

基于新型深度递归网络的空调机组故障诊断研究

王华秋, 朱行行

(重庆理工大学 两江人工智能学院, 重庆 401135)

摘要: 针对空调机组故障数据的特征耦合和时序特征提取的难题, 提出了一种基于深度输出转换循环神经网络(DTO-RNN-LSTM)的故障诊断模型; 每个子块独立处理相关的数据, 可以捕捉更精确的局部特征; 自注意力机制能够增强关键特征在故障诊断中的影响权重, 使得模型能够更加关注那些对诊断结果至关重要的信息; 各子块模型输出的局部特征通过自注意力机制进行加权融合构建出全局特征; 这种融合方法不仅保留了局部特征的独特性, 还能够综合各子块的特征信息, 提供更加全面的诊断依据, 通过 Softmax 层进行分类从而实现了对空调机组故障类型的准确识别; 与传统方法相比, 基于 DTO-RNN-LSTM 的故障诊断模型在空调机组常见故障诊断方面表现出了更优的性能, 该模型不仅提高了系统故障的识别能力, 还显著增强了故障诊断的准确性和可靠性。

关键词: 空调机组; 故障诊断; 深度循环神经网络; 自注意力机制; 算法; 神经网络

Research on Fault Diagnosis of Air Conditioning Unit Based on New Deep Recursive Network

WANG Huaqiu, ZHU Xinghang

(School of Liangjiang Artificial Intelligence, Chongqing University of Technology, Chongqing 401135, China)

Abstract: In response to the difficulty of feature coupling and timing feature extraction for air conditioning unit fault data, a fault diagnosis model based on deep output transition recurrent neural network long short-term memory (DTO-RNN-LSTM) is proposed. Each sub-block processes related data independently, which can capture more accurate local features. The self-attention mechanism can enhance the influence weight of key features in fault diagnosis, so that the model can pay more attention to those information that is crucial to diagnosis results. The local features output by each sub-block model are weighted and fused through the self-attention mechanism to construct global features. This fusion method not only retains the uniqueness of local features, but also integrates the feature information of each sub-block to provide a more comprehensive diagnosis basis. The Softmax layer is used for classification to realize the accurate identification of air conditioning unit fault types. The fault diagnosis model based on DTO-RNN-LSTM has notable advantages over the traditional methods in common fault diagnosis of air conditioning unit. The model not only improves the recognition ability of system faults, but also significantly enhances the accuracy and reliability of fault diagnosis.

Keywords: air conditioning unit; fault diagnosis; deep recurrent neural network; self-attention mechanism; algorithm; neural network

0 引言

在现代建筑中, 空调机组消耗的能源占整个建筑总能耗的 50%~60%。这一比例反映了空调系统在建筑能源消耗中的重要地位, 强调了管理和优化空调系统能源使用的必要性^[1]。空调机组的故障会导致暖通空调系统的工作效率下降 15%~30%。这种效率的下降不仅影响系统的正常运行, 还会导致显著的能源浪费, 进一

步增加运营成本^[2]。因此, 准确检测空调机组中的故障可以有效地缓解能源浪费, 延长设备的使用寿命。通过准确检测和及时修复空调机组的故障, 可以显著减少由于故障导致的能源浪费。

在现代工业领域, 空调机组的故障诊断显得尤为重要。近年来, 随着人工智能技术的发展, 基于机器学习的故障诊断算法在空调机组的应用中取得了显著的进展。这些算法不仅提高了故障检测的准确性, 还减少了

收稿日期:2024-06-23; 修回日期:2024-08-06。

作者简介:王华秋(1975-),男,博士,教授。

引用格式:王华秋,朱行行. 基于新型深度递归网络的空调机组故障诊断研究[J]. 计算机测量与控制, 2025, 33(8):14-21.

