

## 基于联邦学习的暖通空调系统故障检测与诊断

王先圣, 严珂

### 引用本文

王先圣, 严珂. 基于联邦学习的暖通空调系统故障检测与诊断[J]. 计算机科学, 2022, 49(12): 74-80.

WANG Xian-sheng, YAN Ke. [Fault Detection and Diagnosis of HVAC System Based on Federated Learning](#) [J]. Computer Science, 2022, 49(12): 74-80.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

#### Similar articles recommended (Please use Firefox or IE to view the article)

#### [基于改进Sigmoid卷积神经网络的手写体数字识别](#)

Handwritten Numeral Recognition Based on Improved Sigmoid Convolutional Neural Network  
计算机科学, 2022, 49(12): 244-249. <https://doi.org/10.11896/jsjcx.211000179>

#### [基于联邦学习的Gamma回归算法](#)

FL-GRM:Gamma Regression Algorithm Based on Federated Learning  
计算机科学, 2022, 49(12): 66-73. <https://doi.org/10.11896/jsjcx.220600034>

#### [基于联邦学习的车联网多维资源动态分配算法](#)

Multi-dimensional Resource Dynamic Allocation Algorithm for Internet of Vehicles Based on Federated Learning  
计算机科学, 2022, 49(12): 59-65. <https://doi.org/10.11896/jsjcx.211000123>

#### [边缘场景下动态权重的联邦学习优化方法](#)

Federated Learning Optimization Method for Dynamic Weights in Edge Scenarios  
计算机科学, 2022, 49(12): 53-58. <https://doi.org/10.11896/jsjcx.220700136>

#### [联邦学习激励机制研究综述](#)

Survey of Incentive Mechanism for Federated Learning  
计算机科学, 2022, 49(12): 46-52. <https://doi.org/10.11896/jsjcx.220500272>

# 基于联邦学习的暖通空调系统故障检测与诊断

王先圣 严珂

中国计量大学信息工程学院 杭州 310000

(p20030854033@cjl.u.edu.cn)

**摘要** 暖通空调系统的自动化和准确故障检测与诊断是智能工业设施维护领域减少时间、能源和财务成本的最重要技术之一。近年来,基于数据驱动的故障检测与诊断方法在暖通空调方面表现出色,但是大多数方法都只能检测单一故障等级的故障,并且不能进行跨系统故障诊断。为了解决这两个问题,提出一种基于联邦学习的故障检测与诊断方法,该方法使用卷积神经网络来提取信息特征,利用特定算法进行聚合,经过多次联邦学习,能够进行跨故障等级和跨系统故障检测与诊断。在多故障等级故障检测与诊断方面,利用冷水机组4个故障等级数据进行联邦学习。实验结果显示,4个故障等级的故障检测和诊断效果的F1-score平均值接近0.97,已经达到实际应用水平。在跨系统故障检测与诊断方面,利用冷水机组和空气处理机组数据进行联邦学习。实验结果表明,利用不同系统数据进行联邦学习,可以提高某些轻微故障的诊断效果,比如,相比传统机器学习方法,RefOver故障的诊断效果F1-score提升了14.4%,Refleak和Exoil两个故障的诊断F1-score提升了2%~4%。

**关键词:**暖通空调系统;故障检测与诊断;卷积神经网络;联邦学习

中图法分类号 TP391

## Fault Detection and Diagnosis of HVAC System Based on Federated Learning

WANG Xian-sheng and YAN Ke

School of Information Engineering, China Jiliang University, Hangzhou 310000, China

**Abstract** Automation and accurate fault detection and diagnosis of HVAC systems is one of the most important technologies for reducing time, energy, and financial costs in building performance management. In recent years, data-driven fault detection and diagnosis methods have been heavily studied for fault detection and diagnosis of HVAC systems. However, most existing works deal with single systems and are unable to perform cross-system fault diagnosis. In this paper, a federal learning-based fault detection and diagnosis method is proposed, which uses convolutional neural networks to extract information features, aggregates features using special-designed algorithms, and perform cross-level and cross-system fault detection and diagnosis via federal learning. For multi-fault level fault detection and diagnosis, federal learning is performed using data from four fault levels of chillers. Experimental results show that the average F1-score of the fault detection and diagnosis effect of the four-fault levels is close to 0.97, which is within the practical range. Federal learning uses chiller and air handling unit data for cross-system fault detection and diagnosis. Experimental results show that federal learning using different system data improves the diagnosis results of particular faults, e. g., 14.4% for RefOver faults and 2%~4% for both Refleak and Exoil faults.

