

徐晓,陈琦.机器学习在实验动物设施管理中的应用进展与展望 [J]. 中国比较医学杂志, 2024, 34(1): 103-113.
Xu X, Chen Q. A review and promising future directions of machine learning in laboratory animal facility management [J]. Chin J Comp Med, 2024, 34(1): 103-113.
doi: 10.3969/j.issn.1671-7856.2024.01.012

机器学习在实验动物设施管理中的应用进展与展望

徐 骁^{*}, 陈 琦

(华中科技大学实验动物中心, 武汉 430030)

【摘要】 随着我国实验动物设施智能化水平逐步提升, 积累了大量能够反映设施运行真实状态的数据。由于分析手段的缺乏, 数据价值未得到充分的挖掘。在大数据背景下, 机器学习(machine learning)已经在生物医疗、建筑科学等领域取得了显著的成果, 也为其实验动物设施管理中的应用提供了参考。本文对国内外机器学习应用于实验动物设施各系统中的内容、方法和模式进行了综述与展望。

【关键词】 机器学习; 实验动物设施; 屏障设施

【中图分类号】 R-33 **【文献标识码】** A **【文章编号】** 1671-7856 (2024) 01-0103-11

A review and promising future directions of machine learning in laboratory animal facility management

XU Xiao^{*}, CHEN Qi

(Laboratory Animal Center, Huazhong University of Science and Technology, Wuhan 430030, China)

【Abstract】 As the intelligence level gradually improves in domestic laboratory animal facilities, a large amount of valuable data have been accumulated. These data have not been fully exploited because of the lack of analytical method. In the context of big data, machine learning has achieved remarkable result in biomedicine, building science, and other fields, and provides a reference for its application in laboratory animal facility management. In this article, the contents, methods and models of machine learning applied to various systems of laboratory animal facilities at home and abroad are reviewed and discussed.

【Keywords】 machine learning; laboratory animal facility; barrier facility

Conflicts of Interest: The authors declare no conflict of interest.

实验动物设施是实验动物饲养及实验的主要场所, 也是保障实验动物饲育质量的重要基础和支撑条件。目前, 实验动物设施的大部分系统及设备中都应用了传感器及物联网技术, 积累了大量的运行数据, 能够直接反映实验动物设施最真实的状态^[1]。这些运行数据有着数量大、维度多的特点, 常规分析手段无法充分挖掘其数据价值。机器学习(machine learning), 是从数据中学习特定任务的计算机算法, 非常适合用于对大量数据进行分析, 发现数据之间隐藏的潜在规律。

通过调研已有的研究文献, 按照实验动物设施的主要系统分类, 归纳了机器学习分别在 5 个方面

的应用, 即能效评价与系统建模、气流组织数值模拟、空调运行控制优化、系统故障诊断及其他系统, 同时也对机器学习在实验动物设施管理领域未来的应用与发展方向做出展望。

1 机器学习及其应用于实验动物设施管理的概述

机器学习一般被认为包括回归、分类、聚类分析、关联分析等多种算法, 机器学习按照对数据标签的需求可以大致分为有监督学习和无监督学习, 按照算法的复杂程度可以大致分为机器学习和深度学习。常见的机器学习数据处理流程如图 1 所示, 可以分为数据预处理、数据集划分、数据标签处

理、模型选择及训练、知识发现等步骤。

实验动物设施在功能上属于洁净室,对温湿度、压差、尘埃粒子数、换气次数等指标有严格要求,按功能类型可以分为暖通空调系统(HVAC 系统)、空气处理系统、水处理系统、辅助系统等(压缩空气系统、照明系统)。机器学习在各系统中的主要应用如表 1 所示。

2 基于机器学习的能效评价与系统建模

实验动物设施在运行时,通常是不惜代价保证功能,以至于其节能潜力也非常可观^[2]。节能潜力的评估依赖于使用能耗标准值与实际情况进行对比。当前,现行的实验动物设施能效评价相关的标准有国家标准 GB/T 36527—2018《洁净室及相关受控环境节能指南》及国际标准 ISO 14644—16 : 2019《洁净室及相关受控环境 第 16 部分:洁净室和隔离设备的能效》等。由于不同实验动物设施因工艺参数设置不同,造成区别极大,因此现行标准中并未明确给出能效基准参考值^[3],而是采用同类比较方法,即“比对样本可以是另一个相似的洁净室设施、以前经过优化的能源性能调试数据或基于以前经验的计算比对样本”^[4]。

因此,从机器学习的角度出发,实验动物设施的能效评价,是从现有数据中发现标准值的过程。即对系统的能耗进行准确预测,通过分析预测值与测量值之间的差值用于评价系统的能效。机器学习算法在系统能耗的预测上的应用非常成熟且广泛,常用的算法包括线性回归、支持向量机、决策树与随机森林、人工神经网络、深度神经网络等^[5-6]。

Ciulla 等^[7]、Bilous 等^[8]采用多元线性回归进了建筑物的长、短期负荷预测;Liu 等^[9]、Wang 等^[10]、

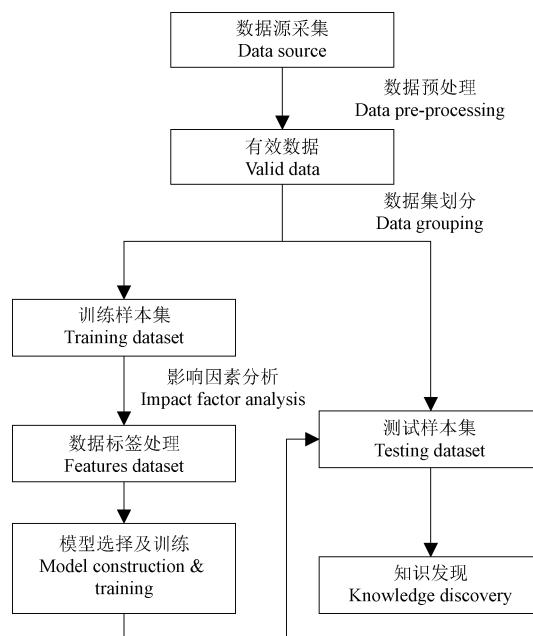


图 1 常见的机器学习数据处理流程

Figure 1 Machine learning common workflow

Seyedzadeh 等^[11]、Wang 等^[12]比较了多种模型包括极端梯度提升(XGBoost)、随机森林、多层神经网络、梯度提升决策树和支持向量回归(SVR)等算法在可解释性、准确性、稳健性和效率方面的情况;Pham 等^[13]、Zhou 等^[14]采用多元线性回归、随机森林、支持向量机(SVM)和 BP 神经网络等方法进行了建筑物的超短期功率预测。由于实验动物设施包含有多个子系统,其能耗、负荷与各种影响因素之间存在复杂的非线性关系,因此非线性算法在系统能耗预测上具有明显优势。