维护成本和停机时间,从而提高了设备的整体运行效率^[3-4]。空调机组的运行数据属于典型的时间序列数据,这类数据具有高度的时间相关性。这意味着在进行故障诊断时,分析和处理这些数据需要考虑其随时间变化的特性,以捕捉到潜在的故障模式和趋势^[5-6]。传统的机器学习方法如支持向量机(SVM, support vector machine)^[7]、随机森林(RF, random forest)^[8]和一些浅层的神经网络(如基本的 RNN, recurrent neural network),在处理高维时间序列数据时存在一定的局限性。这些方法在提取数据中的潜在特征时表现不足,导致故障诊断的效果不尽如人意。特别是对于复杂的时间相关特征,这些传统方法的诊断性能常常受到限制。深度学习方法,特别是长短期记忆网络(LSTM, long short term memory)和更高级的 RNN,由于其出色的自动特征提取能力,已经在故障诊断领域得到了广泛应用。这些方法能够有效捕捉和提取时间序列数据中的深层次特征,从而显著提高故障检测的准确性和可靠性。LSTM 由于其在处理长期依赖性问题上的独特优势,尤其在空调机组故障诊断中表现出色^[9]。基于建筑自动化系统的中央空调机组的发展,从而提高了室内的舒适性并降低能耗。然而系统故障存在时间延迟和实际系统故障运行数据缺乏的问题。所以文献[10]提出了一种结合系统仿真模型和智能检测算法的故障检测方法,利用长短期记忆网络 LSTM 可以有效防止设备损坏和系统能量损失,增强系统运行的稳定性以及可靠性。文献[5, 10]中尽管长短期记忆网络(LSTM)在处理具有高度时间相关性和复杂耦合特征的数据方面展现了显著的优势,特别是在空调机组故障诊断这一应用领域中,LSTM 的表现尤为突出。然而 LSTM 的复杂结构和大量的参数使得模型训练和调整变得更加困难,同时,LSTM 能够在一定程度上缓解梯度消失问题,但在处理极长序列数据时,该问题仍然存在。这些因素限制了 LSTM 的广泛应用,尤其是在需要高效、稳定的实时故障诊断系统中。因此,尽管 LSTM 具有显著的优势,但在实际应用中需要权衡其复杂性和潜在问题,以寻找最佳的解决方案。

为摆脱依赖工厂故障历史、机械模型或一组专家规则来隔离故障的现实难题,文献[11]用 RNN 开发了一种新的供暖、通风和空调机组的故障检测与隔离(FDI, fault detection and isolation)方法。基于工厂数据可诊断不同部件的多个故障。仿真实验和真实数据验证显示,该方法优于基于子空间模型的 FDI 方法。近年来,深度学习算法在空调机组故障检测与诊断(FDD, fault detection and diagnosis)中备受关注,尤其是深度循环神经网络(DRNN, deep recurrent neural network)因其能够学习故障的复杂、不确定和时间依赖特性而被广泛应

用。文献[12]选用 DRNN 模型在故障检测和诊断精度上显著优于随机森林(RF)和梯度提升(GB)技术。然而,DRNN 缺乏定制 DRNN 配置的探索和超参数优化的高计算成本^[13],为进一步提升空调机组 FDD 性能就需要调整 DRNN 结构。

深度神经网络在图像识别、语音处理、自然语言处理和视频处理等多个应用场景中的成功应用,展示了强大的学习和适应能力^[14-15]。其中,文献[14]提出的 DRNN-LSTM 方法在车联网中的追尾碰撞检测能力显著提升,提高了检测方法的准确性和效率。这一成功案例表明,深度学习方法在复杂系统中的应用潜力巨大。然而,由于暖通空调系统故障的时延特性以及系统故障运行数据的缺乏,现有的故障检测策略并没有实现高效性。本文旨在借鉴车联网领域的研究成果,探讨深度学习方法在暖通空调系统故障检测中的应用,以期提升检测效率和准确性。

本研究提出了一种新颖的故障诊断方法,称为 SA-DRNN-LSTM。该方法结合了自注意力机制(Self-Attention)和深度输出转换(DTO, deep output transition),以改进空调机组故障的诊断能力。自注意力机制被引入以增强对关键特征的提取能力。自注意力机制允许模型在处理数据时动态地关注输入序列中的不同部分,从而能够捕捉到更具代表性的特征。这种机制有助于从复杂的传感器数据中提取出与故障诊断相关的关键信息,从而提升模型的准确性和鲁棒性^[16-19]。自注意力机制能够动态关注输入数据中的重要部分,而 DTO 则通过多层次的特征融合确保了对数据的全面理解^[20]。最终,通过全连接层和 Softmax 分类器^[21]进行的分类,不仅提高了故障诊断的准确性,还显著改进了模型在不同故障情境下的表现。这表明 DTO-DRNN-LSTM 方法在空调机组故障诊断领域具有显著的优势和应用潜力^[22]。

