

基于 MSET 算法的发电设备预警诊断增量学习方法研究

吴礼军¹ 任池银¹ 钱 坤¹ 程胜林¹ 张定宇¹ 桂 华¹ 叶欣楠² 郭 庆²

WU Lijun REN Chi Yin QIAN Kun CHENG Shenglin ZHANG Dingyu GUI Hua YE Xinnan GUO Qing

摘 要

为进一步提高预警模型性能,充分利用发电设备数据,节约计算资源,提出了一种基于 MSET 算法的发电设备预警诊断增量学习方法。实验采用某电厂真实运行数据,选取送风机设备特征,对比基线阶段原始运行算法的效果与增量学习阶段的效果,结果表明通过增量学习能利用少量数据激活失效模型,帮助电厂关键设备模型适应数据漂移等问题,从而提高系统的实时性和适应性。所提出的方法在发电设备预警诊断方面具有较好的性能。

关键词

多元状态估计技术;增量学习;设备预警;状态检测

doi: 10.3969/j.issn.1672-9528.2024.04.041

0 引言

随着信息化与数字化技术在电力生产领域逐渐成熟,加之全球对清洁、高效、可持续能源的需求持续攀升,智能电厂已逐渐成为电力生产新一代解决方案。在当前的电力工业中,自动化和数字化技术已成为关键驱动力。工业物联网(IIoT)、传感器、云计算和大数据分析不仅提高了电力生产的效率,还提供了更全面的设备监控和资源管理能力^[1]。除了自动化和数字化,电厂还注重智能控制优化。使用人工智能(AI)和机器学习技术,电厂可以实时监测设备,调整运营参数,以最大化电力生产效益,优化电力生产和降低能源浪费^[2]。

机器学习作为人工智能领域的一个关键分支,是一种通过计算机系统从数据中学习和改进性能的技术^[3]。其核心思想在于从大量数据中提取信息,通过自身的泛化能力使计算机系统能根据以往的经验做出应对未来的决策。传统的模型训练方式往往采用一次性离线处理所有训练数据,这种学习方法通常被归类为“批量学习”^[4]。然而,所有数据同时访问的经典批处理机器学习方法并不能满足在给定时间内处理纯粹数量的需求,因此产生越来越多的未处理累积数据。此外,它们不会将新信息连续地集成到已经构建的模型中,而是定期从头开始重建新模型。这不仅非常耗时,而且会导致潜在的过时模型。

与批量学习相比,增量学习^[5]往往涉及一系列算法的结合,以实现节约资源,提高准确性的目的。一部分研究将增

量学习应用于支持向量机的背景中。叶圣永^[6]利用快速支持向量机增量学习方法构建递归解,向解中添加新数据,并通过每次一个样本的增量学习更新暂态稳定评估模型。实验仿真结果表明,该方法能够有效地更新评估模型,显著缩短学习时间。王洪林^[7]则提出基于支持向量机的增量学习算法,提取线性电网中不可分的边界支持向量,研究人员配置高压电网测相单元系数,通过确定故障识别元自动识别短路故障位置,解决电网结构中的风险最小化问题。还有一部分研究^[8]将其与 KNN 结合,通过对模型簇引进“层”的概念,对新增数据建立不同“层”的模型簇的方式对原有模型进行优化,达到增量学习的效果,其有效性得到实验验证。

在实际生产环境中,由于历史训练数据的质量不均匀,可能导致设备预警效果准确率表现不佳,甚至可能出现误报。同时,由于数据量有限,人们希望能够在有限的资源下获得更加准确的预测结果。因此,在智能电厂研究中,批量学习方法在某些情况下可能并不适用,特别是对于那些需要具备实时性、适应性和高效性的应用。在这一背景下,利用增量学习方法在消除设备生命周期影响、更替历史质量较差数据、增加模型自身的效果和持续改进性能等方面是非常有必要的。针对这一挑战,本文引入了一种基于增量学习的改进 MSET 算法,以优化智能电厂中的数据预测性能。通过这一算法,研究者们能够更好地适应设备数据的动态变化,提高实时决策的准确性。