人工神经网络(ANN)是典型的非线性算法之一,在建筑能耗上得到了非常广泛的应用。Alamin 等^[15]采用 ANN 模型实现了分钟级的空调系统能耗

表 1 机器学习在实验动物设施各系统中的主要应用

Table 1 Main applications of machine learning in laboratory animal facilities

系统类型 Type of system	主要应用目的 Main purpose of algorithm application
暖通空调系统(HVAC 系统) Heating, ventilation, air-conditioning and cooling system (HVAC system)	优化运行控制、负荷预测及建模、设备故障诊断 Optimize operational control, load forecasting & modeling, device fault diagnosis
空气处理系统 Air handling systems	气流组织模拟优化 Simulation optimization of airflow organization
水处理系统 Water treatment system	水质分类、质量参数预测、用水量预测 Water quality classification, quality parameter prediction, water consumption forecasting
辅助系统等(压缩空气系统、照明系统) Auxiliary systems, etc. (Compressed air systems, lighting systems)	设备故障诊断 Device fault diagnosis

预测;Almalaq 等^[16]、Somu 等^[17]采用卷积-长短期记忆神经网络(CNN-LSTM)模型实现了建筑的短期、中长期能耗预测;Fan 等^[18]使用结合循环神经网络(RNN)实现了建筑能耗预测;Kim 等^[19]提出了一种结合循环神经网络(RNN)和改进卷积神经网络(1-D CNN)的短期能耗预测模型,用于预测 3~7 d 的建筑物中央空调系统能耗;Cai 等^[20]提出了一种带有门控的递归神经网络模型(Gated-RNN),并实现了建筑物的超短期能耗预测。

虽然神经网络模型充分证明了其在预测方面的价值,但由于缺乏可解释性,应用受到一定的限制^[21]。许多研究开始着眼于修改神经网络的结构,以提高可解释性。Shan 等^[22]将具有物理意义的重力模型(GRA)与门控循环单元(GRU)模型集成在一起,用于建筑能耗预测;Kim^[23]修改了传统的卷积神经网络(CNN),并通过在 CNN 中添加时间卷积和池化层,提出了用于室内人类活动检测的可解释 CNN(I-CNN);也可以引入先验知识,Drgoña 等^[24]提出可以使用热力学知识来指导的递归神经网络(RNN)模型的设计,具有良好的泛化效果。

上述研究表明,机器学习算法用于能耗预测及系统建模的技术已经十分成熟,也是其在实验动物设施管理中最重要的应用之一。不同的机器学习算法在适用范围、预测尺度上存在不同的特点,应当结合具体情况选用,以上研究情况汇总见表 2。

3 基于机器学习的气流组织数值模拟

实验动物设施一般是通过机械通风系统提供恒定甚至过量的新风量,以满足换气次数等环境控制要求。气流组织形式会直接影响通风效率及冷量/热量需求,传统计算流体力学方法(computational fluid dynamics, CFD)是气流组织设计最为常用的手段^[25]。周斌等^[26]、欧少华等^[27]、杨五强等^[28]使用 CFD 方法对实验动物设施的气流组织进行了优化设计,证明了其在实验动物设施管理中的适用性。

然而,传统 CFD 方法受限于算力及计算时间问题,主要被使用在离线仿真计算中,参与实验动物设施的前期设计。随着环境参数的大量快速监测及获取,数值模拟的预测精度要求和实时性要求越发显著^[29]。机器学习算法由于其处理非线性高维的能力,开始被大量的引入 CFD 中。

机器学习算法在气流组织模拟中主要有两个

方向:(1)用作 CFD 的辅助工具,以提高准确性;(2)替代 CFD 用于更快地预测。常用的算法主要是人工神经网络及深度学习算法。

3.1 辅助 CFD 计算

在辅助 CFD 方面,Zhou 等^[30]利用 CFD 数值模拟结果构建训练数据集,使用神经网络模型实现了二维非等温条件下的室内气流和温度预测,结果显示预测所需时间大幅缩短,平均值的预测误差控制在 5% 以内;Kim 等^[31]利用人工神经网络模型结合 CFD 设计了一种分阶段的预测方法,相比于传统单层预测方法,表现出更好的准确性,并减轻对于大型训练数据样本集的需求;Li 等^[32]提出了一种基于 CFD 的 BP 神经网络结合粒子群优化器(PSO)算法,可以快速预测室内环境空气参数,CFD 计算时间缩短 23.53%;Nina 等^[33]采用梯度提升回归(GBR)结合 CFD 建立了一种室内空气参数实时预测模型,实现使用温度和气流速度的数据即预测与舒适相关的流量参数,实现了 CFD 仿真输入参数的优化;Ren 等^[34]建立基于降维线性通风模型的人工神经网络模型,实现了以通风模式、换气次数和污染源位置作为输入标量的室内污染物浓度场“超实时”预测,并能够根据预测结果实现最优换气次数和通风模式的可视化与调控。

3.2 替代 CFD 计算

在替代 CFD 方面,Zhou 等^[35]提出一种创新的耦合仿真框架,使用神经网络模型替代 CFD 预测不均匀的室内空气分布并与 BES 程序相结合,与传统 CFD 和 BES 之间的耦合仿真相比,计算时间减少约 94%;Guo 等^[36]开发了一种卷积神经网络(CNN)算法,该算法的执行速度比等效的 CFD 解决方案快至少两个数量级;Wei 等^[37]引入物理信息神经网络(PINN)基于测量数据重建室内气流场,与传统的 CFD 相比,PINN 可以直接根据测量数据重建详细的气流场,并且误差较 ANN 模型更小;Fresca 等^[38]提出了一种基于深度学习的降阶模型(DL-ROM),将不同的模型组合在一起以初始化算法的参数,从而显著提高 CFD 离线训练的速度;Wang 等^[39]提出了一种基于长短期记忆网络-循环神经网络(LSTM-RNN)架构的深度学习模型,结合正交分解降维,能够以不到 1/1000 的 CPU 成本完成 CFD 计算,并保持较好的计算精度;Shin 等^[40]提出了一种基于全卷积网络(FCN)的深度学习回归模型,实现了对传统深度神经网络(DNN)架构的优化与改进,与传统深

表 2 机器学习算法在建筑能效评价与系统建模领域的应用

Table 2 Application of machine learning algorithms in the field of building energy efficiency evaluation and system modeling

