Temperature and Humidity Prediction of Liquid Desiccant Dehumidification Air Conditioning System Based on the Fusion of ITSO and TCN-BiGRU-SA*

WANG Zheyu, OU Xianhua*, WANG Xinkai, HE Xiongxiong
(College of Information Engineering, Zhejiang University of Technology, Hangzhou Zhejiang 310023, China)

Abstract: An air temperature and humidity prediction model for liquid desiccant dehumidification air conditioning system is proposed by integrating improved tuna optimization algorithm (ITSO), time convolutional network (TCN), bidirectional gated recurrent unit (BiGRU) and self-attention mechanism (SA), to solve the problem that the system model is difficult to establish. In the prediction model, TCN is used to capture the local features in the sequence and improve the learning ability of time series dependence, BiGRU is adopted to strengthen the model through the global and bidirectional front and back relationships, the different weights between each time steps are assigned by the self-attention mechanism, and then the optimal hyperparameters of the network are determined by the ITSO algorithm which combines Levy flight strategy and nonlinear adaptive weights. To verify the superiority of the proposed model, a series of experiments are conducted on a liquid desiccant dehumidification air conditioning experimental platform. The results show that the accuracy of the proposed air temperature and humidity prediction model is better than other prediction models.

Key words: liquid desiccant dehumidification air conditioning; temperature and humidity prediction; temporal convolutional network; bidirectional gated recurrent unit; self-attention mechanism; tuna swarm optimization
EEACC: 7220 **doi**: 10.3969/j.issn.1004-1699.2026.09.008

基于 ITSO 与 TCN-BiGRU-SA 融合的溶液除湿空调系统温湿度预测*

王浙宇, 欧县华*, 王心恺, 何熊熊
(浙江工业大学信息工程学院, 浙江 杭州 310023)

摘 要: 针对溶液除湿空调系统空气温湿度模型难以建立的问题, 提出了一种融合改进的金枪鱼优化算法(ITSO)、时间卷积网络(TCN)、双向门控循环单元(BiGRU)和自注意力机制(SA)的溶液除湿空调系统温湿度预测模型。在该模型中, TCN 用于获序列内的局部特征并提高时序依赖性的学习能力, BiGRU 通过全局和双向前后关系强化模型, 自注意力机制为各个时间步骤分配不同的权重, 再采用结合了 Levy 飞行策略和非线性自适应权重的 ITSO 算法寻找网络最优超参数, 从而提升模型预测精度。为验证所提出模型的优越性, 通过在溶液除湿空调实验平台上对所提出模型进行评估, 结果表明所提出温湿度预测模型的精度优于其他预测模型。

关键词: 溶液除湿空调; 温湿度预测; 时间卷积神经网络; 双向门控循环单元; 自注意力机制; 金枪鱼优化算法
中图分类号: TP183 **文献标识码**: A **文章编号**: 1004-1699(2026)09-1977-10

据相关统计, 建筑业在全球能源领域占据着重要的地位, 其能源消耗占全球能源消耗的 40%[1]。事实上, 在建筑各种负荷侧能源需求中, 空调系统负荷几乎占建筑能耗的 40%~50%[2]。因此, 实现建筑空调系统更高效的节能对减少全球能源消耗具有重要意义。溶液除湿空调系统因其除湿能力与低能耗在近年来受到广泛关注[3]。为实现溶液除湿空调系统的更精准与高效的实时控制以及能源效率, 建立准确系统温湿度预测模型显得至关重要。然而, 由于溶液除湿空调系统内部结构复杂, 制冷与除湿过程强耦合性与滞后性, 给建立系统传热传质性能实时预测模型带来了困难。现有的溶液除湿空调传热传质模型主要可分为四类[4]: 有限差分模型、ε-NTU(效率-传递单元数, Number of Transfer Unit)模型、神经网络模型和其他模型。

近年来, 神经网络建模方式被广泛应用, 仅使用

项目来源: 浙江省自然科学基金项目(LQ22F030016); 国家自然科学基金项目(62303418 和 62233016)
收稿日期: 2024-09-09 **修改日期**: 2024-10-28