**Keywords** Heating ventilation and air conditioning systems, Fault detection and diagnosis, Convolutional neural networks, Federated learning

### 1 引言

随着工业的进一步发展,现代化工业产业园正在逐步代替传统工业园。暖通空调系统(HVAC)是现代工业产业园中必不可少的一部分。根据特定的季节和天气,全世界暖通空调系统的能源消耗比例通常在40%~60%<sup>[1]</sup>。随着工业水平的不断提高,这一比例还会继续增大。

暖通空调系统的内部结构非常复杂,主要由冷水机组(Chiller)和空气处理机组(AHU)两个子系统构成。暖通空调系统的各种故障导致了巨大的能源浪费,人工手动检测和

诊断故障的时间成本和经济成本很高<sup>[2]</sup>。为了减少能源和人力成本的浪费,需要一种准确的检测和诊断暖通空调系统故障的方法<sup>[3-4]</sup>。

工业数字化让原本冷冰冰的机器产生了许多有意义的数字。基于这些数据,暖通空调系统故障检测与诊断(FDD)方法大量涌现。现有故障检测与诊断方法主要包括支持向量机(SVM)<sup>[5]</sup>、贝叶斯网络(BN)<sup>[6]</sup>、主成分分析(PCA)<sup>[7]</sup>、极端学习机(ELM)<sup>[8]</sup>、基于树形结构的方法<sup>[9]</sup>和极端梯度提升(XGBoost)<sup>[10]</sup>。

目前故障检测与诊断方法<sup>[5-10]</sup>都只能应用于一个故障

等级。例如使用某种严重程度故障数据训练模型,然后检测相同严重程度故障。对于早期轻微等级的故障,大部分方法的表现较差,大多数研究<sup>[5-10]</sup>仅限于单独探索冷水机组或者空气处理机组的某个单一系统,使用来自单一系统的数据训练模型,然后检测和诊断该系统中的故障,不能进行跨系统的故障检测与诊断。

为了解决暖通空调故障检测与诊断方法目前存在的局限性,本文提出了一种基于联邦学习<sup>[11]</sup>的故障检测与诊断方法(Federated Convolutional Neural Networks, Fed\_CNN)。数据持有者在本地使用私有数据训练模型,然后将模型参数传至服务器。服务器对收到的所有参数进行聚合,在聚合结束后,将聚合参数发送给各个数据持有者。数据持有者接收聚合参数后直接用于测试。本文的主要贡献如下:

(1)提出了一种新颖的联邦学习结构。我们将卷积神经网络与联邦学习相结合,卷积神经网络作为全局模型,利用其强大的特征提取能力,为模型的训练提供更好的条件。联邦学习在保证数据的私密性的同时,利用多方数据进行共同建模,提高模型的泛化能力。

(2)利用联邦学习将不同严重程度故障联合起来,提高了早期轻微故障等级的检测与诊断效果。利用不同严重程度故障数据(同样特征)联合建模,使联合模型能够利用不同严重程度故障进行训练,从而使模型能够更好地应对早期轻微故障。

(3)利用联邦学习进行跨领域故障检测与诊断,提高了冷水机组轻微故障的诊断效果。我们使用冷水机组数据和空气处理机组数据联合建模,两个建模数据选择不同的特征,建模得到的模型能够同时检测冷水机组故障和空气处理机组故障,并且能提高冷水机组中轻微故障诊断的效果。

## 2 相关工作

暖通空调系统的故障检测和诊断可以提高工业环境的舒适度,还可以减少额外的能源浪费。在过去的几十年中,许多研究人员探索了故障检测和诊断方法。目前,故障检测和诊断主要有两种方法:基于模型的方法和基于数据的方法。

基于模型的方法通过数据分析预先建立的判别方程和模型对系统进行评估。例如, Kim等<sup>[12]</sup>使用数学模型通过低成本测量来估算传感器流量,评估了3种不同的虚拟制冷剂质量流量(VRMF)传感器,在估算制冷剂质量流量方面适用于无故障条件下的各种系统。Behfar等<sup>[13]</sup>回顾和分析了4种恒温膨胀阀的质量流量模型,并评估和比较了它们应用于制冷系统时的性能。然而,基于模型的方法需要大量的专业人员对数据进行计算分析,建模周期长。因此,近年来基于模型的方法逐渐减少。

随着工业现代化的普及,收集到的数据越来越丰富。数据驱动方法能够从海量数据中识别不同故障的模式,从而准确可靠地诊断故障。Zhao等<sup>[14]</sup>提出了一种基于支持向量数据描述(SVDD)算法的冷水机组系统数据驱动故障检测方法。在正常情况下,最小体积超球包含大多数数据,位于该超球之外的数据样本将被检测为故障样本。Yun等<sup>[15]</sup>将监督自动编码器(SAE)应用于暖通系统的故障诊断,根据SAE的

重建误差为输入变量提供重要的推断。故障检测与诊断模型只有在能够对输入变量进行显著推断时才能进行故障诊断;否则,该模型将系统状态视为未定义状态,并通过重新训练故障检测与诊断模型提供反馈。Li等<sup>[16]</sup>提出了一种基于改进生成对抗网络(Generative Adversarial Networks, GAN)的建筑暖通空调系统半监督故障检测与诊断方法,用多类分类器代替了原GAN中的二值鉴别器。改进后的GAN通过学习未标记样本中存在的分布信息,将该信息与标记数据结合起来,完成对故障的诊断。Huang等<sup>[17]</sup>将关联分类算法应用于离心式冷水机组故障诊断,该方法通过挖掘故障类别和物理属性之间的强规则来构造关联分类器。Yan等<sup>[18]</sup>提出了一种用于冷水机组系统的混合数据驱动故障检测与诊断方法,该方法结合了带有外生变量的自回归模型和支持向量机。Yan等<sup>[19]</sup>提出了一种基于决策树的机器学习(ML)方法,用于空气处理机组的故障诊断。Mulumba等<sup>[20]</sup>比较了所有空气处理机组故障检测与诊断的ML方法,结果表明,随机森林取得了最佳的诊断精度。Li等<sup>[21]</sup>提出了一种树状结构的在线学习算法来处理冷水机组故障检测与诊断问题。Yan等<sup>[22]</sup>建议使用生成式对抗网络(GAN)来生成合成样本,以帮助提高冷水机组故障检测与诊断的准确性。虽然GAN是深度学习方法,但其只用于生成数据样本,仍然需要一个SVM分类器来完成故障诊断阶段。

