动态预测需求。目前,泵站数据分析技术的发展呈现出几个明显的趋势:首先,深度学习技术的应用将进一步扩大,深度神经网络<sup>[18]</sup>、长短时记忆(long short-term memory, LSTM)网络<sup>[19]</sup>、卷积神经网络(convolutional neural networks, CNN)<sup>[20-21]</sup>等模型将提高对复杂系统的建模和预测能力;其次,边缘计算与物联网技术的融合将成为重要方向,通过在设备端进行数据处理,实现更高效的数据管理和分析;此外,未来的研究将更注重多源数据的融合与集成,以建立更全面、综合的泵站信息模型。随着人工智能技术的发展,泵站数据分析将朝着更加智能决策系统方向发展,以实现泵站系统的自动化运营和智能优化。

泵站运行状态往往由多个变量共同反映,需使用多变量统计分析方法,如主成分分析(principal component analysis, PCA)提取关键信息,实现数据降维,以便监测和判断水泵机组的性能<sup>[22]</sup>。泵站的水泵机组是间歇运行的并且参数变化缓慢,每个运行时段通常被作为独立任务进行分析处理,随着设备运行年限的增长,任务数量增加。但是由于数据采集频率低,每个独立任务中能够用于分析的有效数据很少,给数据分析带来了困难。因此,如何在多任务少样本的条件下进行水泵机组状态监测,成

为研究的热点问题。多任务学习(multi-task learning, MTL)<sup>[23]</sup>的机器范式通过同时学习多个相关任务来提高模型性能,为解决多任务少样本问题提供了一种解决思路。模型被设计用于同时处理多个任务,这些任务可以是相关的,共享某些特征或信息,或者互相有助于提高模型的泛化性能。Achille 等<sup>[24]</sup>解决了多任务学习中的任务表示问题,Zhang 等<sup>[25]</sup>研究了如何使用几何推理场景深度和语义优化多任务学习效果。但是多任务学习是每一个任务都使用提取到的所有特征,由于季节、噪声等原因,某些特征可能会有所偏移,并且在实际处理过程中不是每一个特征都会存在,可能只存在一个或多个特征。因此,如何筛选多任务学习提取到的特征成为另一个需要解决的问题。在多任务学习的基础上引入注意力机制(attention mechanism, AM)则是一种可行的研究方法<sup>[26]</sup>。在泵站运行监控中,不同的传感器和监测任务可以提供关于泵站系统不同方面的信息,模型难以有效关注输入中的关键信息,需要注意力机制帮助模型动态地关注不同监测任务的数据,根据当前情况调整任务的重要性。这有助于提高监控系统对多个任务的适应性,确保更全面地了解水泵系统的运行状态。

## 1 研究方法

以某水利枢纽泵站机组运行监测数据为研究对象,在多任务学习提取历史工况数据共同特征的基础上引入注意力机制动态分配权重,从而突出某些特定的共同特征,建立泵站机电运行参数趋势预测模型,实现对机组状态的监测和预防性维护,以保障机组安全运行。

### 1.1 基于注意力机制的权重确定

基于注意力机制的权重生成的基本过程见图 1。主要包括两部分内容:预训练模型,使用卷积神经网络,对已有类别进行精确分类;基于注意力机制的权重生成,推广通过训练任务得到的共性特征,针对新任务,提供权重参数。

预训练模型包括 3 个步骤:

步骤 1,设计特征提取器,方法如下:

$$z = F(X|\theta) \quad (1)$$

式中: $X$ 是任务的训练数据集; $z$ 是特征提取器输出的数据集 $X$ 的特征; $\theta$ 是特征提取器中可训练的参数。

步骤 2,根据公式(2)计算余弦相似性 $s$ :

$$s = \tau \frac{z}{\|z\|} \times \frac{W^*}{\|W^*\|} \quad (2)$$

式中:  $\tau$  是一个可训练的常量参数;  $W^*$  代表预训练模型中最后一层权重值的  $L_2$  范数;  $W^*$  的每个元素分别代表  $K^*$  个基础类别的权重参数, 基础类别指的是已训练的任务中包含的类别。

