

基于深度迁移的新型机械类装备故障数量预测

张红梅, 程湘钧, 柳 泉, 拓明福, 唐希浪, 徐思宁

(空军工程大学装备管理与无人机工程学院, 西安, 710051)

摘要 针对新型机械类装备在试验鉴定阶段样本量较少, 难以建立故障数量预测深度模型评估保障性能的问题, 采用了“迁移学习”方法, 提出了 Score 评价指标, 使用大规模成熟型别装备数据辅助新型装备故障预测模型训练。从迁移学习的样本、特征、模型 3 个角度出发, 以基于深度模型的迁移为重点, 进行故障数量预测研究。实例表明, 基于微调的模型深度迁移在均方根误差与 Score 评价指标上精度分别相对提升了 46.55% 和 164.87%, 标准差分别下降了 86.71% 和 91.41%, 远优于基于样本和特征层次设计应用的迁移预测方法与 7 种典型对比模型, 使得深度学习的数据驱动优势得以充分发挥。在预测精度、效果与稳定性上具有更好表现, 有利于评估新装备保障性能, 推动了装备试验鉴定能力建设。

关键词 迁移学习; 深度学习; 回归预测; 小样本; 微调; 装备试验鉴定

DOI 10.3969/j.issn.2097-1915.2025.04.001

中图分类号 TP181 **文献标志码** A **文章编号** 2097-1915(2025)04-0001-10

A Prediction of Number of Faults in New Mechanical Equipment Based on Deep Transfer

ZHANG Hongmei, CHENG Xiangjun, LIU Quan, TUO Mingfu, TANG Xilang, XU Sining
(Equipment Management and Unmanned Aerial Vehicle Engineering School, Air Force Engineering University, Xi'an 710051, China)

Abstract In view of the problems that samples are limited in size and difficult in establishing a deep model for predicting the number of faults to evaluate the support performance of new mechanical equipment at the stage of testing and identification, a Score evaluation index is proposed by adopting the “transfer learning” method. Large scale mature equipment data was used to assist in training the new equipment fault prediction model. Starting from the perspectives of samples, features, and models in transfer learning, with a focus on deep model-based transfer, this study conducts research on predicting the number of faults. The example shows that the precision of the fine-tuning based model deep transfer has increased by 46.55% and 164.87% respectively in the root mean square error and Score, while the standard deviation has decreased by 86.71% and 91.41% respectively. Far superior to the prediction methods based on sample and feature in design applications of transfer learning and seven typical comparative models, the data-driven advantages of deep learning are fully utilized. With better performance in prediction accuracy, effectiveness, and stability, it is conducive to evaluating the support performance of new equipment and promo-

收稿日期: 2025-02-19

基金项目: 国家自然科学基金(72201276)

作者简介: 张红梅(1970—), 女, 山西临猗人, 教授, 博士, 研究方向为计算机应用技术。E-mail: zhm_plum@163.com

引用格式: 张红梅, 程湘钧, 柳泉, 等. 基于深度迁移的新型机械类装备故障数量预测[J]. 空军工程大学学报, 2025, 26(4): 1-10. ZHANG Hongmei, CHENG Xiangjun, LIU Quan, et al. A Prediction of Number of Faults in New Mechanical Equipment Based on Deep Transfer[J]. Journal of Air Force Engineering University, 2025, 26(4): 1-10.

ting the construction of equipment test and evaluation.

Key words transfer learning; deep learning; regression prediction; small sample size; fine tuning; equipment test and evaluation

随着我国科学技术的迅速发展,大量新技术、新材料、新工艺被应用于工业生产,推动航空装备不断迭代更新,新装备的研制和试验鉴定工作面临着前所未有的挑战。试验鉴定作为武器装备建设的重要组成部分,其核心在于通过严格的试验和评估,有效摸清新装备性能效能底数^[1],在采集大量数据的基础上,通过建立故障数量预测模型,服务于保障性评估,确保其满足作战需求。在数理统计方法下,数百样本便满足要求,但对于正在发展的深度学习类方法,对样本要求在千级及以上^[2]。然而,新型机械类装备数量不足、使用时间短、实践次数少,难以对其采集到符合要求的样本量^[3],在预测模型建立过程中往往面临数据不足、波动性大的问题,使得建立的模型难以反映客观现实,限制了对其故障预测的准确性,难以评估新装备保障性能,制约了深度学习方法在新装备评估上的运用,亟需探索运用新技术以增强装备试验鉴定能力。

“小样本”通常是指样本量相对较小的情况,在本文所涉及的研究问题中,“小样本”指样本量过小无法满足深度神经网络模型训练需要的情况,导致基于深度神经网络的预测模型无法实现应有性能,难以发挥深度学习的数据驱动优势。针对新装备试验数据不足、样本量少的特点,学者们提出了多种方法用于解决这一问题。在传统实践上往往采用经验估计^[3]、数理统计参数估计^[4]等方法,文献[5]从温度载荷下的失效机理出发建立融合失效模型,结合加速退化试验对故障模式影响与危害性分析方法改进,实现了更准确的指标计算,但需要设计者具有对某类产品的深入研究,并付出大量时间精力进行精细化建模;文献[3]提出结合多个来源的规范化数据采集与预处理实现数据融合以拓展样本数量,但仍然使用基于分布假设检验与定义及数学模型的方法,难以适应复杂设备的非线性特征;文献[6]使用离散事件仿真对舰载机保障过程建模,较好刻画了复杂过程的不确定性,有效地实现了对于通用质量特性下多指标的一体化论证,但需要分析详细的内在机理用于过程建模。