## 3 相关网络算法与模型

### 3.1 全局卷积神经网络模型

Cun等<sup>[23]</sup>最初提出卷积神经网络(Convolutional Neural Networks, CNN)用于图像处理。CNN的主要特点包括权重共享和稀疏连接。CNN中的权重共享有效避免了算法的过度拟合,而稀疏连接则减少了训练参数的数量<sup>[24]</sup>。CNN模型可以通过卷积很好地识别数据中的某些特征,然后在更高层次上形成更复杂的信息。本文在联邦学习架构中使用的通用CNN模型如图1所示, CNN模型总体上分为3部分:输入层、隐藏层和输出层。CNN的隐藏层一般由卷积层、池化层和全连接层组成,其中卷积层和池化层用来提取高级特征,全连接层进一步整合特征用于输出层的分类<sup>[25]</sup>。由于数据维度较小,因此我们没有使用池化层进行下采样,每一层的功能解释如下。




图1 全局卷积神经网络模型

Fig. 1 Global convolutional neural network model

#### 3.1.1 卷积层

卷积层(CL)是执行大部分计算的层,其主要目的是从

输入数据中提取特征。它是继输入层之后的网络的第一层。卷积层由多个卷积核组成,用于计算不同的特征图。首先将输入与卷积核进行卷积,将卷积结果输入激活函数来获得新的特征图。为了生成每个特征图,输入的所有空间位置共享卷积核。完整的特征图是使用几个不同的卷积核获得的,卷积公式可以表达为:

$$\mathbf{x}'_k = b'_k + \sum_{i=1}^{N_k-1} \text{conv1D}(\mathbf{w}_{ik}^{-1}, \mathbf{s}_i^{l-1}) \quad (1)$$

其中,  $\mathbf{x}'_k$  定义为输入,  $b'_k$  定义为第  $l$  层的第  $k$  个神经元的偏置,  $\mathbf{s}_i^{l-1}$  是第  $l-1$  层的第  $i$  个神经元的输出,  $\mathbf{w}_{ik}^{-1}$  是第  $l-1$  层的第  $i$  个神经元到第  $l$  层的第  $k$  个神经元的核。conv1D 代表执行一维卷积。

多层卷积之间的具体操作如图 2 所示,卷积中间层的输出  $\mathbf{y}'_k$  可以将  $\mathbf{x}'_k$  输入激活函数  $f(x)$  来表示。现在流行的激活函数有 3 种,即 sigmoid 函数、tanh 函数和整流线性单元(ReLU)。ReLU 函数的具体表示为:

$$\text{ReLU} = \max(\mathbf{x}'_k, 0) \quad (2)$$

其中,  $\mathbf{x}'_k$  是第  $l$  层第  $k$  个神经元的输入。ReLU 是一个分段线性函数,它将负部分标记为零并保留正部分。相比其他两种激活函数,ReLU 函数具有加快学习速度和缓解梯度消失的优势。




图 2 多层卷积内部结构

Fig. 2 Internal structure of multi-layer convolution

### 3.1.2 全连接层

全连接层(FC)是卷积神经网络的重要组成部分。在经过多个卷积层和池化层的堆积后,大部分的架构都会添加一个或者多个全连接层来进一步处理特征。全连接层将前一层中的所有神经元连接到当前层的每个神经元,然后使用非线性函数对特征图进行变换。

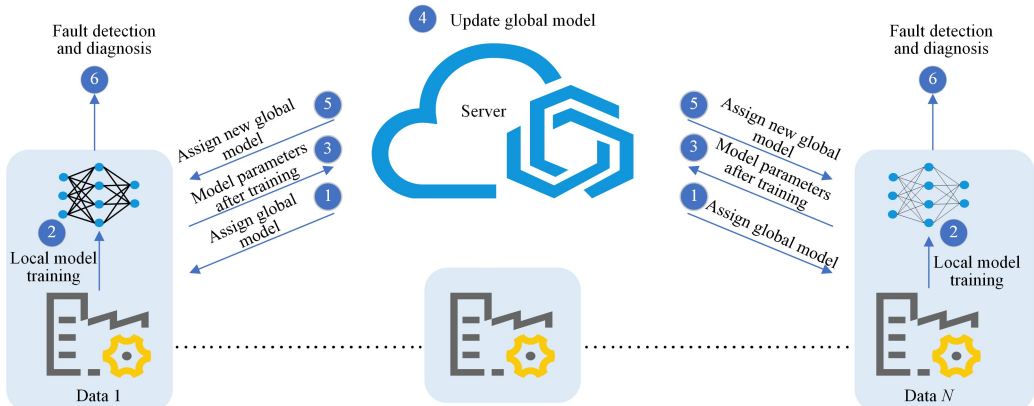


图 3 联邦学习框架

Fig. 3 Federated learning framework

### 3.1.3 输出层

输出层使用之前提取的特征进行最终决策。在故障检测与诊断的多分类问题中,归一化指数函数(Softmax)由于其有效性已成为分类任务中最受欢迎的选择之一。Softmax 操作可以描述为:

$$p(\mathbf{z})_i = \frac{e^{z_i}}{\sum_{i=1}^{N_c} e^{z_i}} \quad (3)$$

其中,  $p(\mathbf{z})_i$  表示  $\mathbf{z}$  属于  $i$  类的概率,  $i \in N_c$ 。

### 3.2 联邦学习

2017 年,谷歌提出了联邦学习,这是一种宏观的分布式学习框架。分布式学习将一个庞大的机器学习任务分成若干个较小的任务,然后将较小的任务分发到各个地方的设备上,使用多个设备来提高机器学习的效率。与传统的分布式学习相比,联邦学习不需要数据传输,保证了数据的私密性。联邦学习在医疗保健、交通和电力方面取得了优异的成绩。

从图 3 可以看出,联邦学习的具体步骤如下:

(1) 中央服务器将全局模型发送给每个客户端。

(2) 不同的客户端接收到中央服务器发送的全局模型,使用自己的私有数据训练模型,并更新模型的权重。为了使全局模型能够被训练,我们进行了特征选择操作,具体特征见 3.3 节特征选择。

(3) 经过训练的客户端将更新后的模型权重发送到中央服务器。每个客户端使用不同的私有数据进行训练,因此每个客户端上传的模型权重是不同的。

(4) 中央服务器从每个客户端接收更新后的权重,然后进行聚合操作,构建一个新的全局模型。在本研究中,我们使用 FedAVG 算法进行参数聚合,表示为:

$$\mathbf{w}_{k+1} = \sum_{c=1}^C \frac{n_c}{n} \nabla \mathbf{w}_c \quad (4)$$

其中,  $\mathbf{w}_{k+1}$  是中央服务器在第  $(k+1)$  轮通信中发送的更新权重,  $\mathbf{w}_c$  是客户端  $c$  发送给中央服务器的权重。参数  $n$  是用于训练全局模型的数据点总数,  $n_c$  是客户端  $c$  用于训练的数据点总数<sup>[26]</sup>。

(5) 经过多次联邦学习后,全局模型逐渐收敛达到预期目标,中央服务器将训练好的全局模型发送给客户端。

(6) 客户端使用从中央服务器接收到的最新模型进行暖通空调系统故障检测与诊断。

### 3.3 特征选择

由于传感器价格昂贵,大部分生产厂商并不会像实验中一样放置多个传感器。因此,特征选择就成为了实验必不可少的一部分,此前的许多研究<sup>[27-28]</sup>也表明,8个特征足够用来进行故障的检测与诊断。冷水机组原始数据集中有65个特征,我们选择其中的8个特征用于本文的研究,如表1所列。使用的特征选择方法是由Sun等在2020年提出的基于SVC的嵌入式特征选择技术(EIFS)<sup>[27]</sup>。AHU原始数据集中有102个特征,我们选择其中的8个特征用于本文的研究,如表2所列。使用的特征选择方法是由Yan等在2018年提出的成本敏感的顺序特征选择(CSSFS)算法<sup>[28]</sup>。

表1 冷水机组重要特征

Table 1 Important features of chillers

Order	Var	Description
1	PO_feed	Pressure of oil feed
2	TCA	Condenser approach temperature
3	VE	Evaporator Valve Position
4	PO_net	Oil Feed minus Oil Vent Pressure
5	FWC	Condenser water flow rate
6	FWE	Evaporator water flow rate
7	TWCD	Condensing temperature
8	Tolerance%	Calculated Heat Balance Tolerance

表2 空气处理机组重要特征

Table 2 Important features of AHU

Order	Var	Description
1	SF-WAT	Supply fan power
2	SA-CFM	Supply air flow
3	RA-CFM	Return air volume
4	SA-TEMP	Supply air temperature
5	MA-TEMP	Mixed air temperature
6	OA-TEMP	Outside air temperature
7	HWC-EWT	Heating water coil discharge air temperature
8	E_coil	Cooling coil load

## 4 实验和结果讨论

### 4.1 数据

本研究使用的冷水机组数据是由美国供热、制冷和空调工程师协会(ASHRAE)的RP-1043项目收集的<sup>[29]</sup>。该项目收集了一个重量约为90t的离心式空调冷水机的故障数据。如图4所示,该项目在空调器的不同位置安装传感器,每10s记录65个特征。这65个特征包括温度传感器(TCA, TWCD等)、阀门传感器(VE, VC等)、流速传感器(FWC, FEW等)和其他传感器数值。本文研究了7个典型的冷水机组故障,包括:冷凝器结垢(ConFoul)、过量油(Exoil)、制冷剂中不凝结物(Noncon)、冷凝器水流量减少(ReduCF)、蒸发器水流量减少(ReduEF)、制冷剂泄漏(Refleak)和制冷剂过量(RefOver)和正常情况。每种故障分为4个严重等级,如表3所列。