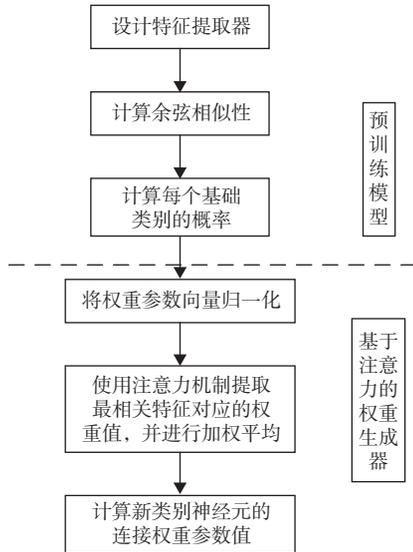


图 1 基于注意力机制的权重确定方法

Fig. 1 The method of weight determination based on the attention mechanism

步骤 3, 根据公式(3)计算基础类别的概率  $p$ :

$$p = \text{Softmax}(s) \quad (3)$$

式中:  $p$  的每个元素分别代表  $X$  属于  $L_2$  个基础类别的概率。

基于注意力机制的权重生成器也包括 3 个步骤:

步骤 1, 使用预训练模型中最后一层权重值的  $L_2$  范数对权重参数向量  $W^*$  进行归一化, 并将权重值  $W_1^*, W_2^*, \dots, W_K^*$  和经过训练的任务数据集特征  $k_1, k_2, \dots, k_K$  存储在记忆模块中。

步骤 2, 在记忆模块中使用注意力机制提取最相关特征对应的权重值, 利用公式(4)进行加权平均:

$$W'_{\text{att}} = \frac{1}{m} \sum_{i=1}^m \sum_{b=1}^K A\left(\phi_q \frac{z'_i}{\|z'_i\|}, k_b\right) \cdot \frac{W_b^*}{\|W_b^*\|} \quad (4)$$

式中:  $m$  是新任务训练集中样本点的个数;  $K$  是训练过的任务中的类别总数;  $\phi_q$  是可训练的参数;  $W_b^*$  是预训练深度网络中最后一层对应第  $b$  个类别神经网络的所有连接权重参数;  $z'_i$  是新任务中第  $i$  个样本点数据集的特征;  $k_b$  是记忆模块中第  $b$  个类别数据集的特征;  $W'_{\text{att}}$  是注意力机制下从记忆模块中提取出的最相关特征对应的权重参数的加权平均值;  $A$  代表注意力机制, 是新任务中每个样本特征与记忆模块

中每个类别特征之间的相似性。相似性越大,  $A$  的值越大, 意味着这个类别的神经元的连接权重参数在加权平均中的权重也越大。  $A$  的值可通过式(5)进行计算:

$$A\left(\phi_q \frac{z'_i}{\|z'_i\|}, k_b\right) = \text{Softmax}\left(\phi_q \frac{z'_i}{\|z'_i\|} \frac{k_b}{\|k_b\|}\right) \quad (5)$$

式中:  $\text{Softmax}$  函数的分母是对  $b$  的求和, 即对所有预训练类别的求和。  $\text{Softmax}$  输出的是在第  $b$  个预训练类别上的概率值, 其值在 0~1, 代表第  $b$  个预训练类别的权重参数在加权平均中的系数。

步骤 3, 计算新类别神经元的连接权重参数值  $W'$ , 公式为

$$W' = \phi_{\text{avg}} \odot W'_{\text{avg}} + \phi_{\text{att}} \odot W'_{\text{att}} \quad (6)$$

式中:  $W'_{\text{avg}}$  是基于特征平均值生成的分类器权重;  $\phi_{\text{avg}}$  是可训练的参数;  $W'_{\text{att}}$  是基于注意力机制生成的分类权重;  $\phi_{\text{att}}$  是可训练的参数;  $\odot$  是 Hadamard 乘积计算符号。

## 1.2 基于注意力机制的多任务学习模型

首先, 利用基于多任务学习的 PCA 算法对机组状态监测数据进行降维处理, 筛选出历史工况数据的共同特征。然后, 引入注意力机制确定预测模型在每个共同特征方向上的权重。最后, 将实时工况数据向关注的共同特征的主元方向上做映射, 通过其在主元方向上的特征变化, 对实时工况下运行数据的变化趋势进行预测。