作者, 年限 Author, Year	机器学习方法 Machine learning algorithms	研究对象 Object of study	预测尺度 Prediction scale
Ciulla, et al. 2019 ^[7]	多元线性回归 Multiple linear regression	冷热负荷预测 Prediction of building heating and cooling loads	长期预测(年度) Long-term prediction (annual)
Bilous, et al. 2018 ^[8]	多元线性回归 Multiple linear regression	房间空气温度预测 Room air temperature prediction	短期预测(小时) Short-term prediction (hours)
Liu, et al. 2021 ^[9]	随机森林 Random forest	空调系统能耗预测 Energy prediction for air-conditioning system	长期预测(年度) Long-term prediction (annual)
Wang, et al. 2019 ^[10]	极端梯度提升 XGBoost	考虑气象数据的空调系统供暖能耗预测 Energy prediction of air-conditioning system considering meteorological data	中长期预测(天) Medium- and long-term prediction (days)
Seyedzadeh, et al. 2019 ^[11]	随机森林、支持向量机(SVM) Random forest, support vector machine	考虑建筑维护结构特性的建筑冷热负荷预测 Prediction of building heating and cooling loads considering building maintenance structure characteristics	长期预测(年) Long-term prediction (annual)
Wang, et al. 2022 ^[12]	多层神经网络、 线性回归、极端梯度提升 Multi-layer perceptron, linear regression, XGBoost	空调系统冬季供暖及生活热水供应能耗预测 Energy prediction of heating and hot water supply of the air-conditioning system	长期预测(年) Long-term prediction (annual)
Pham, et al. 2020 ^[13]	随机森林 Random forest	建筑物每小时能耗预测 Energy prediction for buildings	短期预测(小时) Short-term prediction (hours)
Zhou, et al. 2020 ^[14]	多元线性回归、支持向量机(SVM)和 BP 神经网络 Multiple linear regression, support vector machine, back propagation neural network	建筑物每小时能耗预测 Energy prediction for buildings	短期预测(小时) Short-term prediction (hours)
Alamin, et al. 2018 ^[15]	人工神经网络(ANN) Artificial neural network	空调每小时能耗预测 Hourly energy prediction for air-conditioning system	短期预测(小时) Short-term prediction (hours)
Almalaq, et al. 2019 ^[16]	卷积神经网络-长期短期记忆神经 网络(CNN-LSTM) Convolutional neural network-long short-term memory	建筑能耗预测 Energy prediction for buildings	短期预测(小时) Short-term prediction (hours)
Somu, et al. 2021 ^[17]	卷积神经网络-长期短期记忆神经 网络(CNN-LSTM) Convolutional neural network-long short-term memory	建筑能耗预测 Energy prediction for buildings	中长期预测(天) Medium- and long-term prediction (days)
Fan, et al. 2019 ^[18]	递归神经网络(RNN) Recurrent neural network	建筑能源预测 Energy prediction for buildings	短期预测(小时) Short-term prediction (hours)
Kim, et al. 2019 ^[19]	递归神经网络(RNN)、递归初始卷积 神经网络(RICNN) Recurrent neural network, recursive initial convolutional neural network	建筑能耗预测 Energy prediction for buildings	中长期预测(天) Medium- and long-term prediction (days)
Cai, et al. 2019 ^[20]	带门控的递归神经网络、卷积神经网络(CNN) Gated recurrent neural network, convolutional neural network	建筑能耗预测 Energy prediction for buildings	短期预测(小时) Short-term prediction (hours)

度学习 DNN 回归模型相比, 在均值绝对误差和均方根误差两方面的预测误差分别降低了 43.14% 和 34.77%。

综上, 机器学习无论是辅助 CFD 还是替代 CFD, 其目的都是为了实现更好更快的计算。相比

于传统 CFD 优化方法, 机器学习的速度优势明显, 也能够在无任何先验物理知识的情况下获得结果。

4 基于机器学习的空调运行控制优化

暖通空调(heating, ventilation and air conditioning,

HVAC) 系统能耗一般占实验动物设施能耗的 50% 以上^[2], 做好暖通空调系统运行控制优化, 对实验动物设施的节能至关重要。实际工程中实验动物设施的暖通空调一般带有自动控制系统, 如常见的空调群控或变频/变流量控制, 一般采用传统 PID 控制或基于规则的控制方法 (rule based control, RBC)^[41-42], 均属于反馈控制, 存在一些缺点, 包括实时响应速度差、规则通常由专家经验决定等^[43], 导致暖通空调系统未运行在最佳状态。

4.1 模型预测控制

近年来, 在暖通空调(HVAC)控制领域, 越来越多研究开始采用前馈控制思想, 并结合机器学习的模型预测控制(model predictive control, MPC)^[44-45]。模型预测控制是通过建立一个系统模型来预测未来状态, 结合时变的约束条件, 产生对应动态控制策略的方法^[42], 其核心是系统建模与预测。

Kathirgamanathan 等^[46]根据数据获取的充实程度, 将暖通空调系统建模划分为基于白箱、黑箱和灰箱的模型。黑箱/灰箱模型结合机器学习算法, 因其易用性得到了更广泛的研究与应用^[46-51]。Yue 等^[52]借助云计算平台, 利用机器学习方法预测了室内平均温度, 使用 MPC 控制, 实现了冷水机组的群控运行控制优化, 在不同典型日下系统能耗降低了 37.3%、10.6% 和 23.7%; Maddalena 等^[53]采用基于非线性回归方法, 使用 MPC 对中央空调系统进行仿真, 在三种不同典型日下使系统运行效率分别提升了 2.29%、3.13% 和 4.76%; Chen 等^[54]提出一种由数据驱动模型结合优化算法机器学习-MPC 框架, 其系统节能率可达 7.1%; Afram 等^[55]采用人工神经网络(ANN)设计了一处带有热回收/储热装置的地源热泵系统的 MPC 控制, 能够根据季节节省 6%~73% 的运营成本。

深度学习算法由于其面对多时间尺度和复杂性表现更好的特点, 也开始被采用到模型预测控制中。Fang 等^[56]基于深度 Q 学习(DQN)的多目标最优控制策略, 用于温度设定点实时复位, 以平衡能耗和室内空气温度; Deng 等^[57]提出了一种非平稳 DQN 方法, 结合主动建筑环境变化检测, 空调系统节能率提高 13%; Fu 等^[58]提出了一种事件驱动的深度 Q 网络(ED-DQN)方法, 能够有效捕捉热舒适性的动态非线性特征; Arroyo 等^[59]采用强化学习, 提出了一种 RL-MPC 控制框架, 在不确定性和持续学习上具备更强的可能性。

4.2 模型预测控制(MPC)的性能优化

模型预测控制的问题是实时性一般较差, 许多研究开始结合机器学习算法优化模型结构, 以显著增强模型预测控制在暖通空调系统控制中的适用性。Yang 等^[60]提出了一种基于机器学习的瞬时线性化(IL)的 MPC 控制架构, 将优化问题从非凸问题转换为凸问题, 在保留计算精度的同时显著降低计算量; Gao 等^[61]提出了一种基于物理模型的强化学习算法, 在 MPC 控制上可以实现一样的控制性能, 并且训练时间更短; Chen 等^[62]提出了一种基于集成多时间尺度深度学习的自适应模型预测控制(EMA-MPC)系统, 针对空调系统短期和长期时间尺度上的预测需求, 采用了两个 LSTM 模型的组合方法, 在预测方面有效地提升了速度。