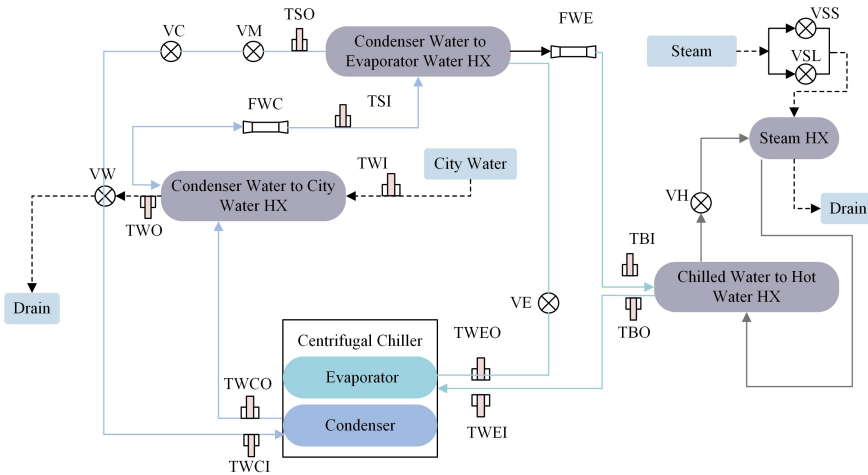


图4 冷水机组内部结构

Fig. 4 Internal structure of chiller

加热线圈、线圈控制阀等部分组成。

表3 7个故障的4个严重级别(级别从1-4)的定量测量

Table 3 Quantitative measurements of four severe levels (levels from 1 to 4) for seven faults

Fault type	(单位:%)			
	Level1	Level2	Level3	Level4
F1(ConFoul)	-12	-20	-30	-45
F2(Exoil)	+14	+32	+50	+68
F3(Noncon)	+1	+2	+3	+5
F4(ReduCF)	-10	-20	-30	-40
F5(ReduEF)	-10	-20	-30	-40
F6(Refleak)	-10	-20	-30	-40
F7(RefOver)	+10	+20	+30	+40

本研究使用的空气处理机组数据集由ASHRAE进行收集,项目编号为1312-RP<sup>[30]</sup>。在此项目中,AHU的基本结构如图5所示,由送风风扇、回风风扇、排气风门、冷却线圈、

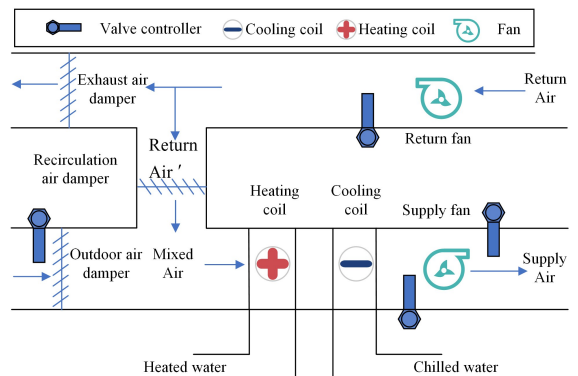


图5 空气处理机组内部基本结构

Fig. 5 Internal basic structure of AHU

该项目使用了两台完全相同的 AHU,其中的一台 AHU 模拟故障发生的情况,另一台模拟设备正常进行的情况。我们挑选了 8 种故障用于本次研究,具体故障如表 4 所列。

表 4 空气处理机组的 8 个故障

Table 4 Eight faults of AHU

Order	Faulty Description
F1	Exhausted air(EA) damper stuck(fully open)
F2	OA damper leak(55% open)
F3	Return Fan at fixed speed(30% spd)
F4	Return Fan complete failure
F5	Cooling coil Valve control unstable
F6	Outdoor air(OA) damper stuck(fully closed)
F7	Cooling coil valve stuck(fully closed)
F8	AHU duct leaking(after supply fan (SF))

## 4.2 联邦卷积神经网络实验

我们使用 3 层一维卷积神经网络作为通用的全局模型。在第一个联邦学习实验(FL1)中,通过特征选择进行数据筛选,然后在不同的客户端中训练不同故障级别的冷水机组数据。训练结束后,4 个模型参数被传送到中央服务器进行聚合,中央服务器将聚合后的参数返回客户端,客户端再次进行训练。重复进行此操作,当全局模型收敛到期望值时,全局模型被发送到 4 个客户端进行故障诊断。在第二个联邦学习实验(FL2)中,利用冷水机组和空气处理机组数据进行联邦学习。为了验证联邦学习在跨领域故障检测和诊断中的能力,我们将 FL2 分为 4 部分。在特征选择后,空气处理机组数据分别与冷水机组的 4 个故障等级数据进行联合学习,例如冷水机组某故障等级数据与空气处理机组数据在不同的客户端中进行训练,训练结束后,两个模型参数被传送到中央服务器进行聚合,中央服务器将聚合后的参数返回客户端,客户端再次进行训练。重复进行此操作直到全局模型收敛,然后使用

全局模型进行故障检测与诊断。

## 4.3 评价指标

目前大部分的研究采用准确率(Accuracy)作为实验结果的评价指标,本文则采用了更为全面的指标 F1-score,定义如下:

$$Precision = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (5)$$

$$Recall = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (6)$$

$$F1\text{-score} = 2 \cdot \frac{Precision \times Recall}{Precision + Recall} \quad (7)$$

其中, $Precision$  为查准率; $N_{TP}$  是预测为阳性,实际也是阳性的数量; $N_{FP}$  是预测为阳性,实际是阴性的数量; $Recall$  为召回率; $N_{FN}$  是预测为阴性,实际是阳性的数量。