基于多任务学习的 PCA 算法将原始历史工况数据  $X = \{X_1, X_2, \dots, X_k, \dots, X_N\}$  进行 PCA 降维分解为正交的得分矩阵  $T = [t_1, t_2, \dots, t_k]$  和正交的载荷矩阵  $P = [p_1, p_2, \dots, p_k]$  的乘积  $X = TP^T$ 。将  $N$  组历史工况数据重复操作可得到主成分个数的集合  $K_k = \{k_1, k_2, \dots, k_N\}$ , 得分矩阵集合  $T_k = \{T_1, T_2, \dots, T_N\}$  和载荷矩阵集合  $P_k = \{P_1, P_2, \dots, P_N\}$ 。然后通过计算载荷矩阵集合中每一个主成分向量之间的相似性进一步筛选出  $q$  组方向一致的向量集合。对于每一组由  $n_q$  个方向一致的向量构成的集合  $A = [\alpha_1, \alpha_2, \dots, \alpha_{n_q}]$ , 将其进行奇异值分解  $AA^T = U\Sigma V^T$  即可得到正交矩阵  $U$  的第一列  $\beta_1$ 。该列向量代表了  $AA^T$  最大的奇异值对应的方向, 即数据的主要变化方向。将  $W = [\beta_1, \beta_2, \dots, \beta_q]$  作为这  $N$  组历史工况数据的共同特征, 其中每一列代表一个特征, 表示数据的不同变化方向。

基于注意力机制的 PCA 算法步骤见表 1。在得到多任务学习的共同特征后, 将设备新的运行时

段的数据向共同特征上做投影映射,以进一步分析其在共同特征上的变化趋势。共同方向的权重会

对预测模型的特征权重分配产生影响,因此需要引入注意力机制来确定最佳权重分配。

表 1 基于注意力机制的主成分分析步骤

Tab. 1 Steps of PCA based on the attention mechanism

步骤	具体内容
步骤1	将实时运行工况下得到的新样本数据进行标准化得到 $X_{\text{new}}$
步骤2	求出新样本 $X_{\text{new}}$ 在共同特征 $W$ 上的投影值,并应用 Softmax 函数,得到权重系数 $\psi = [\psi_1, \psi_2, \dots, \psi_{k_{\text{new}}}]$
步骤3	对新样本 $X_{\text{new}}$ 应用 PCA 模型进行降维分解
步骤4	求出新样本 $X_{\text{new}}$ 在自己的载荷矩阵 $P_{\text{new}}$ 上的投影值,并应用 Softmax 函数,得到权重系数 $\phi$
步骤5	求 $W$ 和 $P_{\text{new}}$ 中每个列向量之间的余弦相似性,得到 $P_{\text{new}}$ 所对应的共同方向 $W$ 的余弦相似性最大的方向,共 $k_{\text{new}}$ 个,构成新的共同特征矩阵 $W_1 = [w_1, w_2, \dots, w_{k_{\text{new}}}]$ ,同时将与 $k_{\text{new}}$ 个方向对应的系数构成新的系数矩阵 $\gamma = [\gamma_1, \gamma_2, \dots, \gamma_{k_{\text{new}}}]$
步骤6	根据系数矩阵 $\psi$ 和 $\gamma$ , 计算共同方向上的权重系数 $\delta_1$ 和新样本特征方向上的权重系数 $\delta_2$ 并归一化,利用权重系数将 $W_1$ 和 $P_{\text{new}}$ 进行加权得到 $Z = \delta_1 \cdot W_1 + \delta_2 \cdot P_{\text{new}}$ ,取 $Z$ 的正交矩阵的前 $k_{\text{new}}$ 列作为调整后的特征向量 $P'$ 。其中, $\delta_1 = \frac{\gamma_i}{\gamma_i + \psi_i}$ , $\delta_2 = \frac{\psi_i}{\gamma_i + \psi_i}$
步骤7	将新样本 $T = P'^T X$ 投影到主成分空间,可得其主成分得分 $T = P'^T X$ 和残差量 $E = (1 - P'P'^T)X$

### 1.3 模型监控参数

选用  $T^2$  和  $Q$  统计量作为监测参数来监控运行过程。

$T^2$  统计量用于检测多维数据中的异常样本,能够反映模型运行的偏离程度,是一种主元模型内部变化的测度,更加侧重反映出模型的稳定性。值越小,模型越稳定。 $T^2$  统计量和阈值  $T_{\text{lim}}^2$  分别通过公式(7)、(8)求得:

$$T^2 = T^T A^{-1} T = X^T P' L^{-1} P'^T X \quad (7)$$

$$T_{\text{lim}}^2 = \frac{A(n_{\text{new}} - 1)}{n - A} F(A, n - A, \alpha) \quad (8)$$