1 相关工作

1.1 增量学习

增量学习^[9]也被称为在线学习或渐进学习,是机器学习领域的一个重要分支,其主要目标是在不断接收新数据时持

1. 淮浙煤电有限责任公司凤台发电分公司 安徽凤台 232100

2. 浙江浙能数字科技有限公司 浙江杭州 310018

续改进模型的性能。这种学习范式对于数据不断演化或增长的应用场景尤为关键。与传统的批量学习不同，增量学习更关注模型的持久性和适应性。

在机器学习中，增量学习是一个重要的概念。作为一种特殊的机器学习方法，机器学习允许模型在不断接收新数据时进行更新，而无需重新训练整个模型。增量学习可以看作是机器学习中的一个子领域，它关注如何有效地利用新数据来保持模型的精度和性能，通过将训练集分解为多个小规模子集，采用分批训练模型的方式，更有效利用有限的物理资源。相对于批量学习，增量学习具有多个显著优点。首先，它具备实时适应性，能够在不断接收新数据时及时更新模型，使其能够灵活适应不断变化的环境和数据。其次，增量学习更为资源高效，因为它只需要在新数据上进行小规模更新，从而节省了宝贵的计算资源和时间成本，且有助于降低过拟合的风险，更少地依赖历史数据。再次，它有助于有效管理大规模数据流，避免了将整个数据集存储在内存中，而是仅保留必要的历史数据以便更新模型。最后，增量学习允许模型持续学习和积累知识，而不仅仅在固定的时间间隔内进行训练。这使得模型能够不断改进性能，特别适用于需要实时决策的应用场景。然而，需要指出的是，增量学习也面临一些挑战，如处理样本不平衡、遗忘旧数据以及难以保持模型稳定性等问题。

此外，增量学习还包括了领域自适应^[10]（domain adaptation）和迁移学习^[11]（transfer learning）等领域的研究，这些方法可将知识从一个领域迁移到另一个领域，在保持原有知识的基础上，学习新知识，提高了模型泛化性能。这种方法涉及在不同领域或设备之间有效传递知识。近年来，增量学习在在线广告、自然语言处理和生物信息学等领域都取得了广泛应用，为应对不断变化的数据提供了强大的工具。

1.2 MSET

本节主要介绍 MSET 的基本信息和具体原理，及其在工业领域的常见应用。在故障预警研究中，MSET 是一种常见的方法，特点在于泛化能力强、精度高，但表现依赖于记忆矩阵的大小。

MSET（multiple set efficiency theory）算法，即多元状态估计技术，最早由美国阿贡国家实验室 Motti 提出，后经 Gross 等人不断完善^[12-13]，成为一种通过历史正常数据构建的记忆矩阵来对当前的状态变量进行预测的非参数建模方法。其算法的核心是通过设备正常工况数据构建记忆矩阵并得到当前工况的估计值，通过实际生产数据与估计值之间偏差来评价设备的健康状况。当数值偏离过大时，可判断为设备存在异常。该算法具有实用性高、使用要求低等特点。近年来，MSET 算法广泛应用于解决工业行业等领域中的状态

检测及故障预警方面^[14-15]，涉及设备包括燃煤电站、风电机组、核电站等。

MSET 的原理和实现过程如下^[16]：若某设备共有 n 个参数参与状态监测，则将某一时刻这些参数的测量值记为观测向量 $\mathbf{X}=[x_1, x_2, \dots, x_n]^T$ 。在设备正常运行时，采集的 m 个观测向量 $\mathbf{X}$ 构造记忆矩阵 $\mathbf{D}$ 如下（要求 m 个观测向量尽可能覆盖设备所有的运行工况）：

$$\mathbf{D}=[\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_m]=\begin{bmatrix} x_{11} & x_{21} & \cdots & x_{m1} \\ x_{12} & x_{22} & \cdots & x_{m2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1n} & x_{2n} & \cdots & x_{mn} \end{bmatrix}_{n \times m} \quad (1)$$