## 4.4 实验结果分析

### 4.4.1 FL1 实验结果分析

本文将 Fed\_CNN 模型与其他传统模型进行比较,包括 CNN、长短期记忆网络(LSTM)、嵌套长短期记忆网络(NLSTM)、双向长短期记忆网络(BILSTM)、梯度提升机(LGBM)和循环神经网络(GRU)。Fed\_CNN 模型利用冷水机组 4 个故障等级的数据进行联合建模,可以同时检测和诊断 4 个故障等级的故障。如表 5 所列,Fed\_CNN 在 4 个故障等级的故障检测和诊断中表现良好。在故障等级一中,Fed\_CNN 检测与诊断的 F1-score 为 0.9052,是所有对比模型中唯一超过 0.9 的模型。Fed\_CNN 在故障等级二上的表现出乎意料地好,检测与诊断的 F1-score 比 GRU 模型高出 6%。基于联邦学习模型在故障等级三和故障等级四中也表现良好,虽然没有达到最好的检测与诊断效果,但是联邦学习模型的检测与诊断 F1-score 都在 0.99 以上。

表 5 7 种不同方法对冷水机组故障检测与诊断的比较

Table 5 Comparison of seven different methods for fault detection and diagnosis of chillers

F1-score	Fed_CNN	CNN	LSTM	NLSTM	BILSTM	LGBM	GRU
Level 1	<b>0.9052</b>	0.8836	0.8822	0.8882	0.8937	0.8813	0.8675
Level 2	<b>0.9800</b>	0.9524	0.9386	0.9078	0.9331	0.9194	0.9188
Level 3	0.9943	0.9971	0.9967	0.9933	<b>0.9983</b>	0.9805	0.9954
Level 4	0.9951	0.9984	<b>0.9988</b>	0.9954	0.9931	0.9891	0.9982
Avg	<b>0.9686</b>	0.9579	0.9541	0.9462	0.9546	0.9426	0.9450

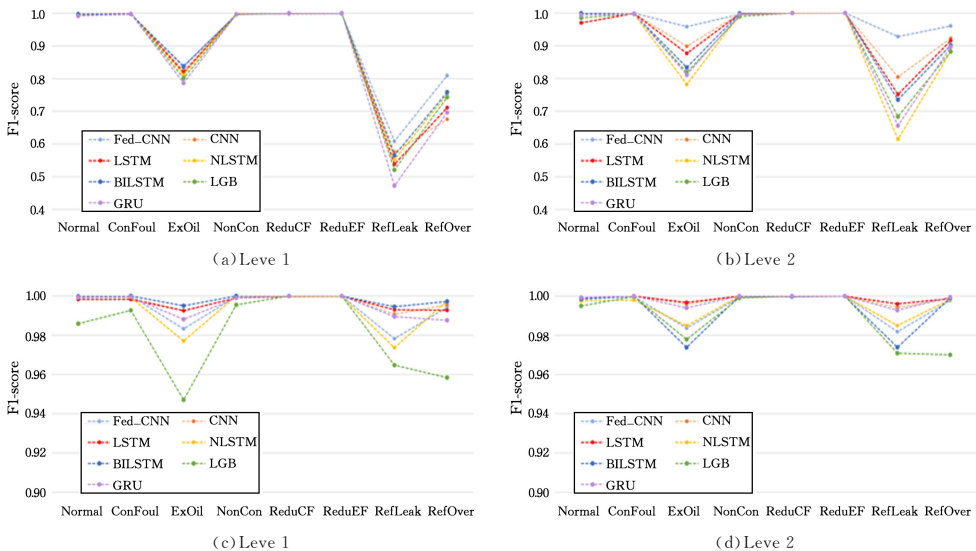


图 6 冷水机组不同故障的 F1-score

Fig. 6 F1-score for different failures of chillers

从图6中可以看到每个故障的检测效果。从整体上看,4个故障等级中,ExOil,Refleak,RefOver这3个故障很难检测,尤其在轻微故障等级中,而本文提出的模型在轻微故障等级中对这3个难以诊断的故障有着巨大的优势。在故障等级三和故障等级四中,本文模型对这3个故障的诊断效果略逊色于其他模型,这是联邦过程中进行权重聚合导致的。

4.4.2 FL2 实验结果分析

我们将冷水机组(Chiller)4个故障等级数据分别与空气处理机组(AHU)数据联合建模,进行跨系统联邦学习。在冷水机组方面,冷水机组4个故障级别的检测与诊断效果并