式中:  $n$  是新样本的个数;  $A$  是 PCA 模型提取出的主成分个数;  $\alpha$  是显著性水平;  $F(A, n - A, \alpha)$  表示自由度为  $(A, n - A)$  的 F 分布的上限  $\alpha \times 100\%$  的临界点。

$Q$  统计量用于监控数据的协方差结构,它基于样本数据点与样本均值之间的马哈拉诺比斯距离,通过标准化来计算。反映预测值的偏离量,可以体现模型预测的精度,值越小,精度越高。 $Q$  统计量通过公式(9)求得,阈值  $Q_{\text{lim}}$  通过公式(10)求得:

$$Q = e^T e = X^T (1 - P'P'^T) X \quad (9)$$

$$Q_{\text{lim}} = \theta_1 \left( \frac{c_\alpha \sqrt{2\theta_2 h_0^2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right)^{\frac{1}{h_0}} \quad (10)$$

式中:  $c_\alpha$  是上限  $(1 - \alpha) \times 100\%$  相对应的标准正态偏差;  $h_0 = 1 - \frac{2\theta_1 \theta_3}{3\theta_2^2}$ ,  $\theta_i = \sum_{j=k_{\text{new}}+1}^{n_{\text{new}}} \lambda_j, i = 1, 2, 3$ , 其中  $\lambda_j$  是新样本协方差矩阵的第  $j$  个特征值。

值得注意的是,统计量  $T^2$  和  $Q$  反映的是数据集

中所有变量的综合变化,是对整个系统运行状态的综合判断,只能检测到系统有故障发生而不能识别出故障来源。当需进一步确定故障是由哪一种或几种变量非正常变化引起时,可计算每个变量对统计量  $T^2$  和  $Q$  统计量的贡献率,贡献率最大的变量一般为引起故障的变量。

## 2 测试结果与分析

### 2.1 样本选择

选取长江沿岸某泵站枢纽 5 台机组(2 号、4 号、6 号、8 号和 9 号)从 2021 年 1 月到 9 月正常运行工况下的 12 104 条历史概况数据(使用样本数较多的 9 个序列)和 1 号机组新时段 100 条正常运行工况数据中的前 15 条(第 10 个序列)作为训练集,1 号机组新时段的后 85 条数据作为测试集,构建基于多任务学习和注意力机制的水泵机组机电参数预测模型。A 相电流、B 相电流、C 相电流、励磁电压、有功功率、无功功率、定子温度、上导温度、下导温度、上油缸温度、下油缸温度、推力瓦温度、内河侧水位、长江侧水位、调度区水位是从机组进行监测数据中提取并用于建模分析的变量,共 15 个。

### 2.2 模型训练

对训练集的主元进行主成分分析,得到如表 2 所示的主元个数、得分向量和载荷向量。计算载荷向量主元之间的余弦相似度,筛选出余弦相似度绝对值大于 0.9 的载荷向量主元,得到 11 组方向一致的主元向量。将 11 组方向一致的主元进行拼接并

做奇异值分解,得到大小为  $15 \times 11$  的共同特征  $W$ 。将新时段机组运行数据即序列 10 在  $W$  方向上进行投影,得到新工况时段机组运行数据在共同特征上的系数矩阵  $\phi$ ,并求出序列 10 在自己载荷向量上的系数矩阵  $\psi$ 。根据共同特征以及载荷向量之间的余弦相似度(如表 3 所示,其中加粗部分为最大的余弦相似度的值),筛选出  $W$  中的方向 5、方向 1、方向 3、方向 6 构成新的共同特征矩阵  $W_1 = [w_5, w_1, w_3, w_6]$  和新的系数矩阵  $\gamma = [\gamma_5, \gamma_1, \gamma_3, \gamma_6]$ 。共同特征矩阵的物理意义表示这些方向在新样本中与关注的主元方向具有相似的特征或变化趋势。将这些方向提取作为共同方向,并与新样本自身的特征方向一起作为新样本数据做主成分映射的依据。最后,计算出权重系数  $\delta_1$ 、 $\delta_2$  见表 4,得到调整后的特征向量  $P'$  作为预测模型监控的特征向量。

表 2 训练集基类主成分分析结果

Tab. 2 PCA results of the raining set

序列	主元个数	得分向量大小	载荷向量大小
序列1	4	1584×4	15×4
序列2	4	1283×4	15×4
序列3	4	1291×4	15×4
序列4	4	1260×4	15×4
序列5	4	1585×4	15×4
序列6	4	1294×4	15×4
序列7	3	1260×3	15×3
序列8	4	1287×4	15×4
序列9	5	1261×5	15×5
序列10	4	21×4	15×4