MSET 的输入为当前时刻的观测向量 $\mathbf{X}_0$ ，输出为观测向量的估计值 $\mathbf{X}_e$ 。对于每个输入 $\mathbf{X}_0$ ，均需要计算一个对应的权值向量 $\mathbf{W}=[w_1, w_2, \dots, w_m]^T$ ，使得记忆矩阵 $\mathbf{D}$ 和权值向量 $\mathbf{W}$ 的乘积等于输出 $\mathbf{X}_e$ 。具体公式如下：

$$\mathbf{X}_e = \mathbf{D} \cdot \mathbf{W} = w_1 \mathbf{X}_1 + w_2 \mathbf{X}_2 + \cdots + w_m \mathbf{X}_m \quad (2)$$

权值向量 $\mathbf{W}$ 的计算公式如下：

$$\mathbf{W} = (\mathbf{D}^T \otimes \mathbf{D})^{-1} \cdot (\mathbf{D}^T \otimes \mathbf{X}_0) \quad (3)$$

式中： $\otimes$ 为非线性运算符，常选取为两向量间的欧几里得距离。

将式（3）代入式（2）中，输出 $\mathbf{X}_e$ 的计算公式如下：

$$\mathbf{X}_e = \mathbf{D} \cdot (\mathbf{D}^T \otimes \mathbf{D})^{-1} \cdot (\mathbf{D}^T \otimes \mathbf{X}_0) \quad (4)$$

MSET 不需要实现基于训练样本进行参数训练，但在计算每一个输出 $\mathbf{X}_e$ 时，都需要重新基于记忆矩阵 $\mathbf{D}$ 计算权值向量 $\mathbf{W}$ 。因此，记忆矩阵 $\mathbf{D}$ 对 MSET 的估计精度和计算速度有着决定性的影响，具体分析如下。

（1）记忆矩阵 $\mathbf{D}$ 的规模较小时，MSET 的计算速度较快，但对设备正常运行状态空间的覆盖有限，估计精度相对较低，状态监测的准确性较差。

（2）记忆矩阵 $\mathbf{D}$ 的规模较大时，MSET 的估计精度相对较高，准确性较好。但在计算权重 $\mathbf{W}$ 和输出 $\mathbf{X}_e$ 时，需要分别进行矩阵乘法运算矩阵 $(\mathbf{D}^T \otimes \mathbf{D})^{-1}$ 和 $(\mathbf{D}^T \otimes \mathbf{X}_0)$ 相乘、矩阵 $\mathbf{D}$ 和 $\mathbf{W}$ 相乘，而矩阵乘法的时间复杂度一般为 $O_{n(3)}$ 左右。因此，扩大记忆矩阵 $\mathbf{D}$ 会使计算速度大幅度增加，同样也会占用更多的存储空间。

根据上述分析，从原理上 MSET 的估计精度和实时性之间存在一定的矛盾，有必要针对该问题进行深入研究，在保证一定估计精度的同时尽可能提高 MSET 的实时计算速度。

2 提出的方法

对于 MSET 算法，其中算法的模型就是记忆矩阵 $\mathbf{D}$ ，记忆矩阵是由训练集中正常运行工况下的特征参数向量组成的矩阵，每一条向量就代表着一种正常运行工况。预警结果的

好坏取决于记忆矩阵中向量的多样性程度，向量与向量之间的相关性越低，说明记忆矩阵中包含的正常工况种类越多，最终产生的误报率也就越低。所以，针对 MSET 算法的增量学习，需要修改记忆矩阵，删除记忆矩阵中存在时间过长、已经不适用于当前设备特性的向量，以及与其他向量相关性过高的冗余的向量。同时，从增量学习训练集中筛选出相互之间相似程度低的向量，加入记忆矩阵中。通过这样的增量学习方法，确保了记忆矩阵中的特征向量保持一定的时效性和多样性。