随着研究的逐步深入,学者们发现可以将已有的大规模样本通过一定的方法,迁移应用于仅有小规模样本的研究问题上,形成了“迁移学习”的专门研究领域。迁移学习通常分为基于样本的迁移学习^[7-8]、基于特征的迁移学习^[9-10]和基于模型的迁移

学习^[11-12],国内外学者在大规模样本对象迁移于小规模样本对象应用方面做了大量研究。特征层面,文献[13]将局部最大均值差异引入深度网络,不需要对抗训练即可对其不同域中的子域分布实现快速迁移;文献[14]使用最大均值差异将仿真数据与现实数据对齐,相比生成对抗网络方法具有更好迁移能力;文献[15]使用联合分布适配进行映射,缩小了不同时空下水声场数据之间分布差异;文献[16]将不同情况下的多域特征通过联合分布适配缩小差异,有效提高了识别精度;文献[17]将卷积层提取的特征采用多核最大均值差异算法进行联合适配,分类准确率显著提高。模型层面,文献[18]从物理信息机器学习角度出发针对性设计损失函数,将概率疲劳寿命分析理论引入机器学习模型,实现知识层面迁移应用;文献[19]将预训练 DenseNet 网络后两层替换并提高学习率,在小样本集中方向取得了良好效果;文献[20]分别采用权重配比样本特征融合方法、分层训练模型特征融合方法,在精准度与拟合度上均优于传统气动力预测模型;文献[21]使用大样本老式装甲车辆图像数据集对 CNN 模型预训练,在小样本新装备图像数据集上微调,有效提升了其表征能力。上述研究表明,迁移学习可以有效地将采集于已有装备的大规模数据,应用于新装备的模型构建,来缓解新装备试验样本不足的问题。

而对于新型机械类装备,其内在系统构成复杂,精细化建模困难,仅能采集到多特征但少量的传感器数据与装备使用保障统计数据,考虑到机械类装备具有技术上的继承性、使用上的相似性以及特征指标上的通用性,成熟型别的机械类装备已经具有较大规模的历史数据,在实际使用中也常常在新装备确定指标时参考已有装备的相关数据,因此采用“迁移学习”方法,使用大规模成熟型别机械类装备数据,辅助新型别机械类装备的故障预测模型训练,从研究对象外部获取知识用于解决样本不足的问题。

因此,本文从迁移学习样本、特征、模型 3 个角度出发,以基于深度模型的迁移为重点进行研究,来自成熟型别机械类装备集群的样本为源域,新型别机械类装备集群试验样本为目标域,学习任务为相同指标下多特征时间序列故障数量预测,进行模型的训练,并引入传统训练、预训练、统计学模型、两种典型机器学习与两种常用迁移学习作为对照,分析

比较上述方法的准确度与适用性,如图1所示。




图1 新装备故障数量预测图

Fig. 1 Diagram for predicting new equipment malfunctions

1 深度迁移预测方法研究

1.1 长短期记忆神经网络

长短期记忆神经网络(long short-term memory, LSTM)作为循环神经网络的变体发展而来,通过“细胞状态”来存储长期记忆,使用“门控机制”来对“细胞状态”进行更新,遗忘不重要信息,留下重要的信息,然后结合当前时刻输入与上一时刻输出(即短期影响)得到当前时刻输出,最终较好地解决长期依赖问题,实现对序列数据的处理^[22],LSTM单元结构如图2所示。




图2 长短期记忆神经网络结构

Fig. 2 LSTM neural network architecture

1.2 注意力机制

注意力机制源自人类对于外界环境的生理性感知特点,本质是一种资源分配机制,使用有限处理资源快速提取高价值信息。而对于深度学习中的注意力机制,体现在根据权重系数来表示信息的重要程度,主要包括:目标数据 Target(由 Query 构成)、源数据 Source(由键值对 Key 与 Value 构成)、注意力得分 Score 与注意力值 Attention。通过计算 Query

和各个 Key_i 之间的相似度,从而得到相应 Value 的权重系数(即注意力得分 Score,用于表示注意力的分布),然后进行加权求和得到注意力值 Attention,核心公式如式(1)所示^[23]:

$$\text{Attention}(\text{Query}, \text{Source}) =$$

$$\sum_{i=1}^{L_x} \text{Similarity}(\text{Query}, \text{Key}_i) \cdot \text{Value}_i \quad (1)$$

式中: L_x 为 Source 长度,即键值对数量;Similarity 为计算相似度函数。

因此,注意力机制的计算可以归纳为3个阶段。

第1阶段,计算相似度,可采用向量点积、余弦相似度和神经网络等方法。通常采用缩放点积,第 i 个键对应相似度 Sim_i 如式(2)所示:

$$\text{Sim}_i(\text{Query}, \text{Key}_i) = \frac{\text{Query} \cdot \text{Key}_i}{\sqrt{d}} \quad (2)$$

式中: d 为 Query 的维度(与 Key_i 的维度相同),用于进行缩放调节,使得点积不至于过大,起到维持梯度的作用。

第2阶段,引入归一化计算注意力得分 Score,将原始权重整理为权重之和为1的概率分布。通常采用 Softmax 函数,如式(3)所示:

$$\text{Score}_i = \text{Softmax}(\text{Sim}_i) = \frac{e^{\text{Sim}_i}}{\sum_{j=1}^{L_x} \text{Sim}_j} \quad (3)$$