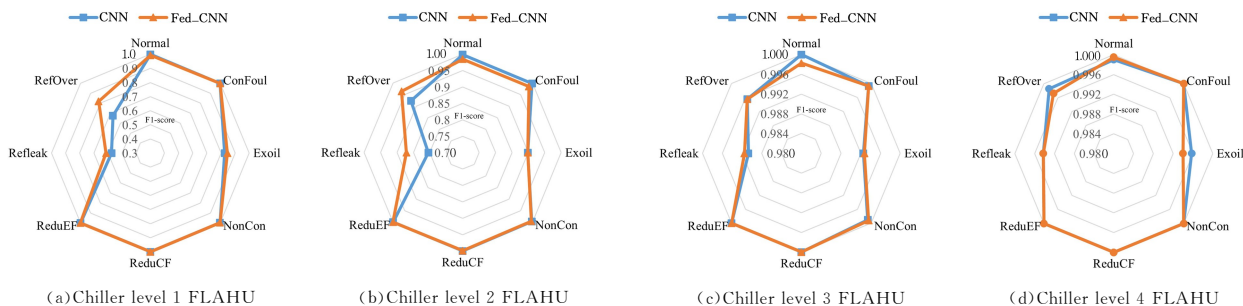


图7 FL2 冷水机组诊断结果  
Fig. 7 FL2 chiller diagnostic results

从图8可以看出,在空气处理机组方面,经过联邦学习后,F5的故障诊断F1-score下降了约1.5%,F8的故障诊断F1-score下降了约0.8%。F3和F4的故障诊断F1-score有

没有下降,甚至略有提高。从图7可以看出,用AHU数据和冷水机组故障等级一数据进行联邦学习后,RefOver故障的诊断效果有了明显的提高,与传统CNN相比,故障诊断的F1-score提高了14.4%,Refleak和Exoil两个故障的诊断F1-score提高了2%~4%,其他故障的诊断效果未受影响。在空气处理机组数据和冷水机组故障等级二数据进行联邦学习后,RefOver和Refleak故障的诊断F1-score提高了约4%~7%。在冷水机组故障等级三和故障等级四中,联邦学习模型对单个故障的检测和诊断效果有轻微的下降,但每个故障的诊断F1-score均超过0.99,整体故障检测效果与传统CNN模型相当。

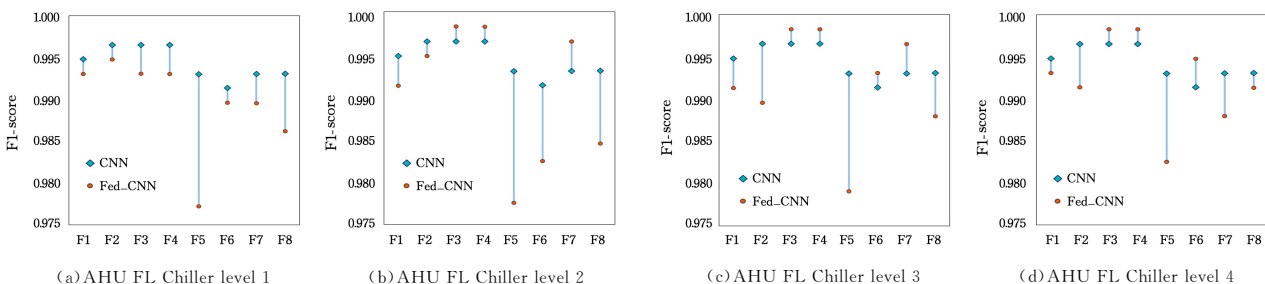


图8 FL2 空气处理机组诊断结果  
Fig. 8 FL2 AHU diagnostic results

**结束语** 随着人工智能技术的快速发展,我们需要将最新的人工智能技术应用于现实生活的各个领域,如节能、可持续设施管理、物联网和网络安全等领域。在这项研究中,我们设计了一个联邦学习模型,利用多方数据共同建模,用于暖通空调系统的故障检测和诊断。综合比较多种研究,结果表明基于联邦学习的暖通空调系统故障检测与诊断方法优于其他故障检测与诊断方法。在冷水机组的故障检测与诊断中,我们利用4个故障级别的数据进行联合建模,实现了4个故障级别的共同检测与诊断。本研究提出的模型利用冷水机组数据和空气处理机组数据进行跨系统联邦学习,可以同时检测和诊断冷水机组和空气处理机组故障。总的来说,本文提出的方法通过对多方数据的联合建模进行联邦学习,可以同时进行多系统的故障检测和诊断,也可以提高轻微故障级别的检测和诊断效果。这为现实生活中的工业应用提供了新的选择。这项研究的未来工作包括将基于联邦的故障检测与诊断

一定提升。从整体故障诊断效果来看,整体故障诊断的F1-score仍保持在0.99左右,说明本文模型能够对故障进行准确诊断。

框架扩展到更广泛的设施管理领域,以提升当前工业应用的性能。预想的应用包括太阳能系统的故障检测与诊断,以及建筑信息模型(BIM)集成建筑设施的故障检测与诊断。

参考文献

[1] OMER A M. Energy, environment and sustainable development [J]. Renewable and Sustainable Energy Reviews, 2008, 12(9): 2265-2300.  
 [2] PAN Y, YANG G H. Event-triggered fault detection filter design for nonlinear networked systems[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2017, 48(11): 1851-1862.  
 [3] YAN K, MA L, DAI Y, et al. Cost-sensitive and sequential feature selection for chiller fault detection and diagnosis[J]. International Journal of Refrigeration, 2018, 86: 401-409.  
 [4] ADHIKARI R, PIPATTANASOMPORN M, RAHMAN S.