设增量训练集为 X , $X_1, X_2, \dots, X_m$ 为待增量的 m 条数据，记忆矩阵为 D , $D_1, D_2, \dots, D_n$ 为记忆矩阵中的 n 条向量，计算矩阵 $X^T \otimes X$ ，具体公式为：

$$X^T \otimes X = \begin{bmatrix} 0 & d(X_1, X_2) & \cdots & d(X_1, X_m) \\ d(X_2, X_1) & 0 & \cdots & d(X_2, X_m) \\ \vdots & \vdots & \ddots & \vdots \\ d(X_m, X_1) & d(X_m, X_2) & \cdots & 0 \end{bmatrix} \quad (5)$$

式中： $d(X_i, X_j)$ 为第 i 条数据与第 j 条数据之间的欧氏距离。当 d 较大时，说明两条向量之间的距离较远，相似度较低；当 d 较小时，说明两条向量之间的距离较近，相似度较高。将距离作为向量之间相似度高低的评判依据，找出训练集中的冗余数据，基于上述记忆矩阵的修改策略，提出了一种针对 MSET 算法的增量学习方法。具体的增量学习策略流程如下。

(1) 计算矩阵 $X^T \otimes X$ 。

(2) 计算矩阵 $X^T \otimes X$ 下三角部分（不含对角线）每一列的最小值，记为 d_j ，即计算

$$d_j = \min[d(X_1, X_j), d(X_{i+1}, X_j), \dots, d(X_m, X_j)] \quad (6)$$

$$i = j+1, 1 \leq j \leq m$$

(3) 将 d_j 从大到小排序，设定更新率 φ ，根据记忆矩阵的大小 n ，记下前 $n \cdot \varphi$ 部分中各个 d_j 的下标 j ，根据下标 j 找到相应的数据 X_j 作为记忆矩阵待插入更新的向量。

(4) 计算矩阵 $D^T \otimes D$ 。

(5) 计算矩阵 $D^T \otimes D$ 下三角部分（不含对角线）每一列的最小值，人为设定一个合适的时间参数 T ，将每列的最小值与列相应倍数的时间参数 T 相加，记为 d_j ，即计算

$$d_j = \min[d(X_1, X_j), d(X_{i+1}, X_j), \dots, d(X_m, X_j)] + j \cdot T \quad (7)$$

$$i = j+1, 1 \leq j \leq m$$

(6) 将 d_j 从小到大排序，记下前 $n \cdot \varphi$ 部分中各个 d_j 的下标 j ，根据下标 j 找到记忆矩阵中的工况向量 D_j 删除。

(7) 将 (3) 中挑选出来的 X_j 按下标 j 的顺序插入到记忆矩阵 D 的最后一行，更新成为新的记忆矩阵 D 。

在一个计算周期内，增量 MSET 算法的在线计算过程如图 1 所示。




图 1 增量 MSET 算法的在线计算过程

3 实验设计及结果

3.1 实验设计

在本研究的实验设计中，旨在评估 MSET 预警算法在加入增量学习算法后的性能差异，以及增量学习后的模型和重新训练后的模型的性能差异。实验数据采用了某电厂的真实运行数据，特征选取于设备送风机的特征，数据采集时间从 2020 年到 2022 年，跨度为两年，采样频率为 10 min。为了对比前后情况，将实验划分为两个阶段：一个基线阶段和一个增量学习阶段。

在基线阶段，将运行原始预警算法，分别使用 2020 年 2 月到 2021 年 2 月的历史数据和 2021 年 8 月到 2022 年 8 月的历史数据进行模型训练，使用 2022 年 9 月到 10 月的数据进行预测，以建立基准性能指标。在增量学习阶段，将引入增量学习算法，使用 2022 年 6 月到 2022 年 8 月的数据进行原模型更新，以模拟真实应用环境中的算法演化。在增量学习的训练过程中，设置更新率 $\varphi=0.05$ ，时间参数 $T=0.0001$ 。

其中，为确定超参数变异率 φ 的值，遍历 φ 值从 1% 到 9.5%，计算各特征在不同的变异率下自学习后实际值与评估值之间的均方误差，如图 2。




图 2 各项特征在不同变异率下的均方误差图

从图2中可以发现,大部分特征在 ϕ 值为2%~4%时,均方误差已经接近收敛,且继续增大 ϕ 值会导致均方误差逐渐增大。所以,自学习超参数 ϕ 设置为2%~4%,云边学习变异率,不高于10%。