第3阶段,加权求和得到注意力,如式(4)所示:

$$\text{Attention}(\text{Query}, \text{Source}) = \sum_{i=1}^{L_x} \text{Score}_i \cdot \text{Value}_i \quad (4)$$

由此,便求出 Query 所对应的注意力值 Attention,如图3所示。




图3 注意力机制过程

Fig. 3 Processes of attention mechanism

1.3 基于参数冻结的微调方法

基于模型的迁移学习将可迁移的知识编码到参数、先验知识与架构等模型层次上,使用在源域数据基础上建立的模型辅助目标域模型学习。随着深度学习的广泛应用,在大量数据基础上可以得到预训练模型,然后针对具体任务使用小规模有标签数据对预训练模型进一步训练,被称为“微调”方法。通过分析神经网络的层次结构以及大量实验证明^[24],前几层神经网络学习到的为通用特征,后面的网络层更偏向于学习特定的特征,通过冻结底层网络,使

用目标域数据微调上层网络,可以较好地克服不同域之间的差异性,加速目标域网络训练与优化,如图4所示。




图4 基于模型的迁移学习

Fig.4 Model based transfer learning

本文在已有的机械类装备大规模数据上建立了基于注意力机制的混合神经网络,对新装备小规模样本数据,目标域与源域数据结构相同、使用保障状态相似,因此使用参数微调方式实现知识迁移。

2 实例验证与分析

本文以某新型机械类装备A为例,通过收集仿真与小规模使用场景下的试验数据,共获取350组数据作为目标域。使用同系列成熟型别装备B在实际应用场景下35 064组大规模使用数据作为源域,已对数据进行了缺失值填补、标准化、脱敏等处理,基于多个体监测传感器所采集的时间段数据,通过统计量来构建使用保障统计数据以描述集群状态,选择27个集群状态的通用监测参数作为特征,目标是预测故障数量,分别采用基于深度模型的微调方法(fine tuning based on deep model, FT-DM)、基于动态时间弯曲距离的样本拓展方法(sample expansion based on dynamic time warping, SEDTW)、基于联合分布适配的特征映射方法(feature mapping based on joint distribution adaptation, FM-JDA)、相关对齐(correlation alignment, COR-AL)、域对抗神经网络(domain adversarial neural network, DANN)与传统深度学习方法(traditional deep learning, TDL)、预训练模型方法(pretrained model, PTM)、差分整合移动平均自回归模型(auto regressive integrated moving average model, ARI-MA)以及随机森林回归(random forest regression, RFR)、支持向量机回归(support vector regression, SVR)进行分析。由于本文研究对象为时间序列数据,为对比验证迁移学习的效果,以专注于时间序列问题的ARIMA作为基准方法。

将A、B数据集中原始特征数据进行归一化处

理,通过直方图观察、核密度估计、Mann-Whitney U检验与Kolmogorov-Smirnov检验分析不同型别在同一特征下的数据分布,发现两种装备的部分特征分布范围存在明显差异,同时在重合范围内特征分布倾向不同,加之特征间存在的复杂非线性关系,其分布特点及影响关系难以准确描述。

2.1 评价指标

评价指标可用于量化模型预测性能和进行参数优化调节。本文使用损失得分函数(Score)作为优化指标,并综合损失得分函数与均方根误差(root mean squared error, RMSE)进行评价。

均方根误差是用于衡量模型预测值与真实值误差的指标,由于预测值应当为整数,采用“四舍五入”规则进行取整,如式(5)所示:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \text{round}(\hat{y}_j))^2} \quad (5)$$

式中: n 为测试样本个数; y_j 为第 j 个样本真实值; $\hat{y}_j$ 为第 j 个样本预测值; $\text{round}(x)$ 表示对 x 就近取整。

评分函数(Score₂₀₀₈)在PHM2008数据比赛中被提出用于评价剩余使用寿命预测模型性能,将其误差映射为非对称得分,结合本文研究实际,将原有Score₂₀₀₈进行改进,定义损失得分函数Score,计算式如式(6)所示:

$$h_j = \hat{y}_j - y_j \quad (6)$$

$$s_j = \begin{cases} d(h_j + m) + e^{\frac{-m}{10}} - 1, & h_j < -m \\ e^{\frac{-h_j}{10}} - 1, & -m \leq h_j < 0 \\ e^{\frac{h_j}{13}} - 1, & 0 \leq h_j < m \\ d(h_j - m) + e^{\frac{m}{13}} - 1, & h_j \geq m \end{cases} \quad (7)$$

$$d = -\frac{1}{10}e^{\frac{-m}{10}} + \frac{1}{13}e^{\frac{m}{13}} \quad (8)$$

$$\text{Score} = \frac{1}{n} \sum_{j=1}^n s_j \quad (9)$$

式中: $\hat{y}_j$ 为对第 j 个样本的预测值; y_j 为第 j 个样本真实值; h_j 为模型预测值与真实值之差; m 为分段阈值; d 为在分段处的导数; n 为测试样本个数; s_j 为第 j 个样本的得分;Score为平均得分。