- Heuristic algorithms for aggregated HVAC control via smart thermostats for regulation service[J]. *IEEE Transactions on Smart Grid*, 2019, 11(3):2023-2032.
- [5] YAN K, JI Z, SHEN W. Online fault detection methods for chillers combining extended kalman filter and recursive one-class SVM[J]. *Neurocomputing*, 2017, 228:205-212.
- [6] HE S, WANG Z, WANG Z, et al. Fault detection and diagnosis of chiller using Bayesian network classifier with probabilistic boundary[J]. *Applied Thermal Engineering*, 2016, 107:37-47.
- [7] XU X, XIAO F, WANG S. Enhanced chiller sensor fault detection, diagnosis and estimation using wavelet analysis and principal component analysis methods[J]. *Applied Thermal Engineering*, 2008, 28(2/3):226-237.
- [8] YAN K, JI Z, LU H, et al. Fast and accurate classification of time series data using extended ELM; Application in fault diagnosis of air handling units[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Systems*, 2017, 49(7):1349-1356.
- [9] ŽÁKOVÁ M, KŘEMEN P, ŽELEZNÝ F, et al. Automating knowledge discovery workflow composition through ontology-based planning[J]. *IEEE Transactions on Automation Science and Engineering*, 2010, 8(2):253-264.
- [10] CHAKRABORTY D, ELZARKA H. Early detection of faults in HVAC systems using an XGBoost model with a dynamic threshold[J]. *Energy and Buildings*, 2019, 185:326-344.
- [11] XIONG G, YAN K, ZHOU X. A distributed learning based sentiment analysis methods with Web applications[C] // *World Wide Web*. 2022:1-18.
- [12] KIM W, BRAUN J E. Development and evaluation of virtual refrigerant mass flow sensors for fault detection and diagnostics[J]. *International Journal of Refrigeration*, 2016, 63:184-198.
- [13] BEHFAR A, YUILL D. Evaluation of gray box thermostatic expansion valve mass flow models[J]. *International Journal of Refrigeration*, 2018, 96:161-168.
- [14] ZHAO Y, WANG S, XIAO F. Pattern recognition-based chillers fault detection method using support vector data description (SVDD)[J]. *Applied Energy*, 2013, 112:1041-1048.
- [15] YUN W S, HONG W H, SEO H. A data-driven fault detection and diagnosis scheme for air handling units in building HVAC systems considering undefined states[J]. *Journal of Building Engineering*, 2021, 35:102111.
- [16] LI B, CHENG F, CAI H, et al. A semi-supervised approach to fault detection and diagnosis for building HVAC systems based on the modified generative adversarial network[J]. *Energy and Buildings*, 2021, 246:111044.
- [17] HUANG R, LIU J, CHEN H, et al. An effective fault diagnosis method for centrifugal chillers using associative classification[J]. *Applied Thermal Engineering*, 2018, 136:633-642.
- [18] YAN K, SHEN W, MULUMBA T, et al. ARX model based fault detection and diagnosis for chillers using support vector machines[J]. *Energy and Buildings*, 2014, 81:287-295.
- [19] YAN R, MA Z, ZHAO Y, et al. A decision tree based data-driven diagnostic strategy for air handling units[J]. *Energy and Buildings*, 2016, 133:37-45.
- [20] MULUMBA T, AFSHARI A, YAN K, et al. Robust model-based fault diagnosis for air handling units[J]. *Energy and Buildings*, 2015, 86:698-707.
- [21] LI D, ZHOU Y, HU G, et al. Fault detection and diagnosis for building cooling system with a tree-structured learning method[J]. *Energy and Buildings*, 2016, 127:540-551.
- [22] YAN K, CHONG A, MO Y. Generative adversarial network for fault detection diagnosis of chillers[J]. *Building and Environment*, 2020, 172:106698.
- [23] CUN Y L, BOSER B, DENKER J, et al. Handwritten digit recognition with a back-propagation network[J]. *Advances in neural information processing systems*, 1989, 2:96-404.
- [24] REN H, QU J F, CHAI Y, et al. Deep learning for fault diagnosis; The state of the art and challenge[J]. *Control and Decision*, 2017, 32(8):1345-1358.
- [25] KHARE S K, BAJAJ V. Time-frequency representation and convolutional neural network-based emotion recognition[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 32(7):2901-2909.
- [26] GHOLIZADEH N, MUSILEK P. Federated learning with hyperparameter-based clustering for electrical load forecasting[J]. *Internet of Things*, 2022, 17:100470.
- [27] SUN X, YAN K, ZHOU X. Fault Detection and Diagnosis of Chillers with S&D Convolutional Neural Network[C] // *Proceedings of IEEE International Conference on Smart Data*. IEEE, 2020:829-836.
- [28] YAN K, ZHONG C, JI Z, et al. Semi-supervised learning for early detection and diagnosis of various air handling unit faults[J]. *Energy and Buildings*, 2018, 181:75-83.
- [29] XIAO F, ZHENG C, WANG S. A fault detection and diagnosis strategy with enhanced sensitivity for centrifugal chillers[J]. *Applied Thermal Engineering*, 2011, 31(17/18):3963-3970.
- [30] WALL J, GUO Y, LI J, et al. A Dynamic Machine Learning-based Technique for Automated Fault Detection in HVAC Systems[J]. *Ashrae Transactions*, 2011, 117(2):449-456.



**WANG Xian-sheng**, born in 1997, post-graduate. His main research interests include machine learning, deep learning, and fault detection and diagnosis.



**YAN Ke**, born in 1983, Ph.D, associate professor. His main research interests include artificial intelligence, machine learning, data mining, deep learning, and energy control.