1 基于 DRNN-LSTM 的故障诊断方法

1.1 基于 DRNN 的故障模型的建立

深度学习通过多个非线性变换层的处理来发现数据的分布特征,模拟人脑对数据间特征的学习。对于 17 个变量:送风温度(SAT, supply air temperature)、送风温度设定点(SATSP, supply air temperature set point)、室外空气温度(OAT, outdoor air temperature)、混合空气温度(MAT, mixed air temperature)、回风温度(RAT, return air temperature)、送风风扇状态(SAFS, supply air fan status)、回风风扇状态(RAFS, return air fan status)、送风风扇速度控制信号(SAFSCS, supply air fan speed control signal)、回风风扇速度控制信号(RAFSCS, return air fan speed control signal)、排风阀控制信号(EADCS, exhaust air damper

control signal)、室外风阀控制信号 (OADCS, outdoor air damper control signal)、回风阀控制信号 (RADCS, return air damper control signal)、冷却盘管阀控制信号 (CCVCS, cooling coil valve control signal)、加热盘管阀控制信号 (HCVCS, heating coil valve control signal)、送风管道静压设定点 (SADSPSP, supply air duct static pressure set point)、送风管道静压 (SADSP, supply air duct static pressure) 及占用模式指示器 (OMI, occupancy mode indicator) 所代表的 11 种故障程度 (如表 1 所示) 与故障类型之间的函数关系, 使用简单的基于机理的模型描述是困难的。

表 1 运行工况类型

工况类型	故障程度	工况标号
正常运行	/	F0
室外风阀卡住	卡在 0% 开度	F1
	卡在 40% 开度	F2
	卡在 45% 开度	F3
	卡在 55% 开度	F4
加热盘管阀泄漏	0.4 加仑/分钟	F5
	1.0 加仑/分钟	F6
	2.0 加仑/分钟	F7
冷却盘管阀卡住	卡在 0% 开度	F8
	卡在 100% 开度	F9
	卡在 15% 开度	F10
	卡在 65% 开度	F11

基于深度学习的模型通过深度神经网络实现输入和输出之间难以解析的非线性函数关系, 属于一种黑箱模型, 因此适合用来构建故障模型。该函数表达为:

$$Y_{fd} = f(\text{SAT}, \text{SATSP}, \text{OAT}, \text{MAT}, \text{RAT}, \text{SAFS}, \text{RAFS}, \text{SAFSCS}, \text{RAFSCS}, \text{EADCS}, \text{OADCS}, \text{RADCS}, \text{CCVCS}, \text{HCVCS}, \text{SADSPSP}, \text{SADSP}, \text{OMI}) \quad (1)$$

为了解决变量与故障之间的函数关系 f 问题, 采用深度学习的方法, 特别是将处理时间序列的循环神经网络 (RNN) 与深度学习网络相结合, 构建深度循环神经网络 (DRNN)。为了增强网络对非线性函数关系的模拟能力, 并解决 RNN 常见的梯度消失问题, 就可以将循环单元替换为长短时记忆 (LSTM) 单元, 从而构建具备长短时记忆功能的深度循环神经网络 (DRNN-LSTM)

具有长短期记忆 (LSTM) 单元的深度递归神经网络 (DRNN) 的 DRNN-LSTM 结构如图 1 所示。输入层 X 代表时间步长处的输入^[2], 也是输入数据输入网络的起点。隐藏层这些是每个隐藏层中的 LSTM 单元或单元。每一层处理输入数据并将其传递到下一层。箭头指示图层和时间步长之间的数据流。 $A_1, A_2, \dots, A_i$ 是每个隐藏层中的 LSTM 单元或单元。每一层处理输入数据并将其传递到下一层。箭头指示图层和时间步长之间的数据流。输出层 y_i 中时间步长处的输出^[2]这是网络在处理完所有隐藏层后产生的最终输出。该图显示了 LSTM 单元在时间上展开。这意味着网络会随时间推移逐步处理数据序列, 跨时间步长保持状态以捕获时间依赖关系。 C_{t-1} 和 h_{t-1} 表示上一个时间步的单元格状态和隐藏状态, 然后被传递到当前的 LSTM 单元。