比较两个阶段中三个不同模型的性能指标,包括MAE、MSE、RMSE、R2,以评估增量学习对预警算法的改进效果。通过这一实验设计,旨在深入了解增量学习算法对电厂预警系统的实际影响,以验证其在长期运行和逐步数据更新的情况下的效益。这将有助于指导电厂运营中的实际决策和改进算法的部署策略。

3.2 基线阶段

实验使用2020年2月到2021年2月的历史数据进行模型训练,将训练好的原模型对2022年9月到10月的送风机数据进行参数估计,发现大部分时间段内,不同的特征均出现了实时值偏离阈值带上下限的情况。同时,又选取了离测试数据较近的时间段2021年8月到2022年8月的历史数据重新进行模型训练,使用重新训练好的新模型对测试数据进行参数估计,发现测试数据的值都在阈值带内,并未产生报警的情况,如图2。

图3左列为原模型其中三个特征的测试结果,右列为新模型的测试结果,从新模型的测试结果可以看出,测试数据时间段内设备并未发生异常,数据均为正常数据,所以原模型在测试阶段产生的异常报警属于误报。产生误报的情况是因为原模型的训练数据采集于2020年2月到2021年2月,与测试数据的时间相隔有一年之久。一年的时间内,设备的关机重启、检修等操作改变了设备原来的特性,使得设备的各个参数或多或少产生了数据漂移的状况。数据漂移使得原模型的性能大大降低,所以需要引入增量学习,在不重新训练模型的情况下,提升原模型的性能。




图3 基线阶段预警结果图

3.3 增量学习阶段

增量学习阶段,使用原模型作为增量学习的基础模型,使用2022年7月到2022年8月的数据作为增量学习的数据。同时,使用增量学习后的模型测试集数据进行参数估计,参数测试情况如图4所示。




图4 增量学习阶段预警结果图

将图3和图4对比并参照表1中的评价指标可以看出,增量学习后的模型在测试集上的表现完全优于增量学习前的原模型,测试数据都落在增量后模型的评估值阈值带内,没有产生大量误报的情况,说明增量学习可以让原模型克服数据漂移产生的模型性能大幅下降的问题。对比重新训练的新模型,尽管增量学习后的模型在性能上略有不足,极少数时间段内的评估值与实时值有一定幅度的偏离,产生轻微报警的情况,但是整体的参数评估趋势与新模型的趋势相似,说明增量学习能够利用少量的样本数据和少量的计算资源对原模型进行自学习,达到近似于模型重新训练的效果。

表1 各模型评价指标数据表

	特征	MAE	MSE	RMSE	R2
原模型	A送风机电机定子温度1	1.19	2.14	1.46	0.88
	A送风机电机轴承温度2	2.55	13.81	3.72	0.61
	A送风机轴承箱供油油温	0.93	1.38	1.17	0.86
训练后新模型	A送风机电机定子温度1	0.13	0.03	0.18	0.99
	A送风机电机轴承温度2	0.25	0.17	0.42	0.99
	A送风机轴承箱供油油温	0.002	5.37e-06	0.002	0.93
增量后新模型	A送风机电机定子温度1	0.15	0.04	0.21	0.99
	A送风机电机轴承温度2	0.57	0.88	0.94	0.98
	A送风机轴承箱供油油温	0.32	0.22	0.47	0.97

如果因为数据漂移等问题直接舍弃训练好的模型,再重新训练新的模型,将会耗费大量的时间成本,显然,在工程上,电厂关键设备预警模型数量庞大,对于每一个失效的模型都重新训练模型不是一个高效且节约成本的方法。所以,需要通过增量学习,在不重新训练模型的情况下,利用少量数据自动修正模型参数,对已有模型定期更新迭代,让失效的预警模型重新恢复性能,大幅降低模型上线使用后的运维成本。