Score₂₀₀₈适用于剩余使用寿命预测, RMSE对于超前、滞后预测的评估趋势一致,而Score₂₀₀₈以不同方式对二者区别预测,突出了超前预测比滞后预测更有意义,被广泛认可与采用^[22, 25]。本文针对机械类装备故障数量进行预测,缺量预测会导致装备补充数量无法满足部队需求,造成作战训练难以正常开展,需要给予较大惩罚;而超量预测虽然会带来一定经济损失,但可以增加备份数量,在之后逐

渐“消化”,可以给予较小惩罚。由于本文所研究的数据量以及目标数据取值范围较大,若直接使用原始的 Score_2008,受其求和方式与指数模型影响,极易导致误差计算溢出与“梯度爆炸”现象,导致训练中断,因此在保留误差非对称映射特点前提下,将 Score_2008 进行如下改进:

- 1)对 y 轴对称,确定超量预测的导向作用;
- 2)求均值代替求和,减少样本数量敏感度;
- 3)进行指数与线性模型的分段处理,误差较小时使用指数模型,使梯度大小随误差增大而增大,并在小误差下进行微小调整便于接近最优解,误差较大时转用线性模型,维持较大梯度加速训练,同时防止指数增长引发“梯度爆炸”现象。

由此得到损失得分函数 Score,损失得分越小则说明模型预测性能越好。RMSE、Score_2008 与 Score 的函数图像如图 5 所示,可见 Score 函数在超量预测导向性与梯度大小平衡性方面更具有优势。




图 5 RMSE、Score_2008 与 Score 函数

Fig. 5 RMSE、Score_2008 and Score functions

2.2 模型建立

采用滑动窗口方法构建时间序列^[25]。原始样本大小为 N ,特征维度 F 为 27,通过探索性实验确

定滑动窗口长度 B 为 5,预测步长 P 为 1,即输入模型的单个样本为矩阵 $\mathbf{X}_{B \times F}$,滑动窗口样本大小为 $N-B+1$,预测标签为窗口下个交易日故障数量。

将本文研究问题视为传统时间序列预测与典型机器学习问题,分别使用 ARIMA、RFR、SVR 进行回归预测。使用遗传算法在训练集上进行随机交叉检验确定超参数,应用于测试集进行测试。

单一模型难以捕捉复杂非线性规律,因此基于成熟型别机械类装备大规模数据集,设计了一种基于注意力机制的混合神经网络用于预测故障数量,该模型在成熟型别装备已被证明具有良好表现,网络结构如图 6 所示。

该模型采用最大池化方式进行降维,通过相同填充法处理边缘问题,在全连接层引入随机失活。一维卷积层卷积核数量为 d_1 ,卷积核大小为 k_1 ,最大池化层的窗口大小为 k_2 ,LSTM 层输出维度为 d_2 ,全连接层节点数为 d_3 ,随机失活率为 l_1 ,学习率为 l_2 ,激活函数均采用线性整流函数,输出层采用线性激活函数,损失函数设置为损失得分 Score,使用 Adam 优化器,采用早停法防止过拟合,阈值为 0.01,耐心度为 30,模型取最优状态权重。经过贝叶斯优化,超参数设置如表 1 所示。

表 1 超参数设置

Tab. 1 Hyperparameter setting

超参数	值
d_1	30.000
d_2	10.000
d_3	20.000
k_1	4.000
k_2	2.000
l_1	0.200
l_2	0.001




图 6 基于注意力机制的混合神经网络

Fig. 6 Hybrid neural network based on attention mechanism

为研究“小样本”特点及样本量对模型的影响,使用不同数量级样本量测试上述模型的预测能力。

将 B 型别装备数据按照 7:3 比例划分为评估集和测试集,在评估集上分别抽取不同数量级的样本,呈

1%、2%、3%、5%、10%、30%、50%、70%、100%非等距阶梯分布,按照 7:3 比例划分为训练集和验证集,计算均值和标准差以度量模型的预测能力与预测稳定性,检验不同样本量对深度模型的影响。

将该问题视为迁移学习问题,使用 CORAL 最小化源域和目标域数据的二阶统计量差异来实现域适应,以及 DANN 经过遗传算法调优后,在源域和目标域训练数据上进行训练,对数据进行特征映射。对齐后的数据使用深度模型进行训练与预测。

使用 SE-DTW 筛选获得拓展样本,将 B 型装备数据作为源域选择拓展样本,合并后的样本用于模型训练。通过 FM-JDA 进行特征层面的迁移,将多元时间序列后二维(时间维、特征维)作为新特征,使用 JDA 适配寻找特征映射矩阵^[26],将映射后的数据恢复数据形状用于混合神经网络模型训练。

使用 B 型装备数据预训练混合神经网络模型,测试 RMSE 与 Score 分别为 19.867 2 和 6.640 7,模型中共 5 563 个参数,使用 A 型装备训练数据对全连接层与输出层进行微调,即对最后 2 层的 641 个参数进行训练,使用测试数据对微调模型进行评估。

2.3 结果分析

在样本量与深度神经网络模型预测能力的实验中,可以发现预测误差与预测不稳定性随样本量增加呈非线性下降趋势,初期下降速率较快,随着样本规模扩大逐渐趋于平缓,不同数量级样本对深度模型预测能力具有显著影响,如图 7 所示。




图 7 样本数量级与深度模型预测能力

Fig. 7 Number of samples and prediction ability of deep model
本实例中新装备 A 样本量仅为实验中可用样