这种结构使 DRNN-LSTM 能够有效地对序列进行建模并捕获长期依赖关系, 使其适用于涉及顺序数据的任务, 对隐藏层输入一个 X_i 进入第一个 LSTM 层 A_1 , 在此层处理输入并生成输出, 该输出将传递到下一个 A_2 , 依此类推, 直到最后一个 LSTM 层。然后网络是及时展开的, 这意味着每个 LSTM 单元在每个时间步长都处理输入数据以及前一个时间步的状态。这允许网络跨时间步长维护信息并捕获时间依赖关系。隐藏状态 h_i 和单元格状态 C_i 是 LSTM 的关键组件, 它们允许网络随着时间的推移维护和更新信息。隐藏状态用于生成输出, 而单元状态则充当通过序列传递信息的存储器。经过所有隐藏层和时间步长处理后, 最终的隐藏状态 h_i 于生成输出 y_i 在每个时间步。其次, 启发式地设置了实现作业单元 (SAE, self attention encoder) 所需的超参数。输入层由 17 个节点组成, 与输入变量的类型数相同。编码器由 300 个节点组成, 采用整流线性单元 (ReLU) 作为编码器层的激活函数。此外, 为了提高泛化性能, 还采用了批量归一化和信息丢弃 (Dropout) 方法。分类器由 12 个节点组成, 每个节点表示无故障状态和 11 个故障。使用 softmax 函数作为分类器的激活函数。解码器由 17 个节点组成, 节点数与输入变量类型相同, 每个节点代表重构后的输入变量。采用线性单元作为解码器的激活函数。

1.2 基于 DRNN-LSTM 网络的优化

从图 1 可以看出 DRNN-LSTM 网络结构能捕捉数据中更复杂模式并更好地处理长期依赖关系。深度分层模型比浅层模型更有效率。Deep RNN 比传统 RNN 表征能力更强。通常, 由于故障特征的维数和故障类型的数量不同, 传统 RNN 没有中间层, 变换函数都是线性变换紧跟着一个非线性函数, 也就是所谓的浅层变换。传统 RNN:

$$y_t = f_o(h_t, x_t) = \varphi_o(V^T h_t) \quad (2)$$




图 1 DRNN-LSTM 结构

$$h_t = f_h(x_t, h_{t-1}) = \varphi_h(W^T h_{t-1} + U^T x_t) \quad (3)$$

其中: h_t 是时间步 t 的隐藏状态, x_t 是时间步 t 的输入向量, y_t 为输出。 W^T 为状态到状态的权重矩阵, U^T 表示输入到状态, V^T 则表示状态到输出。在传统 RNN 之上再加入的好处在于它允许隐变量 h_t 适应输入模式 x_t 的快速变换, 而且它保留了对过去训练的提炼和总结。 DTO-RNN (Deep Output Transition-RNN):

$$y_t = f_o(h_t) = \varphi_o\{V_L^T \varphi_{L-1}[V_{L-1}^T \varphi_{L-2}(\cdots \varphi_1 V_1^T h_t)]\} \quad (4)$$

DTO-RNN 是为了更好地逼近从状态和输出之间的各种非复杂线性变换。 SAE 的训练过程如图 2 所示。 $loss_a$ 为解码器的损耗, 即原始输入和重构输入的均方误差 (MSE, mean square error); $loss_b$ 为分类器的损失, 是目标标签和预测标签的二元分类交叉熵 (BCE, binary cross-entropy)。 将这两个损失与权重 w_a 和 w_b 相加, 得到最终的损失。 然后进行训练, 使最终损失接近于 0。 在此过程中, 对 SAE 的权值和偏差进行了优化, 以满足预测标签派生和输入重构两个目标。 通过提前停止来设置迭代次数 (epoch), 以防止过拟合。




图 2 SAE 的训练过程

一种结合深度输出转换 (DTO) 和长短期记忆 (LSTM) 网络的递归网络模型 DTO-RNN-LSTM 可以更好地逼近状态和输出之间的非线性变换, 处理时间序列数据, 并且提升故障诊断的准确性和可靠性。 因为 DRNN-LSTM 是一种深度递归神经网络, 它结合了长短时记忆网络 (LSTM) 和深度递归神经网络 (DRNN) 两者的优点, 可以有效地解决序列数据建模问题。 DRNN-LSTM 中引入了自注意力机制 SA, 可以让模型更好地捕捉输入序列中的重要信息, 并对不同位置的信息赋予不同的权重。 自注意力机制是指在计算每个位置的表示时, 考虑该位置与其他所有位置之间的关系, 根据它们之间的相

似度计算出每个位置的权重。 具体来说, 在 DRNN-LSTM 中引入的自注意力机制是通过在每个时刻对输入序列进行注意力计算来实现的。 具体来说, 在每个时刻, 模型会计算当前时刻的隐藏状态与输入序列中所有位置的相似度, 并根据相似度计算出每个位置的权重。 然后, 模型会将所有位置的表示按照对应的权重进行加权平均, 得到一个加权表示, 作为当前时刻的表示。 这种自注意力机制还可以让 DRNN-LSTM 更好地捕捉输入序列中的长程依赖关系, 并对不同位置的信息赋予不同的权重, 从而提高模型的表现力和泛化能力。