表 3  $\delta_1$  中方向向量与  $\delta_1$  中主元向量的余弦相似值统计

Tab. 3 Cosine similarity between direction vector and principal component vector

余弦相似度	主元1	主元2	主元3	主元4
方向1	-0.193	<b>-0.734</b>	-0.556	-0.095
方向2	0.552	-0.019	0.081	-0.564
方向3	-0.113	-0.367	<b>0.638</b>	-0.349
方向4	0.328	-0.654	-0.439	-0.212
方向5	<b>-0.720</b>	-0.486	-0.035	-0.282
方向6	0.190	0.007	0.538	<b>-0.718</b>
方向7	0.532	-0.165	-0.102	0.074
方向8	0.519	0.230	-0.570	0.407
方向9	0.391	-0.246	0.306	0.266
方向10	0.262	-0.179	0.557	-0.649
方向11	0.227	-0.111	-0.064	0.383

表 4 权重系数  $\delta_1$ 、 $\delta_2$  数值

Tab. 4 Weight coefficients of  $\delta_1$  and  $\delta_2$

$\delta_1$	$\delta_2$
0.332	0.668
0.387	0.613
0.009	0.991
0.472	0.528

### 2.3 结果分析

所选新时段的机组运行数据作为新类共有 100 个样本,选用的是从 2021 年 7 月 5 日 15:50:00 至 2021 年 7 月 6 日 08:20:00 的 1 号水泵机组正常运行工况的数据。值得注意的是,用于建模的新时段少样本最少采集 15 条数据,因为监控变量是 15 个,样本至少有 15 个,这是最少的能够体现样本之间关系的样本数。为了对比分析所提出的模型的预测效果,选用 99% 和 95% 的控制限在仅使用静态 PCA 模型、仅使用多任务学习和基于注意力机制的多任务学习 3 种情况下对模型进行训练和分析,观察统计量  $T^2$  和  $Q$  的变化情况。

静态 PCA 模型:将新类的前 15 个样本作为训练集,后 85 个样本作为测试集,模型选用静态 PCA 模型,其中 PCA 监控时使用的特征向量是新类训练集的特征向量,模型监控结果见图 2。观察统计量  $T^2$  和  $Q$  的变化可知,在测试集上模型健康效果极差,大部分超出控制限,说明该模型几乎不匹配新时段的运行状态。



(a)  $T^2$  统计量的值



(b)  $Q$  统计量的值

图 2 静态 PCA 模型的监控结果

Fig. 2 Results of the static PCA model

多任务学习模型:将新类的前 15 个样本作为训练集,后 85 个样本作为测试集,模型选用多任务学习模型,即 PCA 监控时的特征向量采用多任务学习模型得到的共同特征  $W$ ,并没有引入注意力机制根据新类的个性特征进行矫正,模型监控结果见图 3。观察统计量  $T^2$  和  $Q$  的变化可知,得到共同特征之后,未调整过权重系数直接用于监控所得到的监测结果,仍然有部分超出控制限,说明该模型不完全匹配新时段的运行状态。

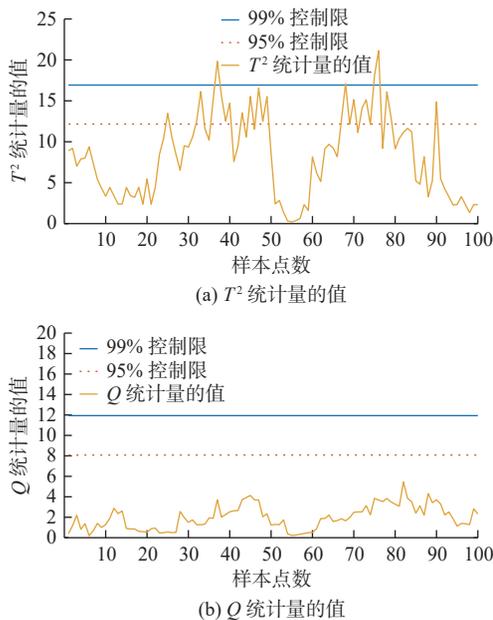


图 3 多任务学习模型的监控结果  
Fig. 3 Results of the MTL model

基于注意力机制的多任务学习模型:将新类的前 15 个样本作为训练集,后 85 个样本作为测试集,模型选用基于注意力机制的多任务学习模型,即 PCA 监控时的特征向量是经过矫正后的特征向量  $P'$ ,模型监控结果见图 4。观察统计量  $T^2$  和  $Q$  的变化可知,测试集模型监控结果没有超出控制限,说明该模型能够匹配新时段的运行状态。与静态 PCA 和多任务学习 PCA 模型相比,基于注意力机制的多任务学习模型中统计量  $T^2$  和  $Q$  所反映的模型预测效果提升效果显著,模型效果最优。