本量的约 1%,无法满足模型训练需要,属于典型小样本场景,需要采用新方法实现有效预测评估。

针对小样本的装备 A 数据建立预测模型,以 ARIMA 为基准方法,与其余 8 种预测模型以及深度迁移学习方法多次训练测试进行对比。

其中,ARIMA 模型采用统计学方法,SVR 使用核函数进行映射,而 PTM 已经完成训练,均不受随机条件影响;TDL、RFR、CORAL、DANN 与 SE-DTW、FM-JDA、FT-DM 3 种迁移学习方法在训练模型时,受到随机条件影响,导致每次训练的模型不同,预测受随机条件影响,因此需要进行多次实验评估方法训练得到模型的稳定性。

从模型集成与评价指标分布 2 个方面考虑对预测方法的准确度与稳定性进行评估。


从模型集成角度而言,将多次实验的预测值进行平均处理,与真实值比较从而得到评价指标 RMSE_G 与 Score_G,如表 2 所示。

表 2 模型集成下预测方法性能对比

Tab. 2 Performance comparison of prediction methods under model integration

方法	RMSE _G	变化率/%	Score _G	变化率/%
ARIMA	26.337 8		13.135 0	
PTM	31.851 5	20.93	29.527 2	124.81
RFR	28.510 4	8.25	16.128 5	22.80
SVR	29.091 5	10.46	20.066 2	52.77
CORAL	31.653 4	20.18	12.807 1	-2.49
DANN	31.522 9	19.69	15.404 8	17.29
TDL	32.801 7	24.54	17.508 1	33.30
SE-DTW	34.611 4	31.41	20.612 7	56.94
FM-JDA	23.400 3	-11.15	9.797 7	-25.40
FT-DM	24.476 1	-7.07	7.686 3	-41.48

从评价指标分布的角度,对每次实验中训练得到的模型进行评价指标计算,然后统计各个方法评价指标的分布情况。各个方法的 RMSE 与 Score 分布如图 8 所示。






图 8 评价指标分布

Fig. 8 Distribution of evaluation indicators

模型集成角度能够反映方法在多次预测中的综合性能,减少单次预测带来的偶然性误差。评价指标分布则考虑了每次预测的性能,能够反映出预测方法在不同情况下的稳定性。

由于 ARIMA、SVR 与 PTM 不受随机条件影响,所以预测标准差不具备传统统计推断意义,故采用 TDL 作为标准差的基准方法。两种评估角度下不同方法相对于基准方法变化趋势相似,相互印证减少随机条件影响,使得结果可信。评价指标分布下预测方法平均值、标准差以及变化率如表 3 所示。

表 3 评价指标分布下预测方法性能对比

Tab. 3 Performance comparison of prediction methods under distribution of evaluation indicators

方法	RMSE				Score			
	平均值	变化率/%	标准差	变化率/%	平均值	变化率/%	标准差	变化率/%
ARIMA	26.337 8				13.134 5			
PTM	31.851 5	20.93			29.527 2	124.81		
RFR	28.571 3	8.48	0.350 5	−77.55	16.275 6	23.91	0.913 5	−23.07
SVR	29.091 5	10.46			20.066 2	52.77		
CORAL	33.852 0	28.53	2.034 1	30.25	15.289 4	16.41	1.283 1	8.05
DANN	34.401 0	30.61	2.110 8	35.16	18.650 0	41.99	2.888 6	143.26
TDL	33.795 7	28.32	1.561 7		18.693 2	42.32	1.187 5	
SE-DTW	35.465 7	34.66	1.317 3	−15.65	21.736 9	65.50	1.596 6	34.45
FM-JDA	24.230 1	−8.00	0.939 9	−39.82	10.737 7	−18.25	1.437 4	21.05
FT-DM	24.547 7	−6.80	0.207 5	−86.71	7.744 6	−41.04	0.102 0	−91.41

ARIMA 作为经典时间序列预测算法,在小样本下能够较好捕捉到时序特点,但明显具有滞后性。

PTM 使用在 B 型装备数据上训练好的预训练模型对 A 型装备测试集进行预测,发现预训练模型掌握了该系列装备故障数量一定的变化规律,但由于数据分布不同,使得预测基准存在较为稳定的偏差,造成严重的缺量预测,不符合实际应用目的,但也说明了 B 型装备特征数据分布能够反映出一定的深层次共有性规律,可应用于 A 型装备模型。

RFR 与 SVR 作为典型机器学习算法,相比于深度学习算法,对样本数量要求较低,在 A 型装备数据上具有较好的效果,但难以自定义损失函数,缺少“超前预测”的实际应用导向,明显在部分样本上存在缺量预测,说明了 Score 评价指标的优势,同时二者预测精度劣于针对时序问题的 ARIMA。

CORAL 与 DANN 作为常用的迁移学习方法,体现出一定的迁移能力,但远不能满足复杂多元特征下需要。CORAL 仅通过二阶统计量以变换源域特征与目标域对齐,难以捕捉深层次分布关系。DANN 基于生成对抗原理训练特征提取器以提取

域之间的不变特征,但训练过程不稳定,容易出现模式崩溃,使得整体预测结果呈现高方差特点。此外,两种方法本身具有无监督自适应特点,没有充分利用已知的目标域标签信息。

仅使用目标域训练数据进行深度学习训练的 TDL,由于样本过少,使用复杂神经网络模型难以捕捉到非线性关系,仅拟合到大致趋势,处于欠拟合状态,具有较大误差。典型训练曲线如图 9 所示,缺少下降调整过程,学习到的关系较为浅层。