总之, 模型预测控制能够让实验动物设施的暖通空调系统实现精细化调控与节能运行。机器学习已经被证明非常适合用于这种非线性程度高、物理结构复杂系统的建模与预测, 具有极大的价值。

5 基于机器学习的系统故障检测诊断

实验动物设施中的简易故障可以依靠经验快速实现诊断, 而传感器等精密元件出现量程失准、精度下降等故障, 不易直接判别^[63]。研究表明, 采用机器学习算法的传感器故障检测与诊断(fault detection and diagnosis, FDD), 几乎不需要先验知识, 还可以以相对较低的成本提升检测覆盖率和诊断准确性。不仅能保障系统的安全高效运行, 还可以降低约 5%~30% 的系统能耗^[64]。一种常见的机器学习 FDD 方法流程如图 2 所示。

5.1 使用带标记的数据集进行故障诊断

机器学习算法在 FDD 领域比较直接的应用是使用有监督算法开发分类模型, 模型输入是故障相关的影响因素, 输出是故障结果(数据样本是正常还是故障)或用于故障诊断的特征(数据样本是否对应于正常或特定的故障操作条件)。常用的算法有决策树与随机森林、支持向量机和贝叶斯网络。

Yao 等^[65]使用 3 种基于树的集成学习方法建立暖通空调系统中冷水机组故障的参考和 FDD 模型, 结果表明, 所提方法能有效识别 88 种常见故障; Movahed 等^[66]使用随机森林算法建立了用于诊断空气处理机组和屋顶机组故障的双层机器学习框架。Li 等^[67]提出一种改进的基于决策树的实用可变制冷剂流量(VRF)空调系统的故障诊断方法。

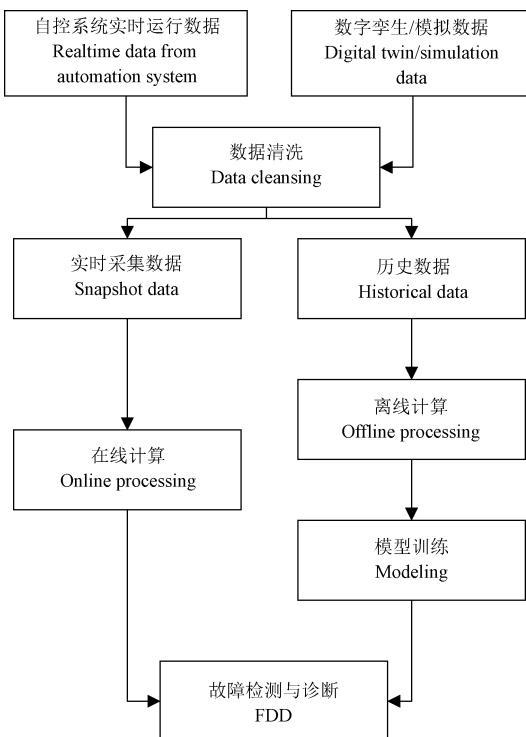


图 2 常见的机器学习 FDD 方法流程

Figure 2 Machine learning algorithm common workflow for FDD

Madhikermi 等^[68]采用 SVM 算法将异常数据与正常数据进行分类,实现了热回收机组的故障诊断;Montazeri 等^[69]使用 SVM 结合 PCA、核主成分分析(KPCA)和径向基函数(RBF),提出一种同时诊断空气处理机组系统中传感器和执行器故障的方法;Li 等^[70]基于冷水机组测试数据集不同的特征输入开发了 4 个 SVM 模型,并分析了不同条件下模型对于故障诊断的性能;Yan 等^[71]构建了基于 SVM 的暖通空调系统中故障诊断模型,以评估和比较不同特征选择策略的成本。

Wang 等^[72]基于实验数据提出了一种用于冷水机组故障诊断的贝叶斯网络特征选择方法;该模型在特征选择后达到了 99.2% 的最高精度;Chen 等^[73]开发了一种离散贝叶斯网络方法来诊断 HVAC 系统/设备两级故障;Melani 等^[74]提出了一个基于移动窗口主成分分析和贝叶斯网络的混合框架用于故障诊断;Ng 等^[75]使用贝叶斯网络进行了传感器故障检测,同时表明贝叶斯网络在数据缺失状态下具有优越的性能。

5.2 直接使用运行数据进行诊断

实际工程中收集的运行数据多数是未标记的,数据标记工作本身又非常耗时。无监督算法可以使用未标记的数据集,表现出了极大的应用潜力,

常用的算法有主成分分析(PCA)及聚类算法。

Madhikermi 等^[76]使用主成分分析(PCA)结合逻辑回归方法来检测空气处理机组的热回收故障。Chen 等^[77]使用基于天气和时间表的模式匹配(WPM)和基于特征的主成分分析(FPCA)的方法来检测 HVAC 的整体故障。Zhou 等^[78]提出了一种主成分分析-合成少数过采样技术(PCA-SMOTE)方法,用以增强在 VRV 空调系统训练数据集不完整情况下故障诊断的准确性;Li 等^[79]结合基于密度聚类(DBSCAN)与 PCA 方法,提高了故障检测和诊断的灵敏度和可靠性及传感器故障估计的准确性。

Aguilar 等^[80]使用 K-Means 聚类方法对 HVAC 常见故障进行划分,用于进行故障识别与诊断;Dey 等^[81]采用改进 K-Means 聚类对 HVAC 系统终端单元的特征进行提取后,应用于 HVAC 系统的故障监测和诊断;Gunay 等^[82]使用分层聚类,结合专家经验,识别出了现有 FDD 方法中被忽略的故障;Xu 等^[83]使用了分层聚类、K-Means 聚类和 PAM 聚类,对比 HVAC 运行记录,有效地进行了误操作及系统故障识别;Zhou 等^[84]提出了一种基于信息熵的分层聚类算法,对比常规特征参数分层聚类法和 K 均值聚类法,有效地提高了故障识别的精度。

神经网络由于其特性,也被广泛地应用于 FDD 中^[85],并常与其他方法结合进行使用。Ding 等^[86]结合决策树与神经网络、Shi 等^[87]结合 PCA 与神经网络、Guo 等^[88]结合关联规则分析与神经网络、Sun 等^[89]结合 ICA 与神经网络对 VRF 系统进行了故障诊断并提高了效能。此外,也有较多研究使用人工神经网络(ANN)预测故障并进行诊断^[90-92]。神经网络的变体,如深度神经网络^[93]、递归神经网络^[93]、生成对抗网络^[94]和卷积神经网络^[95]等,也被证明可以在 FDD 中达到非常高的精度。

上述研究表明,根据实际获取数据集标注的丰富程度,合理地选择算法至关重要。基于机器学习的智能化、自动化的故障诊断方法与系统,是实验动物设施实现高效运行管理的重要基础。