## 2.4 报警阈限确定

由测试分析结果可知,基于注意力机制的多任务学习模型可以很好地对新时段工况下基于运行数据进行匹配和预测。统计量  $T^2$  和  $Q$  既可以监控模型效果,同时也可以作为机组运行数据超限或异常的判断依据。因此,可以根据统计量  $T^2$  和  $Q$  的变化确定相应的报警阈限,建立多级别报警机制。

具体报警级别可分为黄色预警、橙色预警和红色预警。

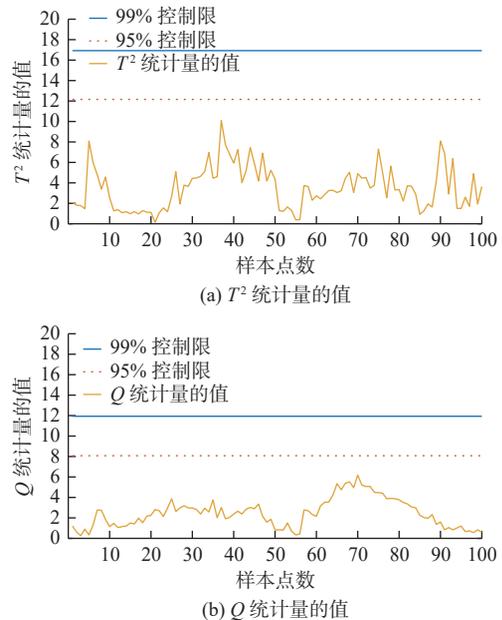


图 4 基于注意力机制的多任务学习模型监控结果  
Fig. 4 Results of the model based on MTL and AM

黄色预警:在 95% 的控制限下,允许一定程度的波动。

橙色预警:在 99% 的控制限下。

红色预警:超过 99% 的控制限。

黄色预警的目的是提醒运维人员注意监测参数的变化趋势,可能存在潜在的问题。这种预警级别不需要立即采取紧急措施,但需要加强监测和观察,以便及时调整运营策略。橙色预警表示监测参数的变化已经超出正常范围,较大可能会出现运行异常情况,此时,运维人员应当加强监测频率,深入分析异常原因,并尽可能采取一些预防性措施,以防止问题进一步恶化。红色预警意味着监测参数的变化已经严重超出正常范围,可能存在重大风险和损失。运维人员需要立即采取紧急措施,停止或调整设备运行,以避免可能的事故发生,保障设备和人员的安全。

## 3 结论

根据水泵机电运行参数数据变化的特点,建立了基于多任务学习和注意力机制的水泵机电运行参数趋势预测模型。与传统静态 PCA 模型预测方法相比,多任务学习模型可以充分利用历史数据的共同特征预测机组参数变化,充分考虑不同任务之间的相关性,提升预测模型的鲁棒性。注意力机制

的引入使得模型能够根据新时段工况下机电运行参数的特征,动态调整映射权重,进一步提高了模型的稳定的和预测的准确性。根据模型预测结果,建立了机组运行监测的多级预警系统,能够帮助运营人员根据不同级别的预警及时做出反应,保障机组的安全稳定运行,具有重要的应用价值。