图 9 传统深度学习方法下训练曲线

Fig. 9 Training curve under traditional deep learning methods

SE-DTW 通过基于 DTW 四分位法拓展样本,在 RMSE 下预测范围有所聚焦。但仅有约 0.52% 的源域样本被判定与目标域样本相似,源域与目标域数据在形式上存在较大差异,同时引入源域样本反而使预测精度下降,造成“负迁移”,说明 DTW 难以准确度量样本间相似性,不同型别装备试验数据表现差异性大,不属于同分布,影响关系复杂。

FM-JDA 通过 JDA 进行特征映射后,在高维空间中样本趋于同一分布,变换后的特征更为集中,同时暴露出更明显关系,有利于模型学习,但缺乏对已有信息的有效利用,同时映射后更关心于绝对误差信息,对缺量、超量的关系有所失真。

FT-DM 在 B 型大规模成熟型别装备数据上得到的预训练模型上,使用 A 型新装备的小样本数据进行微调,对于压缩在权重内的知识过于隐式使得训练呈现波动调整,如图 10 所示,可见模型由原装备故障模式向新装备故障模式的显著迁移趋势。预训练模型在学习到通用性变化规律基础上,只需要少量新装备样本即可实现较好迁移。




图 10 基于模型的迁移学习训练曲线

Fig. 10 Training curve based on model-based transfer learning

综上所述,ARIMA 模型具有滞后跟随性特点,PTM 能够学习到一定通用关系但对具体全貌难以掌握,TDL 受限于样本量大小易欠拟合,典型机器学习的 RFR 与 SVR 可在少样本下具有相对一般深度学习更好效果。在迁移学习中,常用的 CORAL 与 DANN 难以捕捉深层次关系,没有充分利用已有信息,不同分布下样本的复杂性使得 SE-DTW 造成负迁移现象,而 FM-JDA 和 FT-DM 能够较好地将源域中抽象的特征、知识应用于目标域的模型训练中,与 ARIMA 模型相比,在 RMSE 与 Score 评价指标上平均值分别下降 8.00% 和 6.80%、18.25% 和 41.04%。在深度学习中,以在 B 型装备大规模样本上采用 TDL 正常训练为基准,采用 FT-DM 与 FM-JDA 相比于采用 TDL 在 A 型装备小规模样本上直接训练,精度分别相对提升了 48.15%、119.80%、46.55% 和 164.87%。此外 FT-DM 预测

标准差分别下降 86.71% 和 91.41%,具有更高预测精度、更好预测效果与更强稳定性。

3 结论

本文针对装备试验鉴定场景下新型机械类装备的小样本特点,阐述了基于深度模型的迁移学习理论,结合研究对象特点提出了损失得分函数 Score 用于故障数量预测,针对性设计了基于深度模型的微调方法来具体实现。通过在两型装备数据集上开展实例研究,从模型集成与评价指标分布两种评估角度出发,得到如下结论:

1)随着样本量的增加,深度模型的预测误差与不稳定性呈非线性下降趋势,初期下降速率较快,随着样本规模的扩大逐渐趋于平缓。样本量过小无法满足深度神经网络模型训练需要,导致虽收敛但缺乏泛化能力,无法实现应有性能。小样本对深度神经网络模型预测性能具有显著负面影响,而在小样本条件下对样本数量的增加对模型预测能力的提升具有显著效益,但同时存在边际递减现象。

2)在小样本条件下,传统统计方法、典型机器学习方法、常见迁移学习方法优于一般深度学习方法。传统深度学习方法受限于样本数量,难以发挥深度学习的数据驱动优势,而不同型别样本下得到的预训练模型能够捕捉通用规律,在具体细节方面难以掌握。导致在新装备试验鉴定中,难以建立可靠的故障数量预测深度模型评估保障性能,制约了深度学习方法在新装备评估上的运用,亟需探索运用新技术以增强装备试验鉴定能力。

3)本文所提出的基于深度迁移学习方法在预测精度、效果与稳定性上优于 9 种对比方法,可有效应用于小样本场景。不同类别的机械类装备具有通用性的监测参数作为特征,但数据分布以及对故障数量的影响机理上存在较大差异,在高维空间下底层网络能够学习到通用性变化规律,通过少量新装备样本微调便可实现快速迁移。

4)损失得分函数 Score 与 Score₂₀₀₈、RMSE 相比,在装备故障数量预测上具有更好适用性与实际导向作用,能够更好评估模型性能,在加快模型训练同时减少“梯度爆炸”现象,在该问题上具有更好的应用价值,有利于优化预测效果。

5)通过深度迁移学习的方法可以对传统深度学习模型进行改进,充分利用已有成熟型别装备的大规模样本数据,快速简便实现迁移预测应用。显著缓解了新型装备试验不足、样本不足的问题,有利于发挥数据驱动优势,使得模型学习到实际应用场景

中更加复杂情况下的非线性关系,克服试验设计不够全面的缺点,具有更好的泛化性能。与传统深度学习模型、迁移学习模型以及统计学模型、典型机器学习模型相比,在预测精度、效果与稳定性上具有更好的表现,有利于更好对新装备的保障性能进行有效评估,推动了装备试验鉴定能力建设。