4 结论

本文提出一种基于增量学习的改进 MSET 算法应用于智能电厂的故障预警,该方法利用增量学习的思想,在避免耗费大量时间重新训练的前提下,完成了对模型的更新迭代,同时结合 MSET 算法,提升了预警准确率。通过实验已经验证该算法的有效性和准确性,提升了模型的性能。在未来的工作中,将进一步考虑改进的 MSET 算法与增量学习的深度结合,通过实际环境部署,提升该算法的可拓展性。

参考文献:

- [1] 尹峰,陈波,苏烨,等.智慧电厂与智能发电典型研究方向及关键技术综述[J].浙江电力,2017,36(10):1-6+26.
- [2] 刘吉臻,胡勇,曾德良,等.智能发电厂的架构及特征[J].中国电机工程学报,2017,37(22):6463-6470+6758.
- [3] 苏金树,张博锋,徐昕.基于机器学习的文本分类技术研究进展[J].软件学报,2006(9):1848-1859.
- [4] 孙宇.针对含有概念漂移问题的增量学习算法研究[D].合肥:中国科学技术大学,2017.
- [5] LOSING V, HAMMER B, WERSING H. Incremental on-line learning: a review and comparison of state of the art algorithms[J]. Neurocomputing, 2018, 275: 1261-1274.
- [6] 叶圣永,王晓茹,刘志刚,等.基于支持向量机增量学习的电力系统暂态稳定评估[J].电力系统自动化,2011,35(11):15-19.
- [7] 王洪林,董春林,董俊,等.基于支持向量机增量学习算法的高压电网短路故障位置自动识别[J].电气自动化,2022,44(4):34-36.
- [8] 郭躬德,黄杰,陈黎飞.基于KNN模型的增量学习算法[J].模式识别与人工智能,2010,23(5):701-707.
- [9] 刘冰瑶,刘进锋.增量学习研究综述[J].现代计算机,2022,28(13):72-75+91.
- [10] 李晶晶,孟利超,张可,等.领域自适应研究综述[J].计算机工程,2021,47(6):1-13.
- [11] MOTT J, YOUNG J, BERTCH W, et al. Pattern-recognition software for plant surveillance[J]. Trans. am. nucl. soc, 1987, 54: 5816384.
- [12] GROSS K C, SINGER R M, WEGERICH S W, et al. Application of a model-based fault detection system to nuclear plant signals[J]. Office of scientific & technical information technical reports, 1997, 5: 481606.
- [13] 丁世飞,齐丙娟,谭红艳.支持向量机理论与算法研究综述[J].电子科技大学学报,2011,40(1):2-10.
- [14] LV Y, FANG F, YANG T, et al. An early fault detection method for induced draft fans based on MSET with informative memory matrix selection[J]. ISA transactions, 2020, 102: 325-334.
- [15] 刘志刚,熊国良,张龙.滚动轴承性能退化的 MSET 模型及其故障预警[J].机械设计与研究,2021,37(2):60-65.
- [16] 赵劲松,王梓齐,刘长良.基于 Bagging 集成策略和多元状态估计的风电机组齿轮箱状态监测[J].科学技术与工程,2020,20(20):8180-8186.

【作者简介】

吴礼军(1973—),男,安徽太湖人,大专,中级工程师,研究方向:发电厂电气专业检修、维护。

任池银(1984—),男,河南卫辉人,本科,工程师,研究方向:电气工程及其自动化。

钱坤(1984—),男,安徽天长人,本科,工程师,研究方向:汽机专业、汽轮机及控制系统检修维护工艺。

程胜林(1987—),男,湖北黄梅人,本科,工程师,研究方向:火电厂热工仪表测量及自动控制。

张定宇(1988—),男,河北深州人,本科,工程师,研究方向:火电厂热工仪表测量及自动控制。

桂华(1973—),男,安徽宿州人,本科,高级工程师,研究方向:火电厂热工仪表测量及自功控制。

叶欣楠(1997—),通信作者(email: 42578475@qq.com),女,浙江丽水人,硕士,研究方向:预警诊断算法。

郭庆(1998—),男,浙江台州人,本科,助理工程师,研究方向:工业自动化。

(收稿日期:2024-01-25)