系统的入口参数来预测系统出口空气的温湿度。Ibrahim 等[5]在多回路集中空调系统上使用长短期记忆(Long Short-Term Memory,LSTM)方法预测室内空气温度,结果显示 LSTM 模型在 R^2、均方误差、平均绝对误差等评价指标上优于循环神经网络(Recurrent Neural Network,RNN)模型。为了进一步减少参数数量,He 等[6]采用了一种仅保留两个门结构的简化 LSTM 网络,即门控循环单元(Gated Recurrent Unit,GRU)网络来预测温室温度。结果表明,GRU 模型的预测效果明显优于随机森林、支持向量机和多元线性回归广义机器学习模型。Li 等[7]基于 TDNN 和 ENN 对变风量空调系统中的室内空气温度进行了建模和预测。结果表明,ENN 更适合预测室内空气温度,因为它的网络结构更简单、存储空间更小、预测精度更高。为了提升预测精度,由多个深度学习模块的混合模型在预测领域中得到越来越广泛地应用。Elmaz 等[8]开发了一个 CNN-LSTM 模型来预测室内温度,其中 CNN 被用作局部特征提取器,从中提取的特征被传输到 LSTM 管道进行多步温度预测。他们的实验结果表明,该模型在长达 2 h 的预测期内稳定(R^2>0.9)。上述模型也存在一些局限性,混合模型中包含多个可调整的超参数,会对预测结果产生直接影响,如何找到最适合该模型的超参数是一个关键问题。因此,把优化算法融入混合模型也是目前的主流趋势。为了优化住宅建筑的空调系统,Guo 等[9]还考虑了四种元启发式算法优化 MLP 模型的可行性,包括樽海鞘群优化、鲸鱼优化、斑鬣狗优化和风驱动优化,结果表明供热负荷预测的准确率从 83.85%提高至 92.48%,制冷负荷预测的准确率从 60.61%提高至 89.29%。

为了建立更精确的溶液除湿空调系统温湿度模型,本文提出了一种融合改进的金枪鱼算法(Improved Tuna Swarm Optimization,ITSO)、时间卷积网络(Temporal Convolutional Network,TCN)、双向门控循环单元(Bidirectional Gated Recurrent Unit,BiGRU)自注意力机制(Self-Attention Mechanism,SA)的预测模型。在该预测模型中,TCN 层主要采用卷积运算来捕获序列内的局部特征和时间依赖性;BiGRU 层接在 TCN 层的末尾,能在更高级别上运行,捕获序列前后关系和远程依赖性;自注意力机制层识别序列的重要特征,为各个时间步骤分配不同的权重;ITSO 算法负责找出最适合该模型的超参数。最后,在溶液除湿空调系统实验平台中评估本文提出的 ITSO-TCN-BiGRU-SA 模型,并与其他模型进行对比,结果表明本文提出的预测模型具有更高的预测精度,能够为后续实时控制提供基础。

1 系统原理

溶液除湿空调系统中主要包含冷却盘管、除湿器与冷却器三个传热传质部件,原理如图 1 所示。

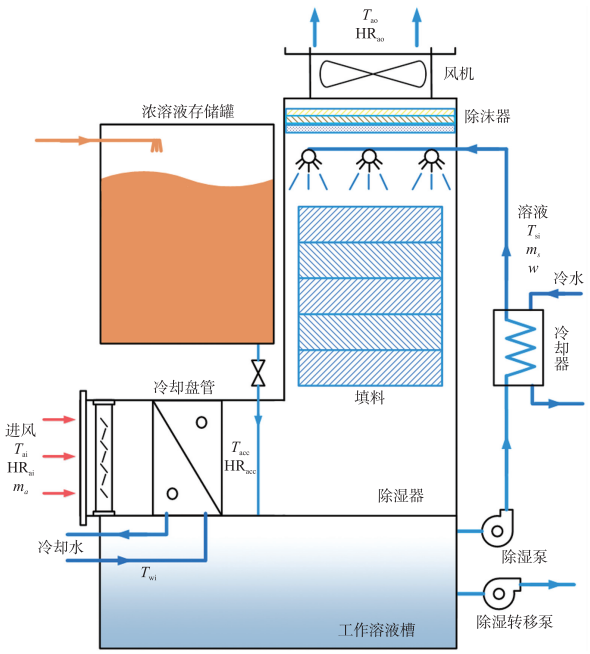

图 1 溶液除湿空调系统

在冷却盘管中,空气与冷水分别由风机与水泵驱使以错流的方式流动,由于两者之间存在温度差,从而发生热传递过程。质量流量为 m_a 的空气通过冷却盘管后,其温度和湿度分别由 T_{ai} 和 HR_{ai} 降低到 T_{acc} 和 HR_{acc}。

在冷却器中,冷水对质量流量为 m_s、浓度为 w 的高温除湿剂溶液通过板式换热器金属壁进行降温,降温后除湿剂溶液温度为 T_{si}。

在除湿器中,空气与除湿剂溶液分别通过风机与溶液泵驱使以逆流的方式通过除湿塔中的填料,并直接接触。除湿器入口空气自下而上通过填料后,与填料表面流动的低温除湿剂溶液接触并发生热传递与质传递,热量与水蒸气从空气中转移到除湿剂溶液中。系统出口的空气温度与湿度分别降到 T_{ao} 和 HR_{ao}。