下一步考虑研究不同型别装备之间的特征在高维下的分布特点与映射关系,将特征映射、对抗调整方法引入到深度学习中以构建一体化的端到端模型,以及考虑对于多型别迁移、异构数据迁移的研究,并增强迁移学习模型的可解释性,进一步提高对新装备保障效能的评估能力。

参考文献

- [1] 薛卫,谢伟朋,郑超. 装备试验鉴定技术需求生成理论研究[J]. 中国电子科学研究院学报, 2021, 16(8): 839-843, 850.
- XUE W, XIE W P, ZHENG C. Research on Demand Generation Theory of Equipment Test and Evaluation Technology[J]. Journal of China Academy of Electronics and Information Technology, 2021, 16(8): 839-843, 850. (in Chinese)
- [2] 曹荧荧, 郇战, 陈震, 等. 基于小样本学习的滚动轴承故障检测[J]. 数据采集与处理, 2024, 39(4): 1033-1042.
- CAO Y Y, HUAN Z, CHEN Z, et al. Rolling Bearing Fault Detection Based on Few-Shot Learning[J]. Journal of Data Acquisition & Processing, 2024, 39(4): 1033-1042. (in Chinese)
- [3] 李娇, 蒋觉义. 多源数据驱动下的航空装备状态鉴定通用质量特性评估方法研究[J]. 航空标准化与质量, 2023(1): 39-44.
- LI J, JIANG J Y. Research on the General Quality Characteristics Evaluation Method for Aviation Equipment Status Identification Driven by Multi Source Data[J]. Aeronautic Standardization & Quality, 2023(1): 39-44. (in Chinese)
- [4] 吴慧伦, 柴霖, 李威. 空间站有效载荷通用质量特性协同设计[J]. 载人航天, 2023, 29(3): 398-406.
- WU H L, CHAI L, LI W. Collaborative Design of General Quality Characteristics for Payloads in Space Station[J]. Manned Spaceflight, 2023, 29(3): 398-406. (in Chinese)
- [5] 杨金鹏, 连光耀, 李会杰. 温度载荷条件下的新装备故障模式影响及危害性分析[J]. 中国测试, 2019, 45(8): 156-160.
- YANG J P, LIAN G Y, LI H J. Failure Mode Effect and Critically Analysis of New Equipmen under Thermal Loadings[J]. China Measurement & Test, 2019, 45(8): 156-160. (in Chinese)
- [6] 祝华远, 李军亮, 张陕辉, 等. 舰载机通用质量特性指标论证[J]. 舰船科学技术, 2023, 45(8): 185-189.
- ZHU H Y, LI J L, ZHANG S H, et al. Demonstration of Carrier-Based Aircraft Universal Quality Characteristic Indicators[J]. Ship Science and Technology, 2023, 45(8): 185-189. (in Chinese)
- [7] 王晓霞, 艾兴成, 王涛. 基于实例迁移学习的小样本光伏功率短期预测[J]. 太阳能学报, 2024, 45(6): 325-333.
- WANG X X, AI X C, WANG T. Few-Shot Photovoltaic Power Short-Term Forecasting Based on Instance Transfer Learning[J]. Acta Energiæ Solaris Sinica, 2024, 45(6): 325-333. (in Chinese)
- [8] 方熙, 王怀远, 党然, 等. 考虑样本加权的迁移学习暂态稳定评估模型更新方法[J]. 福州大学学报(自然科学版), 2023, 51(6): 777-783.
- FANG X, WANG H Y, DANG R, et al. Transfer Learning-Based Updating Method of Transient Stability Assessment Model Considering Sample-Weighted[J]. Journal of Fuzhou University (Natural Science Edition), 2023, 51(6): 777-783. (in Chinese)
- [9] 徐进, 赵慧祺, 张泽慧, 等. 基于特征差异增强的工程装备知识跨项目多源域迁移学习研究[J]. 系统工程理论与实践, 2024, 44(3): 1097-1113.
- XU J, ZHAO H Q, ZHANG Z H, et al. A Multi-source Transfer Learning Study Based on Feature Difference Enhancement for Inter-Project Knowledge Transfer of Construction Equipment[J]. Systems Engineering-Theory & Practice, 2024, 44(3): 1097-1113. (in Chinese)
- [10] 潘晓博, 葛鲲鹏, 董飞. 基于特征迁移学习的提升机轴承智能故障诊断[J]. 工矿自动化, 2022, 48(9): 1-7, 32.
- PAN X B, GE K P, DONG F. Intelligent Fault Diagnosis of Hoist Bearing Based on Feature Transfer Learning[J]. Journal of Mine Automation, 2022, 48(9): 1-7, 32. (in Chinese)
- [11] 杨魏华, 阮爱国, 黄国勇. 基于预训练 GoogleNet 模型和迁移学习的齿轮箱故障检测方法[J]. 机电工程, 2024, 41(2): 262-270.
- YANG W H, RUAN A G, HUANG G Y. Gearbox Fault Detection Based on Pretrained GoogleNet Modal and Transfer Learning[J]. Mechanical & Electrical Engineering Magazine, 2024, 41(2): 262-270. (in Chinese)
- [12] LI P P, LIANG F. Construction of Mental Health Monitoring System Based on Model Transfer Learning Algorithm[J]. International Journal of Wireless and Mobile Computing, 2023, 24(1): 58.
- [13] ZHU Y C, ZHUANG F Z, WANG J D, et al. Deep