2 故障分析实验

2.1 AHU 结构及其故障

中央空调设备 (AHU, air handling unit) 由多个设备和传感器组成, 典型 AHU 的结构如图 3 所示。 在 AHU 中, 使用循环空气阻尼器和室外空气阻尼器将空气混合到所需的比例。 混合空气随后被输送到过滤器、加热盘管和冷却盘管。 过滤器用来过滤空气中的灰尘。 加热盘管用于通过空气与热水的热交换来提高送风温度, 冷却盘管通过空气与冷冻水的热交换来降低送风温度。 两个阀门分别用于调节热水流量和冷冻水流量。 送风风机向室内送风, 满足人体舒适度要求。 回风风机将空气输送到排气阀和再循环阀。 如图 3 所示, 在 AHU 中, 安装了几种类型的传感器, 用于采集温度、流量、湿度比及压力等各种变量, 监控 AHU 的运行状态, 这使得采集的数据更加准确。




图 3 AHU 结构^[22]

2.2 故障特征预处理及分析

ASHRAE RP-1312 数据集由 ASHRAE 资助的 ASHRAE RP-1312 项目的两个真实空调机组的 AHU 收集的数据组成。 AHU-B 在正常条件下运行, AHU-A 模拟冷却盘管, 供应风扇, 阻尼器, 管道和其他设备的多种典型故障。 数据集包含运行中的建筑物供暖、通风和空调机组数据, 以及关于是否存在故障的经过验证的真实信息。 该数据集涵盖了一系列季节和运行条件, 包括多种建筑系统类型、故障类型、故障严重性或强度级别, 重点系统就包括中央空调设备。

图 4 所包含的数据点反映了通常在建筑控制系统中




图 4 RP-1312 数据直方图

记录的测量值。数据集包括模拟（即建模）数据和来自测试设施的实验（即物理）数据。所有的特性都有数值，这使得预处理更容易，因为处理其他数据类型并不简单。将其特征映射到一组表示时间相关变量的数据，这些变量包括一天中的小时数（从 1~24），一年中的天数，给定月份中的一天和月份以及项目时间范围内的年份。

首先对所有数值型数据进行数列汇总统计在表 2，计数、平均值、标准差、最小值、四分位数、最大值。为了验证故障诊断方法，考虑了 12 种运行工况：正常运行 F0、室外风阀卡住 F1、室外风阀卡住 F2、室外风阀卡住 F3、室外风阀卡住 F4、加热盘管阀泄漏 F5、加热盘管阀泄漏 F6、加热盘管阀泄漏 F7、冷却盘管阀卡住 F8、冷却盘管阀卡住 F9、冷却盘管阀卡住 F10、冷却盘管阀卡住 F11。

表 2 RP-1312 数据集数列统计

	送风温度	送风温度设定点	室外空气温度	混合空气温度	回风温度
总计	21 600	21 600	21 600	21 600	21 600
平均数	62.99	57	58.22	67.48	72.61
标准差	7.37	4	21.45	7.87	1.67
最小值	0	55	-0.49	0	0
25%	55.15	55	44.98	64.10	71.34
50%	64.84	55	63.64	68.66	72.81
75%	70.43	55	74.55	72.59	73.44
最大值	79.69	65	91.85	108.24	79.12

基于图 4，可以实施离散性相关操作来改进数据集。

如图 5 所示，“AHU：回风温度”功能具有离散性。现在，查看其直方图，可以发现 AHU：回风温度 ≥ 80 类别的实例数量相对较少。

查看每个属性与蓝线（回风温度）中位数值的相关性，从而找到与之最相关的数据属性。为实际应用程序收集的数据集容易受到一些错误/差异的影响，这可能导致糟糕的数据分析。这些差异可能会影响噪声、不完整的数据及缺失的值等。结合预处理过后的数据，确保能够从数据集中获得更高分辨率的知识。

为了去除噪声，检测异常值，并解决数据集中的差异，合适地填充缺失值，这一步称为

数据清理。必须确保数据是可用的格式。这是通过特征缩放和将多个文件集成到一个包含所有数据的主文件中来实现的。这个阶段被称为数据转换。必须检查与负载预测相关的最重要和最不重要的特征。通过这样做，可以深入了解目标，删除不太相关的属性，并创建高度相关的新特性。通过创建一个按顺序执行所有步骤的管道，将极大地帮助组织所有的过程，达到数据可用性。