由于整个空气制冷关于除湿过程分阶段进行,传热传质过程复杂,经过冷却盘管后的空气温度 T_{acc} 和湿度 HR_{acc} 不易测得,因此预测模型中只考虑外部的输入。

2 基于 ITSO-TCN-BiGRU-SA 的预测模型构建

2.1 时间卷积神经网络

时间卷积网络(TCN)是一种具有特殊结构的新

型 CNN,在传统一维 CNN 的基础上,结合了因果卷积、扩张卷积和残差连接[10],相比循环神经网络,可以解决梯度消失和爆炸的问题。

2.1.1　因果卷积

因果卷积[11]是一个时间约束模型,公式如下:

$$P(x_t)=\prod_{t=1}^{T}P(x_t\mid x_1,x_2,\cdots,x_{t-1}) \tag{1}$$

式中:$P(x_t)$是预测概率,T 是总时间,Π 是正交运算。TCN 的输出序列与输入序列长度相同,网络的输出仅与之前的输入相关,避免了未来的信息泄漏,其结构如图 2 所示。

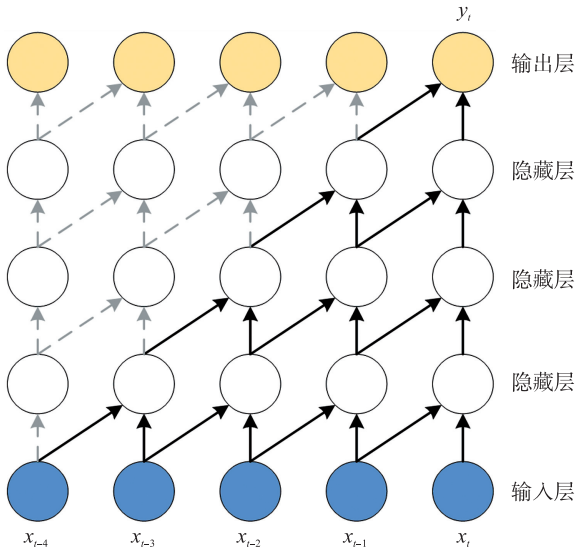

图 2　因果卷积结构

2.1.2　扩张卷积

与普通卷积不同,扩张卷积通过指数级增加卷积层的扩张率,使 TCN 能够以更少的网络层数实现最大可能的感知领域[12]。如图 3 所示,扩张卷积的指数增长的扩张系数 $d_i=2^i$(i 是网络层数)。表达式 F 计算如下:

$$F(s)=(x_d^{*}f)(s)=\sum_{i=0}^{k-1}f(i)\times x_{s-d\times i} \tag{2}$$

式中:k 是卷积核的大小,d 是扩张系数,$(s-d\times i)$表示对时序信息的索引。

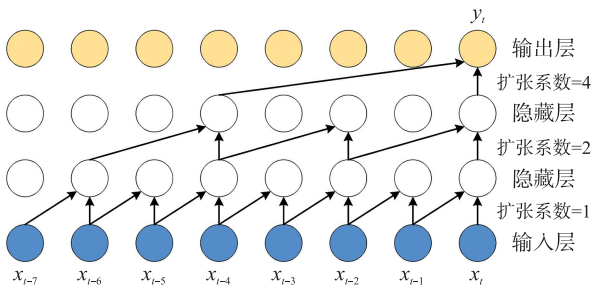

图 3　扩张卷积结构

2.1.3　残差模块

TCN 模型引入了残差模块,避免了网络深度过大造成的信息丢失和不稳定问题,其核心思想是引入一层或多层“跳连接”操作。

残差模块包括两层扩张的因果卷积层和一个非线性映射,并且还结合了权重范数和 Dropout 来对网络进行正则化,其结构如图 4 所示。为了纠正输入和输出宽度的差异,实现了一个额外的一维卷积,以确保求和操作(⊕)中涉及的两个张量保持一致的形状。残差块输出为:

$$o=\mathrm{Activation}[x+F(x)] \tag{3}$$

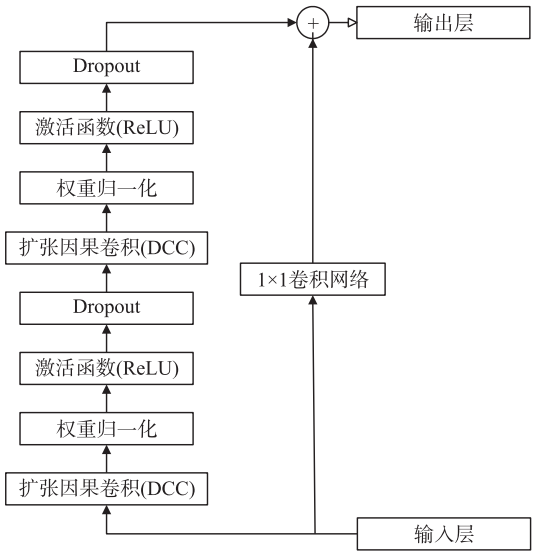

图 4　残差模块结构

2.2　双向门控循环单元

门控循环单元[13](GRU)是一种循环神经网络,属于 LSTM[14]的一种变体,也是为了解决长期记忆和反向传播中的梯度等问题而提出的。典型的 GRU 单元如图 5 所示。与 LSTM 相比,GRU 的参数更少,准确率几乎相同。