- Subdomain Adaptation Network for Image Classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(4): 1713-1722.
- [14] 徐丽霞, 钟季龙, 伍劭实, 等. 基于云模型和最大均值差异的指标迁移学习[J]. 系统仿真学报, 2024, 36(9): 2004-2015.
- XU L X, ZHONG J L, WU S S, et al. Indicator Transfer Learning Based on Cloud Model and Maximum Mean Discrepancy[J]. Journal of System Simulation, 2024, 36(9): 2004-2015. (in Chinese)
- [15] 李理, 孙玉林, 曹然, 等. 基于联合分布适配的水下声源测距算法研究[J]. 电子与信息学报, 2022, 44(6): 2061-2070.
- LI L, SUN Y L, CAO R, et al. Research on Underwater Source Ranging Algorithm Based on Joint Distribution Adaptation[J]. Journal of Electronics & Information Technology, 2022, 44(6): 2061-2070. (in Chinese)
- [16] 黄华, 姚嘉靖, 薛文虎, 等. 基于多域特征联合分布适配的刀具磨损状态识别[J]. 计算机集成制造系统, 2022, 28(8): 2419-2429.
- HUANG H, YAO J J, XUE W H, et al. Tool Wear State Recognition Based on Joint Distribution Adaptation of Multi-Domain Feature[J]. Computer Integrated Manufacturing Systems, 2022, 28(8): 2419-2429. (in Chinese)
- [17] 陈景霞, 胡修文, 唐喆喆, 等. 基于卷积联合适应网络的脑电信号情感识别[J]. 数据采集与处理, 2022, 37(4): 814-824.
- CHEN J X, HU X W, TANG Z Z, et al. EEG Emotion Recognition Based on Convolutional Joint Adaptation Network[J]. Journal of Data Acquisition and Processing, 2022, 37(4): 814-824. (in Chinese)
- [18] 蔡培, 袁辉, 徐鹤鸣, 等. 基于小样本量的航空发动机材料高低周复合疲劳 P-S-N 曲线优化方法[J]. 材料工程, 2024, 52(10): 117-126.
- CAI P, YUAN H, XU H M, et al. Optimization Method of Combined High and Low Cycle Fatigue P-S-N Curve for Aeroengine Materials with Small Size Sample[J]. Journal of Materials Engineering, 2024, 52(10): 117-126. (in Chinese)
- [19] 殷孝唯, 潘雪, 左雁斌, 等. 基于迁移学习的风电机组叶片损伤检测与分析[J]. 太阳能学报, 2024, 45(10): 506-511.
- YIN X J, PAN X, ZUO Y B, et al. Wind Turbine Blade Damage Detection and Analysis Based on Transfer Learning[J]. Acta Energiæ Solaris Sinica, 2024, 45(10): 506-511. (in Chinese)
- [20] 崔榕峰, 李鸿岩, 王祥云, 等. 基于迁移学习的飞行器高低阶精度数据融合方法[J]. 飞行力学, 2024, 42(4): 7-12, 20.
- CUI R F, LI H Y, WANG X Y, et al. High and Low Order Precision Data Fusion Method for Aircraft Based on Transfer Learning[J]. Flight Dynamics, 2024, 42(4): 7-12, 20. (in Chinese)
- [21] 刘懿, 任济寰, 吴祥, 等. 基于集成迁移学习的新装备装甲车辆分类[J]. 兵工学报, 2023, 44(8): 2319-2328.
- LIU Y, REN J H, WU X, et al. Newly Equipped Armored Vehicle Classification Based on Integrated Transfer Learning[J]. Acta Armamentari, 2023, 44(8): 2319-2328. (in Chinese)
- [22] 孙颂. 基于数据驱动方法的发动机剩余寿命预测研究[D]. 徐州: 中国矿业大学, 2023.
- SUN S. Research on Engine Remaining Life Prediction Based on Data-Driven Methods[D]. Xuzhou: China University of Mining and Technology, 2023. (in Chinese)
- [23] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is All You Need[C]// Proceedings of the 31st International Conference on Neural Information Processing Systems/ NIPS' 17. Red Hook, NY: Curran Associates Inc, 2017: 6000-6010.
- [24] 崔展博, 景博, 焦晓璇, 等. 长短期记忆网络微调的氧气浓缩器寿命预测模型迁移[J]. 国防科技大学学报, 2023, 45(4): 243-252.
- CUI Z B, JING B, JIAO X X, et al. Transfer of Oxygen Concentrator Life Prediction Model Based on LSTM-Fine-Tune[J]. Journal of National University of Defense Technology, 2023, 45(4): 243-252. (in Chinese)
- [25] 苗冯博. 基于特征融合的发动机寿命预测方法研究[D]. 吉林: 吉林化工学院, 2023.
- MIAO F B. Research on Engine Life Prediction Method Based on Feature Fusion[D]. Jilin: Jilin Institute of Chemical Technology, 2023. (in Chinese)
- [26] 张海燕, 闫文君, 张立民, 等. 基于微分思想和动态时间弯曲(DTW)的飞行员着舰技能评估研究[J]. 兵器装备工程学报, 2023, 44(3): 124-130.
- ZHANG H Y, YAN W J, ZHANG L M, et al. Evaluation of Pilot Landing Skills Based on Differential Thinking and Dynamic Time Warping[J]. Journal of Ordnance Equipment Engineering, 2023, 44(3): 124-130. (in Chinese)

(编辑: 陈斐)