6 基于机器学习的其他系统应用

机器学习算法在实验动物设施其他系统上的应用也十分广泛,如纯水、照明、空压机系统等。

6.1 纯水系统的水质监测及评估

Ap 等^[96]在监测水质变化的同时,使用线性回归模型算法根据消耗率预测未来的水位。Ahmed

等^[97]利用 K-Means 和人工神经网络(ANN)机器学习算法实时监测水质,并使用机器学习算法来预测 3 个月的用水需求。Sukor 等^[98]在监测 pH、电导率、温度和总溶解固体等参数的基础上,使用人工神经网络(ANN)、支持向量机(SVM)和决策树三种算法对水质进行分类。

6.2 照明系统

Motta Cabrera 等^[99]采用数据关联挖掘算法与照明显耗规律结合,对学校教室的照明显耗异常进行诊断,最高可以节约 70% 的用电量; Norouziasl 等^[100]采用支持向量机(SVM)的方法建立了一种针对照明显耗影响因素的预测框架,用于准确了解照明系统能耗的变化趋势并采取合理的节能措施; Sahin 等^[101]采用人工神经网络(ANN)用于估计建筑照明系统中随时间变化的能量损失,并提出了改进措施从而避免能源浪费。

6.3 空压机系统

Wu 等^[102]使用人工神经网络(ANN)结合空压机的历史用电数据进行负荷预测,对制定空压机的优化运行策略提供了参考。McLaughlin 等^[103]采用 5 种机器学习算法建立了一个用于诊断空压机压缩空气是否泄漏的模型,有效地指导空压机的实际运维工作。

上述研究表明,机器学习可以很好地应用于实验动物设施各类系统的量化研究中,帮助研究人员理解实验动物设施运行的特性和规律,为保障系统安全高效运行提供新的角度和思路。

7 结论与展望

近年来,我国实验动物设施的智能化程度快速提高,积累了大量的运行数据。机器学习也已经十分成熟,在建筑智能化、生物医疗等领域中均取得了显著的成果。两者相结合,机器学习在实验动物设施管理上存在广阔的应用前景。

本文广泛综述了机器学习在实验动物设施管理中的应用,总结如下:

(1) 机器学习在实验动物设施管理中最为成熟的应用是系统能耗预测与评价建模。机器学习可以有效并准确地采用历史数据/相关因素来预测不同时间尺度下的系统能耗,用于建立能效基准、能耗指标及评价体系等。能够有效地解决现行标准中能效基准值未明确给定的问题,帮助实验动物设施进行明确的能效量化评价及异常识别。

(2) 机器学习可以在实验动物设施管理中发挥节能提效作用。在设计、建设、改造等阶段,机器学习结合常用的流体力学 CFD 方法,能够显著提升气流组织模拟的速度与精度。在运行、管理等阶段,机器学习结合前馈控制思想,采用模型预测控制(MPC),能够准确地制定暖通空调系统、空气处理系统等的优化运行控制策略,实现系统节能提效运行。

(3) 机器学习可以在实验动物设施管理中发挥安全保障作用。面对复杂系统,在缺乏物理先验知识的条件下,机器学习能够以相对低的成本快速准确地进行传感器故障检测与诊断(FDD),保障系统安全稳定运行。机器学习也能够用于实验动物设施各子系统的量化研究中,从新的角度提供思路与方法。

同时,机器学习在实验动物设施管理方面存在需要进一步研究的内容,总结如下:

(1) 机器学习的适用性和泛化性需要进一步提高。多数研究关注于某种算法或某几种算法的结合在单一环境条件下的精度/性能等,少有研究着眼于迁移至不同环境下方法的适用程度。从算法的角度来讲,泛化能力的研究十分重要,也必然是未来的研究重点。

(2) 实际应用中数据缺乏的问题需要从算法方面克服。常见的现象包括:仅安装自动控制所必需的传感器,传感器数据不存储上传、数据缺乏标准化归集方式等,导致数据严重缺乏。机器学习如何选择研究必需的数据,如何在缺乏数据的情况下进行有效地工作,甚至如何有效地处理与生成数据,都是亟待研究的问题。

(3) 机器学习在实验动物设施管理中的工程应用需要进一步得到加强。多数研究基于模拟数据或典型样本数据集进行离线仿真计算,部分研究通过机器学习算法结合理论与实际,建立了实时气流模拟系统及在线故障诊断系统等。未来,机器学习算法在实验动物设施管理的工程实践中有望进一步得到广泛的应用。

参考文献:

[1] 李可欣, 张凤梅, 杨根岭, 等. 实验动物屏障设施系统自动化控制技术体系应用探索 [J]. 中国比较医学杂志, 2018, 28(12): 102-107.

Li KX, Zhang FM, Yang GL, et al. Application of an automated control system to specific pathogen-free barrier facilities for