如图 6 所示，利用该方法找到最重要的属性为“AHU：送风风扇转速控制信号”并拆分数据使用特征工程找到更好的属性，然后进行数据清理。

所以在数据处理之后，考虑改进 DRNN-LSTM 来进行故障诊断，因为 DRNN-LSTM 是一种结合了深度递归神经网络和长短期记忆神经网络模型，LSTM 有助于捕捉长期依赖性，而 DRNN 的递归结构有助于




图 5 离散相关性




图 6 AHU 属性分析

处理序列中的顺序信息。LSTM 具有记忆单元, 可以记住长期的上下文信息, 并且对于需要长期记忆的任务效果显著。DRNN-LSTM 的结合能够利用 LSTM 的这种能力, 并通过递归结构进一步捕捉序列中的层次性和复杂关系。DRNN-LSTM 能够适应不同长度的输入和输出序列, 这在处理可变长度序列的任务中非常有用。DRNN-LSTM 通过结合 DRNN 和 LSTM 的优势, 可以在故障诊断上提供比单独使用其中一种更好的性能。这种组合可以更好地捕获序列数据的结构和模式。从而使用 DRNN-LSTM 可以帮助在处理序列数据时更好地捕获长期依赖性、上下文信息和序列中的层次结构, 从而提高模型性能。

3 故障诊断实验

3.1 步骤提出

为开展空调机组故障诊断实验, 通过构建和训练 DRNN-LSTM 模型实现。深入挖掘空调机组故障运行数据的特征信息, 通过分析这些数据以识别潜在的故障原因, 从而提高故障诊断的准确性和效率。为此, 我们采用了一种结合了自注意力机制和深度输出转换的 DRNN-LSTM 模型。该模型利用自注意力机制动态调整时间步数据的权重, 以捕捉复杂时序数据中的重要特征, 同时, LSTM 网络处理和记忆长时间序列信息, 克服了传统神经网络在时间序列数据处理中的不足。故障诊断流程如图 7 所示。

研究的目的是成功实现对设备故障的准确诊断, 识别出具体的故障类型, 并验证了 DTO-DRNN-LSTM 模型在故障诊断中的有效性, 结果表明其性能优于传统机器学习模型。

3.2 实验与结果

2007-08-28T0:00~2009-05-31T23:59 中稳定态的数据在经过处理后考虑使用进行故障诊断, 数据分类如表 3 所示。将过滤后的数据标准化后分成 3 个数据集。第一个是训练集, 用于模型训练; 第二个是验证集, 通过判断模型训练过程中是否出现过拟合的情况, 来检验




图 7 故障诊断流程

训练是否执行得当; 第三个是测试集, 用来评估训练模型的性能。

表 3 数据分类

分类	数据大小
训练集	80 % 的故障数据作为训练集
测试集	20 % 的故障数据作为测试集
验证集	未定义数据作为验证集

每种工况的数据采集均以一天 (24 小时) 为单位, 采样时间间隔为 1 分钟, 每天 1 440 个时间序列的数据样本, 数据集中包含了如表 2 所示的 17 个特征变量和表 4 所示的 4 种运行工况类型。其中, 正常运行数据采集天数为 13 天, F1 和 F9 故障采集天数为 2 天, 其余故障采集天数均为 1 天。

表 4 工况类型

工况类型	故障程度	工况标号
正常运行	/	F0
室外风阀卡住	卡在 0 % 开度	F1
	卡在 40 % 开度	F2
	卡在 45 % 开度	F3
	卡在 55 % 开度	F4
加热盘管阀泄漏	0.4 加仑/分钟	F5
	1.0 加仑/分钟	F6
	2.0 加仑/分钟	F7
冷却盘管阀卡住	卡在 0 % 开度	F8
	卡在 100 % 开度	F9
	卡在 15 % 开度	F10
	卡在 65 % 开度	F11

然后使用加入 SA 的 DTO-RNN-LSTM 的情况下, 与传统 RNN, DRNN, DTI-RNN, DRNN-LSTM 等做

一系列比较。引用上述 RP-1312 数据集来进行该方法的对于空调机组故障诊断的实验。




图 8 误差线性图

从图 8 中可以清晰看出，与其他方法相比，S - DTO-DRNN-LSTM 方法（黑色实线）的错误率逐步迭代到 10% 以下，表现为最低，表明其在空调机组故障诊断任务中具有优越的性能。这样看来在 DTO-RNN-LSTM 中将自注意力机制引入，能够根据输入序列的不同部分动态地分配注意力，因此可以更好地捕捉输入序列中的重要信息，从而提高序列建模的能力。又能捕捉序列中任意两个位置之间的依赖关系，因此能够处理更长的依赖关系，而不受限于固定长度的上下文窗口。减少了信息丢失，在一定程度上可以高效地进行并行计算。