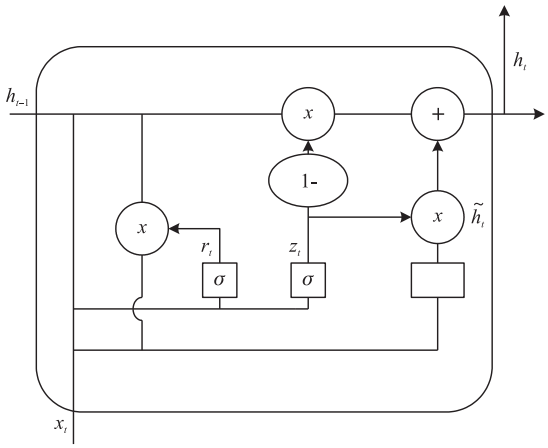

图 5　GRU 模型结构

具体公式如下：

$$z_t=\sigma(W^Z x_t+U^Z h_{t-1}) \tag{4}$$

$$r_t=\sigma(W^r x_t+U^r h_{t-1}) \tag{5}$$

$$\tilde{h}_t=\tanh(r\odot Uh_{t-1}+Wx_t) \tag{6}$$

$$h_t=(1-z_t)\odot\tilde{h}_t+z_t\odot\tilde{h}_{t-1} \tag{7}$$

式中：x_t 为 t 时刻的输入，h_{t-1} 表示 $t-1$ 时刻隐藏单元的状态，h_t 表示输出和传递到下一个单元的隐藏状态。σ 表示 Sigmoid 函数，它是一个门控信号，起到激活函数的作用。tanh 是另一个激活函数。W^Z 和 U^Z 是更新门的权重，W^r 和 U^r 是更新门的权重重置门，U 和 W 是 $\tilde{h}_t$ 的权重，r_t 是重置门的状态，$\odot$ 表示 Hadmard 乘积。

BIGRU 又称双向门控循环单元，是 GRU 的一种变体，实现正向和反向双向传播，使输出层在正向传播的基础上进行反向传播。每个训练序列分别以正向和反向的方式呈现到两个不同的隐藏层。然后将这些层链接到相同的输出层，该输出层随后包含输入序列中每个点过去和未来发生的完整信息。与单向 GRU 模型相比，BIGRU 模型收敛速度快，不易过拟合。BIGRU 的输出依赖于前向状态和后向状态影响的双重权重，提高了最终输出结果的准确性。BiGRU 的结构如图 6 所示。

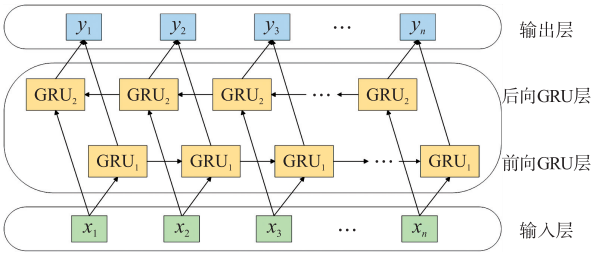

图 6 BiGRU 模型结构

2.3 自注意力机制模块

自注意机制[15]（SA）是一种模仿人类视觉机制的直观解释方法。它经常用于深度学习任务，例如自然语言处理、图像分析和负载预测。人们发现通过在网络模型中添加注意力机制和权重分配原则可以有效保留相关的时间序列信息。自注意力机制的结构如图 7 所示，其计算公式如下：

$$\text{Attention}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=\text{Softmax}\left(\frac{\boldsymbol{QK}^{\mathrm{T}}}{\sqrt{d_k}}\right)\boldsymbol{V} \tag{8}$$

式中：$\boldsymbol{Q}$ 是查询矩阵，$\boldsymbol{K}$ 是键矩阵，$\boldsymbol{V}$ 是值矩阵。通过计算 $\boldsymbol{Q}$ 与 $\boldsymbol{K}$ 的乘积来确定自注意力机制中每个查询元素对所有键元素的重要性。再将结果除以 $\sqrt{d_k}$，最后通过 Softmax 函数得到每一个位置的注意力权重，输出加权和。