- laboratory animals [J]. Chin J Comp Med, 2018, 28(12): 102–107.
- [2] 唐利军, 徐国景, 张金明, 等. 实验动物建筑设施节能技术探讨 [J]. 中国比较医学杂志, 2010, 20(1): 73–78.
Tang LJ, Xu CJ, Zhang JM, et al. Research for energy-saving technologies of laboratory animals building facilities [J]. Chin J Comp Med, 2010, 20(1): 73–78.
- [3] Cleanrooms and associated controlled environments-part 16: energy efficiency in cleanrooms and separative devices: ISO 14644: 16[S]. 2019.
- [4] 张彦国. ISO 14644-16: 2019《洁净室及相关受控环境——第 16 部分: 洁净室和隔离设备的能效》简介 [J]. 暖通空调, 2021, 51(11): 1–5.
Zhang YG. Introduction of ISO 14644-16: 2019 Cleanrooms and associated controlled environments-part 16: energy efficiency in cleanrooms and separative devices [J]. Heat Vent Air Cond, 2021, 51(11): 1–5.
- [5] Wei Y, Zhang X, Shi Y, et al. A review of data-driven approaches for prediction and classification of building energy consumption [J]. Renew Sustain Energy Rev, 2018, 82: 1027–1047.
- [6] Chen Y, Guo M, Chen Z, et al. Physical energy and data-driven models in building energy prediction: a review [J]. Energy Rep, 2022, 8: 2656–2671.
- [7] Ciulla G, D'Amico A. Building energy performance forecasting: a multiple linear regression approach [J]. Appl Energy, 2019, 253: 113500.
- [8] Bilous I, Deshko V, Sukhodub I. Parametric analysis of external and internal factors influence on building energy performance using non-linear multivariate regression models [J]. J Build Eng, 2018, 20: 327–336.
- [9] Liu Y, Chen H, Zhang L, et al. Enhancing building energy efficiency using a random forest model: A hybrid prediction approach [J]. Energy Rep, 2021, 7: 5003–5012.
- [10] Wang R, Lu S, Li Q. Multi-criteria comprehensive study on predictive algorithm of hourly heating energy consumption for residential buildings [J]. Sustain Cities Soc, 2019, 49: 101623.
- [11] Seyedzadeh S, Rahimian FP, Rastogi P, et al. Tuning machine learning models for prediction of building energy loads [J]. Sustain Cities Soc, 2019, 47: 101484.
- [12] Wang M, Wang Z, Geng Y, et al. Interpreting the neural network model for HVAC system energy data mining [J]. Build Environ, 2022, 209: 108449.
- [13] Pham AD, Ngo NT, Ha Truong TT, et al. Predicting energy consumption in multiple buildings using machine learning for improving energy efficiency and sustainability [J]. J Clean Prod, 2020, 260: 121082.
- [14] Zhou Y, Zheng S. Machine-learning based hybrid demand-side controller for high-rise office buildings with high energy flexibilities [J]. Appl Energy, 2020, 262: 114416.
- [15] Alamin YI, Álvarez JD, del Mar Castilla M, et al. An Artificial Neural Network (ANN) model to predict the electric load profile for an HVAC system [J]. IFAC-PapersOnLine, 2018, 51(10): 26–31.
- [16] Almalaq A, Zhang JJ. Evolutionary deep learning-based energy consumption prediction for buildings [J]. IEEE Access, 2018, 7: 1520–1531.
- [17] Somu N, Raman MRG, Ramamritham K. A deep learning framework for building energy consumption forecast [J]. Renew Sustain Energy Rev, 2021, 137: 110591.
- [18] Fan C, Wang J, Gang W, et al. Assessment of deep recurrent neural network-based strategies for short-term building energy predictions [J]. Appl Energy, 2019, 236: 700–710.
- [19] Kim J, Moon J, Hwang E, et al. Recurrent inception convolution neural network for multi short-term load forecasting [J]. Energy Build, 2019, 194: 328–341.
- [20] Cai M, Pipattanasomporn M, Rahman S. Day-ahead building-level load forecasts using deep learning vs. traditional time-series techniques [J]. Appl Energy, 2019, 236: 1078–1088.
- [21] Naser MZ. An engineer's guide to eXplainable Artificial Intelligence and Interpretable Machine Learning: Navigating causality, forced goodness, and the false perception of inference [J]. Autom Constr, 2021, 129: 103821.
- [22] Shan S, Cao B, Wu Z. Forecasting the short-term electricity consumption of building using a novel ensemble model [J]. IEEE Access, 2019, 7: 88093–88106.
- [23] Kim E. Interpretable and accurate convolutional neural networks for human activity recognition [J]. IEEE Trans Ind Inform, 2020, P1: 1.
- [24] Drgoña J, Tuor AR, Chandan V, et al. Physics-constrained deep learning of multi-zone building thermal dynamics [J]. Energy Build, 2021, 243: 110992.
- [25] Deng HY, Feng Z, Cao SJ. Influence of air change rates on indoor CO₂ stratification in terms of Richardson number and vorticity [J]. Build Environ, 2018, 129: 74–84.
- [26] 周斌, 赵勇, 汪亚兵, 等. 两种不同类型实验动物屏障设施的气流组织计算流体力学模拟技术分析 [J]. 实验动物与比较医学, 2021, 41(3): 252–258.
Zhou B, Zhao Y, Wang YB, et al. Analysis on air distribution by computational fluid dynamics simulation in two types of laboratory animal barrier facilities [J]. Lab Anim Comp Med, 2021, 41(3): 252–258.
- [27] 欧少华, 周斌, 刘吉宏. 某 GLP 实验动物设施空调及通风系统设计研究 [J]. 中国比较医学杂志, 2020, 30(4): 110–116.
Ou SH, Zhou B, Liu JH. Discussion of an HVAC system design for a good laboratory practice lab animal vivarium [J]. Chin J Comp Med, 2020, 30(4): 110–116.
- [28] 杨五强, 潘杰, 李勋. 屏障系统回风口布置方式对气流组织的模拟分析 [J]. 实验动物与比较医学, 2010, 30(5): 384–387.
Yang WQ, Pan J, Li X. Simulation and analysis of air distribution in specific pathogen free air return layout [J]. Lab