3.3 验证

所提出方案的性能以准确率（precision）、召回率（recall）、 F_1 、支持度（support）作为标准来评判验证：

$$precision = \frac{TP}{TP + FP}$$
 (5)

$$recall = \frac{TP}{TP + FN}$$
 (6)

$$F_1 = 2 * \frac{precision * recall}{precision + recall}$$
 (7)

$$support:P(AB) = P(A \cap B)$$
 (8)

其中：真阳性（TP，true positive）是模型对实际真实数据的正确分类，假阳性（FP，false positive）是模型将实际虚假数据错误分类为真实的情况，假阴性（FN，false negative）是模型将实际真实数据错误分类为虚假的情况。Positive 表示具有目标标签的数据，negative 表示具有所有其他标签的数据。精度是指模型确定为正的数据样本中实际为正的数据样本所占的比例。灵敏度是确定为阳性的数据样本与实际阳性数据的比率。当按类别划分的数据数量不平衡时， F_1 将模型的性能表示为一个数字。 F_1 由精度和灵敏度的加权调和平均值计算。

表 5 对比实验验证

模型	准确率 / %	精确率 / %	召回率 / %	F_1	训练时间	推理时间
SVM	85	83	80	0.82	较短	较短
RF	88	86	85	0.85	中等	中等
CNN	90	88	89	0.88	较长	中等
LSTM	92	90	91	0.91	较长	较长
DTO-RNN-LSTM	96	94	94	0.94	较长	较长

表 5 在对比实验中使用同一数据集，保证各模型在相同条件下进行训练和测试。统一的数据预处理步骤，包括数据清洗、标准化和划分训练集、验证集、测试集。SVM 和 RF 等传统模型在处理时间序列数据时，无法有效捕捉数据中的时序关系，导致诊断精度较低。CNN 模型在特征提取方面具有一定优势，但在长时间依赖关系的处理上不如 LSTM 和 DTO-DRNN-LSTM 模型。

DTO-DRNN-LSTM 模型在准确率和精确率方面表现最佳，说明其在处理时间序列数据和长时间依赖关系方面具有显著优势。DTO-DRNN-LSTM 模型的召回率和 F_1 分数也最高，进一步验证了其在故障诊断中的有效性和可靠性。

3.4 消融实验

表 6 确定 DTO-DRNN-LSTM 模型，移除或修改模型的某些部分，构建一系列消融模型。实验过程中使用相同的数据集对每个消融模型进行训练。评估每个消融模型的性能，计算准确率、精确率、召回率和 F_1 等指标。然后比较消融模型与完整模型的性能差异，分析各组件对整体模型性能的贡献。

表 6 消融实验

模型	准确率 / %	精确率 / %	召回率 / %	F_1
Model	96	94	94	0.94
Model A	89	87	85	0.86
Model B	91	89	88	0.88
Model C	93	90	91	0.90
Model D	90	88	87	0.87

Model 代表完整模型，移除第一层 LSTM 层（Model A）准确率和其他指标显著下降，表明第一层 LSTM 层对于捕捉数据中的时序关系至关重要。因为 LSTM 层是 DTO-DRNN-LSTM 模型的核心组件，移除 LSTM 层会显著影响模型性能。移除 Dropout 层（Model B）性能有所下降，但不如移除 LSTM 层影响大，说明 Dropout 层对模型的正则化效果有一定贡献，能减少过拟合。Dropout 层对模型的正则化效果起到重要作用，有助于提升模型的泛化能力。修改激活函数（Model C）性能稍有下降，但影响不如移除 LSTM 层或 Dropout 层大，表明激活函数对模型性能有影响，但相对较小。通

过消融实验,我们验证了 DTO-DRNN-LSTM 模型各组成部分的重要性和贡献,为优化模型提供了有价值的参考。移除 DTO 层 (Model D) 后模型的性能显著下降,说明 DTO 层在处理状态和输出之间的非线性变换时起到了关键作用。