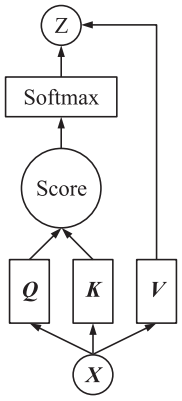

图 7 自注意力机制结构

2.4 改进的 TSO 算法

2.4.1 TSO 算法

金枪鱼优化算法（Tuna Swarm Optimization，TSO）是 Xie 等[16]2021 年提出的一种群体智能优化算法，该算法模拟了金枪鱼群抛物线觅食和螺旋觅食两种觅食行为。

金枪鱼群中有 NP 条金枪鱼。在群体初始化阶段，金枪鱼群体优化算法在搜索空间中随机生成初始群体。初始化金枪鱼个体的数学公式如下：

$$X_i^{\text{int}}=\text{rand}\times(\text{ub}-\text{lb})+\text{lb},\quad i=1,2,\cdots,\text{NP} \tag{9}$$

式中：X_i^{int} 是第 i 个初始个体，每个个体在金枪鱼群中代表 TSO 的候选解决方案，ub 和 lb 是搜索空间的上下边界，rand 是范围从 0 到 1 的均匀分布的随机向量。

金枪鱼群有两种觅食策略，分别是螺旋觅食策略和抛物线觅食策略，选取任一策略的概率为 50%。螺旋觅食策略的数学公式如下：

$$\alpha_1=a+(1-a)\times\frac{t}{t_{\max}} \tag{10}$$

$$\alpha_2=(1-a)-(1-a)\times\frac{t}{t_{\max}} \tag{11}$$

$$\beta=\mathrm{e}^{bl}\times\cos(2\pi b) \tag{12}$$

$$l=\mathrm{e}^{3\cos\{[(t_{\max}+1/t)-1]\pi\}} \tag{13}$$

$$X_i^{t+1}=\begin{cases}\alpha_1\times(X_{\text{rand}}^t+\beta\times|X_{\text{rand}}^t-X_i^t|)+\alpha_2\times X_i^t & i=1\\ \alpha_1\times(X_{\text{rand}}^t+\beta\times|X_{\text{rand}}^t-X_i^t|)+\alpha_2\times X_{i-1}^t & i=2,3,\cdots,\text{NP}\end{cases}\quad \text{if rand}<\frac{t}{t_{\max}}$$

$$\begin{cases}\alpha_1\times(X_{\text{best}}^t+\beta\times|X_{\text{best}}^t-X_i^t|)+\alpha_2\times X_i^t & i=1\\ \alpha_1\times(X_{\text{best}}^t+\beta\times|X_{\text{best}}^t-X_i^t|)+\alpha_2\times X_{i-1}^t & i=2,3,\cdots,\text{NP}\end{cases}\quad \text{if rand}\geqslant\frac{t}{t_{\max}} \tag{14}$$

式中:x_i^{t+1} 为第 $t+1$ 次迭代的第 i 个个体,X_{best}^t 为当前最优个体,α_1 控制金枪鱼个体游向最优个体或随机选择相邻个体的趋势权重系数。α_2 是控制金枪鱼个体向前方个体游动的趋势权重系数。β 是距离参数,控制金枪鱼个体与最佳个体或随机选择的参考个体之间的距离。a 是一个常数,用于确定初始阶段金枪鱼跟随最优个体和前一个个体的程度,t 表示当前迭代次数,$t_{\max}$ 是最大迭代次数,b 是 0 到 1 之间均匀分布的随机数。

抛物线觅食的数学公式如下:

$$X_i^{t+1}=\begin{cases}X_{\text{best}}^t+\text{rand}\times(X_{\text{best}}^t-X_i^t)+\\ \quad \text{TF}\times p^2\times(X_{\text{best}}^t-X_i^t) & \text{if rand}<0.5\\ \text{TF}\times p^2\times X_i^t & \text{if rand}\geqslant 0.5\end{cases} \tag{15}$$

$$p=\left(1-\frac{t}{t_{\max}}\right)^{(t/t_{\max})} \tag{16}$$

式中:TF 是 1 或-1 的随机值。

2.4.2　ITSO 算法

由于金枪鱼算法在初始化阶段随机生成金枪鱼的位置,容易使初始金枪鱼聚集在同一位置,初始金枪鱼群不能完全覆盖搜索空间,导致金枪鱼个体间差异性较小,大大降低了算法的全局搜索能力。因此本文采用改进的 Circle 混沌映射取代原始算法中随机产生的初始种群,公式如下:

$$x_{i+1}=\text{mod}[3.8x_i+0.4-(0.7/3.8\pi)\sin(3.8\pi x_i),1] \tag{17}$$

式中:x_i 是第 i 个混沌粒子,x_{i+1} 是第 $i+1$ 个混沌粒子。

利用改进的 Circle 混沌映射算子对 TSO 进行修改,可以得到更加均匀的候选解。算法的初始金枪鱼个体均匀分布在搜索空间中,可以显著增加 TSO 的种群多样性。