- Anim Comp Med, 2010, 30(5): 384–387.
- [29] Cao SJ. Challenges of using CFD simulation for the design and online control of ventilation systems [J]. Indoor Built Environ, 2019, 28(1): 3–6.
- [30] Zhou Q, Ooka R. Influence of data preprocessing on neural network performance for reproducing CFD simulations of non-isothermal indoor airflow distribution [J]. Energy Build, 2021, 230: 110525.
- [31] Kim M, Park HJ. Application of artificial neural networks using sequential prediction approach in indoor airflow prediction [J]. J Build Eng, 2023, 69: 106319.
- [32] Li L, Zhang Y, Fung J, et al. A coupled computational fluid dynamics and back-propagation neural network-based particle swarm optimizer algorithm for predicting and optimizing indoor air quality [J]. Build Environ, 2022, 207: 108533.
- [33] Nina M, Xavier TF, Roser C, et al. A CFD-based surrogate model for predicting flow parameters in a ventilated room using sensor readings [J]. Energy Build, 2022, 266: 112146.
- [34] Ren C, Cao SJ. Development and application of linear ventilation and temperature models for indoor environmental prediction and HVAC systems control [J]. Sustain Cities Soc, 2019, 51: 101673.
- [35] Zhou Q, Ooka R. Implementation of a coupled simulation framework with neural network and Modelica for fast building energy simulation considering non-uniform indoor environment [J]. Build Environ, 2021, 211: 108740.
- [36] Guo X, Li W, Iorio F. Convolutional neural networks for steady flow approximation [A]. Proceedings of the proceedings of the ACM SIGKDD international conference on knowledge discovery and data mining [C]. San Francisco United States: Association for Computing Machinery; 2016.
- [37] Wei C, Ooka R. Indoor airflow field reconstruction using physics-informed neural network [J]. Build Environ, 2023, 242: 110563.
- [38] Fresca S, Manzoni A. POD-DL-ROM: enhancing deep learning-based reduced order models for nonlinear parametrized PDEs by proper orthogonal decomposition [J]. Comput Methods Appl Mech Eng, 2022, 388: 114181.
- [39] Wang Z, Xiao D, Fang F, et al. Model identification of reduced order fluid dynamics systems using deep learning [J]. Int J Numer Methods Fluids, 2018, 86(4): 255–268.
- [40] Shin S, Baek K, So H. Rapid monitoring of indoor air quality for efficient HVAC systems using fully convolutional network deep learning model [J]. Build Environ, 2023, 234: 110191.
- [41] Maddalena ET, Lian Y, Jones CN. Data-driven methods for building control-a review and promising future directions [J]. Control Eng Pract, 2020, 95: 104211.
- [42] Drgoña J, Arroyo J, Cupeiro Figueroa I, et al. All You need to know about model predictive control for buildings [J]. Annu Rev Control, 2020, 50: 190–232.
- [43] Saloux E, Candanedo J. Optimal rule-based control for the management of thermal energy storage in a Canadian solar district heating system [J]. Sol Energy, 2020, 207: 1191–1201.
- [44] Zhan S, Chong A. Data requirements and performance evaluation of model predictive control in buildings: a modeling perspective [J]. Renew Sustain Energy Rev, 2021, 142: 110835.
- [45] Yao Y, Shekhar DK. State of the art review on model predictive control (MPC) in Heating Ventilation and Air-conditioning (HVAC) field [J]. Build Environ, 2021, 200: 107952.
- [46] Kathirgamanathan A, De Rosa M, Mangina E, et al. Data-driven predictive control for unlocking building energy flexibility: a review [J]. Renew Sustain Energy Rev, 2021, 135: 110120.
- [47] Zhang X, Pipattanasomporn M, Chen T, et al. An IoT-based thermal model learning framework for smart buildings [J]. IEEE Internet Things J, 2020, 7: 518–527.
- [48] Maher A, Mohammed R, Albbod Maysam F, et al. Data-driven based HVAC optimisation approaches: a systematic literature review [J]. J Build Eng, 2022, 46: 103678.
- [49] Löwenstein KF, Bernardini D, Fagiano L, et al. Physics-informed online learning of gray-box models by moving horizon estimation [J]. Eur J Control, 2023, 2023: 100861.
- [50] Pratyush K, Rawlings James B, Wenzel Michael J, et al. Grey-box model and neural network disturbance predictor identification for economic MPC in building energy systems [J]. Energy Build, 2023, 286: 112936.
- [51] Li Y, O'Neill Z, Zhang L, et al. Grey-box modeling and application for building energy simulations-A critical review [J]. Renew Sustain Energy Rev, 2021, 146: 111174.
- [52] Yue B, Su B, Xiao F, et al. Energy-oriented control retrofit for existing HVAC system adopting data-driven MPC-Methodology, implementation and field test [J]. Energy Build, 2023, 295: 113286.
- [53] Maddalena E, Muller SA, Santos R, et al. Experimental data-driven model predictive control of a hospital HVAC system during regular use [J]. Energy Build, 2022, 271: 112316.
- [54] Chen S, Ding P, Zhou G, et al. A novel machine learning-based model predictive control framework for improving the energy efficiency of air-conditioning systems [J]. Energy Build, 2023, 294: 113258.
- [55] Afram A, Janabi-Sharifi F, Fung AS, et al. Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems: a state of the art review and case study of a residential HVAC system [J]. Energy Build, 2017, 141: 96–113.
- [56] Fang X, Gong G, Li G, et al. Deep reinforcement learning optimal control strategy for temperature setpoint real-time reset in multi-zone building HVAC system [J]. Appl Therm Eng, 2022, 212: 118552.
- [57] Deng X, Zhang Y, Zhang Y, et al. Towards optimal HVAC control in non-stationary building environments combining active change detection and deep reinforcement learning [J]. Build Environ, 2022, 211: 108680.
- [58] Fu Q, Li Z, Ding Z, et al. ED-DQN: an event-driven deep reinforcement learning control method for multi-zone residential

- buildings [J]. *Build Environ*, 2023, 242: 110546.
- [59] Arroyo J, Manna C, Spiessens F, et al. Reinforced model predictive control (RL-MPC) for building energy management [J]. *Appl Energy*, 2022, 309: 118346.
- [60] Yang S, Wan MP. Machine-learning-based model predictive control with instantaneous linearization-A case study on an air-conditioning and mechanical ventilation system [J]. *Appl Energ*, 2022, 306: 118041.
- [61] Gao C, Wang D. Comparative study of model-based and model-free reinforcement learning control performance in HVAC systems [J]. *J Build Eng*, 2023, 74: 106852.
- [62] Chen EX, Han X, Malkawi A, et al. Adaptive model predictive control with ensembled multi-time scale deep-learning models for smart control of natural ventilation [J]. *Build Environ*, 2023, 242: 110519.
- [63] Borgstein EH, Lamberts R, Hensen JLM. Mapping failures in energy and environmental performance of buildings [J]. *Energy Build*, 2018, 158: 476–485.
- [64] Li Y, O'Neill Z. A critical review of fault modeling of HVAC systems in buildings [J]. *Build Simul*, 2018, 11(5): 953–975.
- [65] Yao W, Li D, Gao L. Fault detection and diagnosis using tree-based ensemble learning methods and multivariate control charts for centrifugal chillers [J]. *J Build Eng*, 2022, 51: 104243.
- [66] Movahed P, Taheri S, Razban A. A bi-level data-driven framework for fault-detection and diagnosis of HVAC systems [J]. *Appl Energy*, 2023, 339: 120948.
- [67] Li G, Chen H, Hu Y, et al. An improved decision tree-based fault diagnosis method for practical variable refrigerant flow system using virtual sensor-based fault indicators [J]. *Appl Therm Eng*, 2018, 129: 1292–1303.
- [68] Madhikermi M, Malhi AK, Främling K. Explainable artificial intelligence based heat recycler fault detection in air handling unit [A]. Proceedings of the Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics) [C]. Montreal Canada: Springer Verlag; 2019.
- [69] Montazeri A, Kargar SM. Fault detection and diagnosis in air handling using data-driven methods [J]. *J Build Eng*, 2020, 31: 101388.
- [70] Li X, Liu J, Liu B, et al. Impacts of data uncertainty on the performance of data-driven-based building fault diagnosis [J]. *J Build Eng*, 2021, 43: 103153.
- [71] Yan K, Ma L, Dai Y, et al. Cost-sensitive and sequential feature selection for chiller fault detection and diagnosis [J]. *Int J Refrig*, 2018, 86: 401–409.
- [72] Wang Z, Wang Z, Gu X, et al. Feature selection based on Bayesian network for chiller fault diagnosis from the perspective of field applications [J]. *Appl Therm Eng*, 2018, 129: 674–683.
- [73] Chen Y, Wen J, Pradhan O, et al. Using discrete Bayesian networks for diagnosing and isolating cross-level faults in HVAC systems [J]. *Appl Energy*, 2022, 327: 120050.
- [74] Melani AHDA, Michalski MADC, da Silva RF, et al. A framework to automate fault detection and diagnosis based on moving window principal component analysis and Bayesian network [J]. *Reliab Eng Syst Safe*, 2021, 215: 107837.
- [75] Ng K, Yik F, Lee P, et al. Bayesian method for HVAC plant sensor fault detection and diagnosis [J]. *Energy Build*, 2020, 228: 110476.
- [76] Madhikermi M, Yousefnezhad N, Främling K. Heat recovery unit failure detection in air handling unit [A]. Proceedings of the IFIP Advances in Information and Communication Technology [C]. Seoul South Korea: Springer New York LLC; 2018.
- [77] Chen Y, Wen J, Lo J. Using weather and schedule based pattern matching and feature based principal component analysis for whole building fault detection—part II field evaluation [J]. *J Eng Sustain Bldgs Cities*, 2022, 3(1): 011002.
- [78] Zhou Z, Chen H, Li G, et al. Data-driven fault diagnosis for residential variable refrigerant flow system on imbalanced data environments [J]. *Int J Refrig*, 2021, 125: 34–43.
- [79] Li G, Hu Y. Improved sensor fault detection, diagnosis and estimation for screw chillers using density-based clustering and principal component analysis [J]. *Energy Build*, 2018, 173: 502–515.
- [80] Aguilar J, Ardila D, Avendaño A, et al. An autonomic cycle of data analysis tasks for the supervision of HVAC systems of smart building [J]. *Energies*, 2020, 13(12): 13123103.
- [81] Dey M, Rana SP, Dudley S. Smart building creation in large scale HVAC environments through automated fault detection and diagnosis [J]. *Future Gener Comput Syst*, 2020, 108: 950–966.
- [82] Gunay HB, Shi Z. Cluster analysis-based anomaly detection in building automation systems [J]. *Energy Build*, 2020, 228: 110445.
- [83] Xu Y, Yan C, Shi J, et al. An anomaly detection and dynamic energy performance evaluation method for HVAC systems based on data mining [J]. *Sustain Energy Technol*, 2021, 44: 101092.
- [84] Zhou X, Yang T, Liang L, et al. Anomaly detection method of daily energy consumption patterns for central air conditioning systems [J]. *J Build Eng*, 2021, 38: 102179.
- [85] Yun WS, Hong WH, Seo H. A data-driven fault detection and diagnosis scheme for air handling units in building HVAC systems considering undefined states [J]. *J Build Eng*, 2021, 35: 102111.
- [86] Ding X, Guo Y, Liu T, et al. New fault diagnostic strategies for refrigerant charge fault in a VRF system using hybrid machine learning method [J]. *J Build Eng*, 2021, 33: 101577.
- [87] Shi S, Li G, Chen H, et al. An efficient VRF system fault diagnosis strategy for refrigerant charge amount based on PCA and dual neural network model [J]. *Appl Therm Eng*, 2018, 129: 1252–1262.
- [88] Guo Y, Li G, Chen H, et al. Optimized neural network-based fault diagnosis strategy for VRF system in heating mode using data mining [J]. *Appl Therm Eng*, 2017, 125: 1402–1413.