4 结束语

本文首先回顾了前人采用的网络结构和方法,并在此基础上建立了基于 DRNN-LSTM 的故障诊断模型。随后,创新性地将自注意力机制引入 DTO-RNN-LSTM 网络结构,显著提升了模型在捕捉序列中长期依赖关系、动态调整注意力分布以及提高泛化能力等方面的性能。通过这种改进,不仅加速了模型的训练和推理过程,还在数据分析和预测的准确性和效率上取得了显著进展。然而,仍需进一步优化自注意力机制与深层输出转换机制的结合,并探索应对更复杂序列数据的策略。未来期望将此方法应用于更广泛的领域,如智能制造和故障预测,以实现更高效和准确的数据分析,为实际应用带来更多的实际益处。

参考文献:

- [1] BEITER P, ELCHINGER M. 2018 renewable energy data book [Z]. National Renewable Energy Lab., Golden, Co., 2020: 32-42.
- [2] LOMBARD L P, ORTIZ J. A review on buildings energy consumption information [J]. Energy Build, 2008, 40 (3): 394-398.
- [3] QIU A, YAN Z. Modeling of HVAC systems for fault diagnosis [C] //Modeling of HVAC Systems for Fault Diagnosis, IEEE Access, 2020: 248-262.
- [4] ELNOUR M, MESKIN N. Sensor data validation and fault diagnosis using auto-associative neural network for HVAC systems [J]. Journal of Building Engineering, 2020, 27: 910-935.
- [5] ZHU H, YANG W. An effective fault detection method for HVAC systems using the LSTM-SVDD algorithm [J]. Buildings, 2022, 12 (2): 246.
- [6] MTIBAA F. LSTM-based indoor air temperature prediction framework for HVAC systems in smart buildings [J]. Neural Comput. & Applic., 2020, 32: 17569-17585.
- [7] 王忆之. 基于支持向量机的空调机组故障检测与诊断优化研究 [D]. 杭州: 杭州电子科技大学, 2021.
- [8] 王晓佩. 基于随机森林的空调机组典型故障诊断方法研究 [D]. 广州: 华南理工大学, 2020.
- [9] LI Z W, WANG P. A strategy of improving indoor air temperature prediction in HVAC system based on multivariate transfer entropy [J]. Building and Environment, 2022, 219: 109164.
- [10] ZHAO T Y, ZHANG B Y. Handling fault detection and diagnosis in incomplete sensor measurements for BAS based HVAC system [J]. Journal of Building Engineering, 2023, 80: 108098.
- [11] SHAHNAZARI H, MHASKAR P. Modeling and fault diagnosis design for HVAC systems using recurrent neural networks [J]. Computers & Chemical Engineering, 2019, 126: 189-203.
- [12] TAHERI S. Fault detection diagnostic for HVAC systems via deep learning algorithms [J]. Energy and Buildings, 2021, 250: 111275.
- [13] PAVITHRA D. A secured and optimized deep recurrent neural network (DRNN) scheme for remote health monitoring system with edge computing [J]. Automatika, 2023, 64: 508-517.
- [14] ALMUTAIRI M S. Hybrid of deep recurrent network and long short term memory for rear-end collision detection in fog based internet of vehicles [J]. Expert Systems with Applications, 2023, 213: 119033.
- [15] GAO C. Long short-term memory-based deep recurrent neural networks for target tracking [J]. Information Sciences, 2019, 502: 279-296.
- [16] LI D. Residual neural network with spatiotemporal attention integrated with temporal self-attention based on long short-term memory network for air pollutant concentration prediction [J]. Atmospheric Environment, 2024, 329: 120531.
- [17] SHEN C X. Augmented data driven self-attention deep learning method for imbalanced fault diagnosis of the HVAC chiller [J]. Engineering Applications of Artificial Intelligence, 2023, 117: 105540.
- [18] CUI L, TIAN X C. A self-attention based contrastive learning method for bearing fault diagnosis [J]. Expert Systems with Applications, 2024, 238: 121645.
- [19] ZHANG W X. A dual attention mechanism network with self-attention and frequency channel attention for intelligent diagnosis of multiple rolling bearing fault types [J]. Measurement Science and Technology, 2023, 35: 036112.
- [20] MORTEZA A. Deep learning hyperparameter optimization: Application to electricity and heat demand prediction for buildings [J]. Energy and Buildings, 2023, 289: 113036.
- [21] WEI A K, GUAN S. Damage detection of jacket platforms through improved stacked autoencoder and softmax classifier [J]. Ocean Engineering, 2024, 306: 118036.
- [22] YAN Y, CAI J, TANG Y, et al. Fault diagnosis of HVAC AHUs based on a BP-MTN classifier [J]. Building and Environment, 2022: 1-7.