非线性自适应权重如何平衡群体智能优化算法的探索能力和开发能力非常重要。权重参数在 TSO 算法中起着重要作用。当金枪鱼选择螺旋觅食策略时,式(10)和式(11)中,权重参数 α_1 和 α_2 决定了金枪鱼个体跟随最优个体觅食的程度,这反映了算法的优化过程。

类似地,在抛物线觅食策略中,式(16)中的权重参数 p 决定了普通个体追随最优个体的程度。当权重参数较大时,金枪鱼追随最优个体的程度较高,使得整个金枪鱼种群更好地探索整个空间。当权重参数较小时,普通金枪鱼个体不会跟随最优个体。它们会围绕一小部分空间游动,这有助于普通金枪鱼个体在自身周围形成区域。综上所述,TSO 的探索和开发能力取决于权重参数 α_1、α_2 和 p 的变化。

然而,TSO 的优化过程非常复杂,权重参数 α_1 和 α_2 的线性变化不能反映算法的实际优化过程。目前,为了克服线性控制权重带来的弊端,许多学者利用非线性自适应权重来改进群体智能优化算法[17]。反复实验表明,非线性自适应权重策略的优化效果优于线性权重策略。将权重系数 α_1、α_2、p 更改为 α_{1i}、α_{2i} 和 p_i,公式如下:

$$\alpha_{1i}(t)=\alpha_{1\text{ini}}-(\alpha_{1\text{ini}}-\alpha_{1\text{fin}})\times\sin\left(\frac{t}{\mu\times t_{\max}}\times\pi\right) \tag{18}$$

$$\alpha_{2i}(t)=\alpha_{2\text{ini}}-(\alpha_{2\text{ini}}-\alpha_{2\text{fin}})\times\sin\left(\frac{t}{\mu\times t_{\max}}\times\pi\right) \tag{19}$$

$$p_i(t)=p_{\text{ini}}-(p_{\text{ini}}-p_{\text{fin}})\times\sin\left(\frac{t}{\mu\times t_{\max}}\times\pi\right) \tag{20}$$

式中:$\mu=2$,$\alpha_{1\text{ini}}$ 表示 α_1 的初始值,$\alpha_{1\text{fin}}$ 表示 α_1 的最终值,$\alpha_{2\text{ini}}$ 表示 α_2 的初始值,$\alpha_{2\text{fin}}$ 表示 α_2 的最终值,p_{ini} 表示 p 的初始值,p_{fin} 表示 p 的最终值。改进后的权重参数 α_{1i}、α_{2i} 和 p_i 在前期变化较快,使得普通金枪鱼个体能够更加紧密地跟随最优个体,提高了 TSO 的全局探索能力;在后期变化较慢,使得金枪鱼个体能够更加主动地探索其周边区域,提高了 TSO 的局部搜索能力。

对于群体智能优化算法来说,如何摆脱局部吸引点的影响是一个重要的问题。Levy 飞行策略是一种能够增强 TSO 全局探索能力的方法。这种机制常常采用短步行走,偶尔采用长步跳跃。低频使用长步长可以保证 TSO 能够广泛搜索整个搜索区域,短步长的高频使用可以保证 TSO 能够局部搜索到其最近的范围。因此引入 Levy 算子来修改 TSO 的群体更新策略。

Levy 飞行机制为:

$$\text{levy}(s)=0.01\times\frac{u}{|v|^{1/\xi}} \tag{21}$$

$$u\sim N(0,\sigma^2) \tag{22}$$

$$v\sim N(0,1) \tag{23}$$

式中:$\xi=1.5$,方差 σ 如式(24)所示:

$$\sigma=\left[\frac{\Gamma(1+\xi)\sin\left(\frac{\pi\xi}{2}\right)}{\xi\times\Gamma\left(\frac{1+\xi}{2}\right)\times 2^{\frac{1-\xi}{2}}}\right]^{1/\xi} \tag{24}$$

$$\Gamma(x)=\int_0^{+\infty}\mathrm{e}^{-t}t^{x-1}\mathrm{d}t \tag{25}$$

基于 Levy 算子和非线性自适应权重策略的改进螺旋觅食策略的数学模型如下:

$$X_i^{t+1}=\begin{cases}\alpha_{1i}\times[X_{\text{rand}}^t+\text{Levy}(s)\times|X_{\text{rand}}^t-X_i^t|]+\alpha_{2i}\times X_i^t & i=1\\ \alpha_{1i}\times[X_{\text{rand}}^t+\text{Levy}(s)\times|X_{\text{rand}}^t-X_i^t|]+\alpha_{2i}\times X_{i-1}^t & i=2,3,\cdots,\text{NP}\end{cases}\quad \text{if rand}<\frac{t}{t_{\max}}$$

$$\begin{cases}\alpha_{1i}\times(X_{\text{best}}^t+\beta\times|X_{\text{best}}^t-X_i^t|)+\alpha_{2i}\times X_i^t & i=1\\ \alpha_{1i}\times(X_{\text{best}}^t+\beta\times|X_{\text{best}}^t-X_i^t|)+\alpha_{2i}\times X_{i-1}^t & i=2,3,\cdots,\text{NP}\end{cases}\quad \text{if rand}\geqslant\frac{t}{t_{\max}}\tag{26}$$

2.5 ITSO-TCN-BiGRU-SA 模型

本文提出的 ITSO-TCN-BiGRU-SA 预测模型结构如图 8 所示。BiGRU 层被引入到 TCN 模型的末尾,将双向循环处理合并到 TCN 的特征表示中,这样能进一步提升模型对序列数据的理解,进而增强序列数据的建模能力[18]。TCN 用于捕获局部特征和时间依赖性,而 BiGRU 则引入双向前后关系。BiGRU 可以捕获来自前向和后向的信息,这对于涉及全局前后关系和远程依赖关系的任务特别有益。将自注意力机制引入 TCN-BiGRU 模型中,能够强调关键的时间步骤并捕获序列内的长期依赖性,从而提高模型的预测能力。通过为不同的时间步骤分配不同的自注意力权重,自注意力机制可以更好地识别重要特征,有助于从时间数据中提取更多信息丰富的特征表示。TCN-BiGRU 模型的架构有效地处理长序列数据,自注意力机制帮助模型关注不同时间尺度的重要信息,缓解长序列中梯度消失等问题,并根据当前输入和过去的信息有选择地关注特定的时间步骤,使模型能够在预测或分类任务期间更好地理解前后关系[19]。引入自注意力机制后得到的 TCN-BiGRU-SA 模型可以选择性地从不同时间步长中提取关键特征,捕获序列中的长期依赖性和重要信息。这有助于提高模型在序列建模和预测任务中的性能。

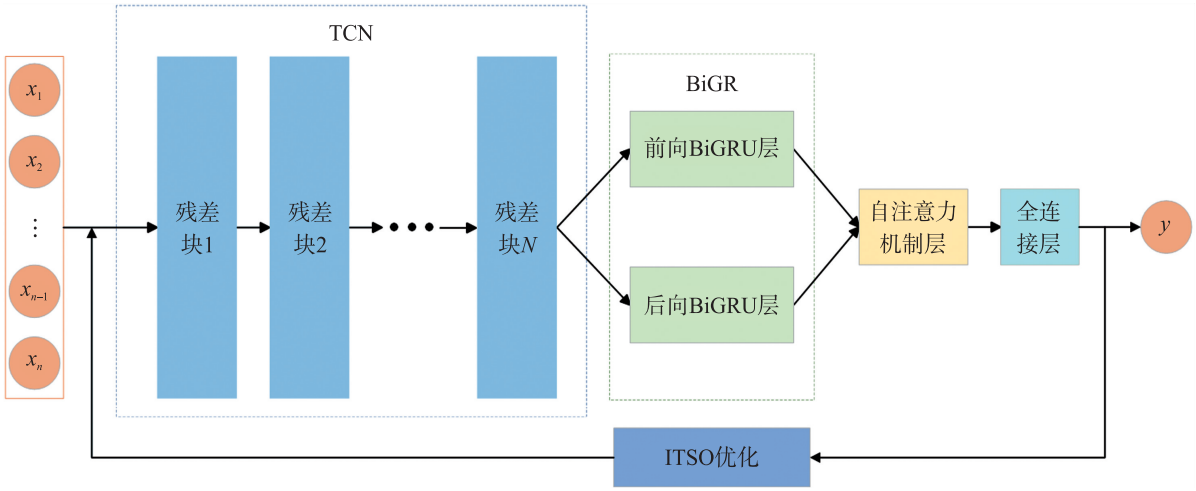

图 8 ITSO-TCN-BiGRU-SA 预测模型结构图

由于神经网络的各参数大多是由人工试凑给定的,很难找出最适合该模型的网络参数,因此将 ITSO 优化算法引入 TCN-BiGRU-SA 模型,针对该模型影响较大的学习率、TCN 扩张系数、过滤器数、BiGRU 隐藏层神经元个数、自注意力机制的键值和正则化参数进行寻优,找到最适合该模型的参数。ITSO-TCN-BiGRU-SA 预测模型结流程如图 9 所示。将预测值和期望值的平均绝对百分比误差作为适应度函数,用式(27)表示:

$$Y_{\text{MAPE}}=\frac{1}{n}\sum_{t=1}^{n}\frac{|y_t-\hat{y}_t|}{y_t}\times 100\% \tag{27}$$