- [89] Sun S, Li G, Chen H, et al. A hybrid ICA-BPNN-based FDD strategy for refrigerant charge faults in variable refrigerant flow system [J]. Appl Therm Eng, 2017, 127: 718–728.
- [90] Fan C, Xiao F, Zhao Y, et al. Analytical investigation of autoencoder-based methods for unsupervised anomaly detection in building energy data [J]. Appl Energy, 2018, 211: 1123–1135.
- [91] Loy-Benitez J, Li Q, Nam K, et al. Sustainable subway indoor air quality monitoring and fault-tolerant ventilation control using a sparse autoencoder-driven sensor self-validation [J]. Sustain Cities Soc, 2020, 52: 101847.
- [92] Choi Y, Yoon S. Autoencoder-driven fault detection and diagnosis in building automation systems: residual-based and latent space-based approaches [J]. Build Environ, 2021, 203: 108066.
- [93] Lee KP, Wu BH, Peng SL. Deep-learning-based fault detection and diagnosis of air-handling units [J]. Build Environ, 2019, 157: 24–33.
- [94] Yan K, Chong A, Mo Y. Generative adversarial network for fault detection diagnosis of chillers [J]. Build Environ, 2020, 172: 106698.
- [95] Cheng F, Cai W, Zhang X, et al. Fault detection and diagnosis for Air Handling Unit based on multiscale convolutional neural networks [J]. Energy Build, 2021, 236: 110795.
- [96] Ap BL, Yadav A, Pandey A, et al. IoT based WSN ground water monitoring system with cloud-based monitoring as a service (maas) and prediction using machine learning [J]. Int J Innov Technol Explor Eng, 2019, 9(1): 816–821.
- [97] Ahmed SS, Bali R, Khan H, et al. Improved water resource management framework for water sustainability and security [J]. Environ Res, 2021, 201: 111527.
- [98] Sukor ASA, Muhamad MN, Wahab MNA. Development of *in situ* sensing system and classification of water quality using machine learning approach [A]. Proceedings of the 2022 IEEE 18th International Colloquium on Signal Processing & Applications (CSPA) [C]. Selangor Malaysia: Institute of Electrical and Electronics Engineers Inc; 2022.
- [99] Motta Cabrera DF, Zareipour H. Data association mining for identifying lighting energy waste patterns in educational institutes [J]. Energy Build, 2013, 62: 210–216.
- [100] Norouziasl S, Jafari A. Identifying the most influential parameters in predicting lighting energy consumption in office buildings using data-driven method [J]. J Build Eng, 2023, 72: 106590.
- [101] Şahin M, Oğuz Y, Büyüktümtürk F. ANN-based estimation of time-dependent energy loss in lighting systems [J]. Energy Build, 2016, 116: 455–467.
- [102] Wu DC, Bahrami AB, Razban A, et al. Air compressor load forecasting using artificial neural network [J]. Expert Syst Appl, 2021, 168: 114209.
- [103] McLaughlin E, Choi JK. Utilizing machine learning models to estimate energy savings from an industrial energy system [J]. Resour Environ Sustain, 2023, 12: 100103.

〔收稿日期〕2023-08-01

(上接第 51 页)

- [29] Granvald V, Marciszko C. Relations between key executive functions and aggression in childhood [J]. Child Neuropsychol, 2016, 22(5): 537–555.
- [30] 罗娟, 王桂梅, 徐芸, 等. 青少年攻击行为及其影响因素分析 [J]. 当代护士(下旬刊), 2021, 28(5): 44–47.
- Luo J, Wang GM, Xu Y, et al. Analysis of adolescent aggressive behavior and its influencing factors [J]. Mod Nurse (next ten-day issue), 2021, 28(5): 44–47.
- [31] Mansour R, Dovi AT, Lane DM, et al. ADHD severity as it relates to comorbid psychiatric symptomatology in children with Autism Spectrum Disorders (ASD) [J]. Res Dev Disabil, 2017, 60: 52–64.
- [32] Gaunet F, Besse S. Guide dogs' navigation after a single journey: a descriptive study of path reproduction, homing, shortcut and detour [J]. PLoS One, 2019, 14(7): e0219816.
- [33] Udell MAR, Dorey NR, Wynne CDL. The performance of stray dogs (*Canis familiaris*) living in a shelter on human-guided object-choice tasks [J]. Animal Behav, 2010, 79 (3): 717–725.
- [34] Albuquerque N, Mills DS, Guo K, et al. Dogs can infer implicit information from human emotional expressions [J]. Anim Cogn, 2022, 25(2): 231–240.

〔收稿日期〕2023-04-18