#### 参考文献:

- [1] 路则峰,张昊鹏,王秀艳. 泵站机组设备健康自动监测技术应用分析[J]. *水电站机电技术*, 2024, 47(5): 55-57. DOI: 10.13599/j.cnki.11-5130.2024.05.018.
- [2] ZHAO Y, LI T, ZHANG X, et al. Artificial intelligence-based fault detection and diagnosis methods for building energy systems: Advantages, challenges and the future[J]. *Renewable and Sustainable Energy Reviews*, 2019, 109: 85-101. DOI: 10.1016/j.rser.2019.04.021.
- [3] YU K, LIN T R, MA H, et al. A multi-stage semi-supervised learning approach for intelligent fault diagnosis of rolling bearing using data augmentation and metric learning[J]. *Mechanical Systems and Signal Processing*, 2021, 146: 107043. DOI: 10.1016/j.ymsp.2020.107043.
- [4] MILOSEVIC M, RADIC M, RASIC-AMON M, et al. Diagnostics and control of pumping stations in water supply systems: Hybrid model for fault operating modes[J]. *Processes*, 2022, 10(8): 1475. DOI: 10.3390/pr10081475.
- [5] SHI H, GUO J, BAI X, et al. Research on a nonlinear dynamic incipient fault detection method for rolling bearings[J]. *Applied Sciences*, 2020, 10(7): 2443. DOI: 10.3390/app10072443.
- [6] DUTTA N, KALIANNAN P, PARAMASIVAM S J I J O A E. A comprehensive review on fault detection and analysis in the pumping system[J]. *International Journal of Ambient Energy*, 2022, 43(1): 6878-6898. DOI: 10.1080/01430750.2022.2056917.
- [7] SHORT M, TWIDDLE J. An industrial digitalization platform for condition monitoring and predictive maintenance of pumping equipment[J]. *Sensors (Basel, Switzerland)*, 2019, 19(17): 3781. DOI: 10.3390/s19173781.
- [8] GHAZALI M H M, RAHIMAN W. Vibration analysis for machine monitoring and diagnosis: A systematic review[J]. *Shock and Vibration*, 2021, 2021(1): 9469318. DOI: 10.1155/2021/9469318.
- [9] JIANG W, LI Z, ZHANG S, et al. Hydraulic pump fault diagnosis method based on EWT decomposition denoising and deep learning on cloud platform[J]. *Shock and Vibration*, 2021, 2021(1): 6674351. DOI: 10.1155/2021/6674351.
- [10] FILIPE J, BESSA R J, REIS M, et al. Data-driven Predictive Energy Optimization in a wastewater pumping station[J]. *Applied Energy*, 2019, 252: 11323. DOI: 10.1016/j.apenergy.2019.113423.
- [11] JI D, WANG C, LI J, et al. A review: Data driven-based fault diagnosis and RUL prediction of petroleum machinery and equipment[J]. *Systems Science & Control Engineering*, 2021, 9(1): 724-747. DOI: 10.1080/21642583.2021.1992684.
- [12] XU G, LIU M, WANG J, et al. Data-driven fault diagnostics and prognostics for predictive maintenance: A brief overview[C]// Proceedings of the 2019 IEEE 15th International Conference on Automation Science and Engineering (CASE), Vancouver, BC, Canada, 2019: 103-108. DOI: 10.1109/COASE.2019.8843068.
- [13] ALSAIHATI A, ELKATATNY S, MAHMOUD A A, et al. Use of machine learning and data analytics to detect downhole abnormalities while drilling horizontal wells, with real case study[J]. *Journal of Energy Resources Technology*, 2020, 143(4): 043201. DOI: 10.1115/1.4048070.
- [14] ALTAF M, ARAM T, KHAN M A, et al. A new statistical features based approach for bearing fault diagnosis using vibration signals[J]. *Sensors*, 2022, 22(5): 2012. DOI: 10.3390/s22052012.
- [15] NIE S, LIU Q, JI H, et al. Integration of ARIMA and LSTM models for remaining useful life prediction of a water hydraulic high-speed on/off valve[J]. *Applied Sciences*, 2022, 12(16): 8071. DOI: 10.3390/app12168071.
- [16] CHENG T, HARROU F, KADRI F, et al. Forecasting of wastewater treatment plant key features using deep learning-based models: A case study[J]. *IEEE Access*, 2020, 8: 184475-184485. DOI: 10.1109/ACCESS.2020.3030820.
- [17] 薛萍,张召,雷晓辉,等. 基于 BP 神经网络的不同时间尺度泵站前池水位预测模型[J]. *南水北调与水利科技(中英文)*, 2022, 20(2): 393-407. DOI: 10.13476/j.cnki.nsbdqk.2022.0040.
- [18] TANG S, ZHU Y, YUAN S J I T. Intelligent fault diagnosis of hydraulic piston pump based on deep learning and Bayesian optimization[J]. *ISA Transactions*, 2022, 129: 555-563. DOI: 10.1016/j.isatra.2022.01.013.
- [19] WISYALDIN M K, LUCIANA G M, PARIAMAN H. Using LSTM network to predict circulating water pump bearing condition on coal fired power

- plant[C]// 2020 International Conference on Technology and Policy in Energy and Electric Power (ICT-PEP), Bandung, Indonesia, 2020: 54-59. DOI: [10.1109/ICT-PEP50916.2020.9249905](https://doi.org/10.1109/ICT-PEP50916.2020.9249905).
- [20] TANG S, ZHU Y, YUAN S J A E I. An improved convolutional neural network with an adaptable learning rate towards multi-signal fault diagnosis of hydraulic piston pump[J]. *Advanced Engineering Informatics*, 2021, 50: 101406. DOI: [10.1016/j.aei.2021.101406](https://doi.org/10.1016/j.aei.2021.101406).
- [21] TANG S, YUAN S, ZHU Y J I A. Convolutional neural network in intelligent fault diagnosis toward rotatory machinery[J]. *IEEE Access*, 2020, 8: 86510-86519. DOI: [10.1109/ACCESS.2020.2992692](https://doi.org/10.1109/ACCESS.2020.2992692).
- [22] ZHU X, YU W, LI F, et al. Spatio-temporal distribution and source identification of heavy metals in particle size fractions of road dust from a typical industrial district[J]. *Science of the Total Environment*, 2021, 780: 146357. DOI: [10.1016/j.scitotenv.2021.146357](https://doi.org/10.1016/j.scitotenv.2021.146357).
- [23] ZHUANG Z, WEI C, LI B, et al. Performance prediction model based on multi-task learning and co-evolutionary strategy for ground source heat pump system[J]. *IEEE Access*, 2019, 7: 117925-117933. DOI: [10.1109/ACCESS.2019.2936508](https://doi.org/10.1109/ACCESS.2019.2936508).
- [24] ACHILLE A, LAM M, TEWARI R, et al. Task2Vec: Task Embedding for Meta-Learning[C]// 2019 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE, 2019: 6430-6439. DOI: [10.1109/ICCV.2019.00653](https://doi.org/10.1109/ICCV.2019.00653).
- [25] ZHANG J, SU Q, TANG B, et al. Dpsnet: Multitask learning using geometry reasoning for scene depth and semantics[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 34(6): 2710-2721. DOI: [10.1109/TNNLS.2021.3107362](https://doi.org/10.1109/TNNLS.2021.3107362).
- [26] JIANG L, LI X, WU L, et al. Bearing fault diagnosis method based on a multi-head graph attention network[J]. IOP Publishing Ltd, 2022, 33(7): 075012.

## Prediction model for pump unit operating parameters based on multi-task learning and attention mechanism

SHAO Zhiyu<sup>1</sup>, XUE Meiling<sup>2</sup>, HE Cong<sup>3</sup>, LI Jingwei<sup>1</sup>, TANG Hongru<sup>1</sup>

(1. School of Electrical and Energy Power Engineering, Yangzhou University, Yangzhou 225009, China; 2. Jiangsu Jiangdu Water Conservancy Project Management Office, Yangzhou 225009, China; 3. Nanjing Institute of electronic equipment, Nanjing, 210007, China)

**Abstract:** The safe and stable operation of the pumping station system is of great significance for ensuring supply for domestic water agricultural irrigation, and industrial water. Therefore, real-time monitoring of pump station operating parameters and establishing predictive models for fault diagnosis and intelligent alarm of unit equipment have significant application value. The data-driven method for fault diagnosis is currently a hot topic in the research of pump station equipment status monitoring. However, there are problems such as insufficient data samples, difficulty in feature extraction, and insufficient generalization ability in practical application.

Addressing the challenge of predicting the trends in operating parameters of water pump units under complex working conditions, a prediction model for operating parameters of water pump units was proposed based on multi-task learning method and attention mechanism. Firstly, the historical working condition data was fully utilized, and a multi-task learning model was established to find the common characteristics of the historical working condition data on the basis of traditional principal component analysis methods. Secondly, an attention mechanism was introduced to dynamically allocate weight coefficients for common feature mapping when predicting the trend of parameter changes under new operating conditions, highlighting key common features and improving the accuracy of the prediction.

Based on the actual operating data of a pumping station hub unit, the performance of the model was tested. By monitoring the statistical parameters  $T^2$  and  $Q$ , which reflecting the stability and accurately of the model, results showed that the prediction model proposed has good stability and prediction accuracy under 98% and 95% control thresholds. On this basis, a multi-level equipment operation monitoring and alarm model was also preliminarily established. The alarm level is divided into three levels: yellow, orange, and red. Management personnel can take different disposal measures based on the alarm level, such as paying attention to observation, strengthening

(下转第 977 页)