具体步骤如下:

步骤 1:划分训练集和测试集,并对数据进行归一化处理。

步骤 2:对超参数进行寻优,设置超参数的上下界、初始鱼群规模和最大迭代次数;用式(17)生成初始种群位置。

步骤 3:计算 ITSO 算法的适应度函数,根据 ITSO 算法搜索原理,寻找最优金枪鱼个体位置。

步骤 4:设定一个随机数 rand,若 rand<0.5,则用式(9)初始化位置,反之则采用改进的觅食方法更新位置;其中,觅食方法有两种,当 rand<0.5 时,采用式(15)抛物线觅食策略更新位置,反之则采用式(26)改进的螺旋觅食策略更新位置。

步骤 5:将更新完位置的个体参数代入 TCN-BiGRU-SA 模型中,将预测的温湿度结果保存,若未到达最大迭代次数,则返回步骤 3,反之则输出最优参数和结果,算法迭代过程结束。

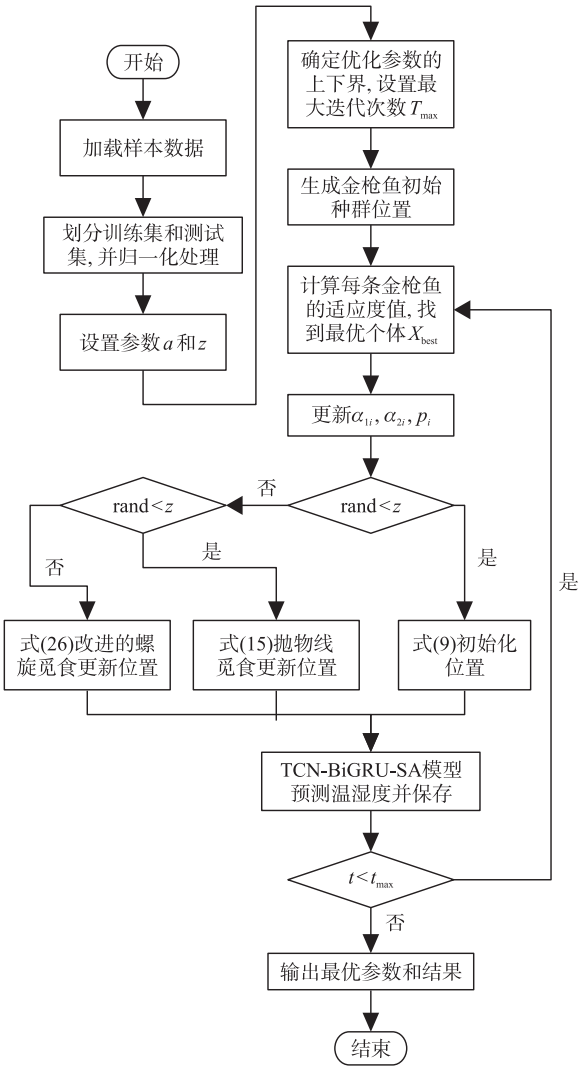

图 9　ITSO-TCN-BiGRU-SA 预测模型流程图

3　仿真和实验

3.1　实验数据采集及仿真环境

溶液除湿空调系统实验平台以氯化锂水溶液为除湿剂,主要包含冷却盘管、除湿器、冷却器等,实验平台如图 10 所示。

图 10　溶液除湿空调系统实验平台

通过传感器测量并采集空气的流量、温度与湿度,除湿剂溶液的流量与温度等。由于系统出口空气温湿度受多种因素共同影响,根据传热传质模型的特性,将温度和湿度分开预测。温度模型选择系统入口空气温度 T_{ai}、入口空气湿度 HR_{ai}、入口空气流量 m_a、除湿剂溶液温度 T_{si}和除湿剂溶液流量 m_s 作为输入,系统出口温度 T_{ao}作为输出;湿度模型选择系统入口空气温度 T_{ai}、入口空气湿度 HR_{ai}、入口空气流量 m_a、除湿剂溶液温度 T_{si}、除湿剂溶液流量 m_s 和浓度 w 作为输入,系统出口湿度 HR_{ao}作为输出[20-22]。

实验平台一共测得 3 268 组样本数据,每组样本数据间隔时间为 10 s,按照 8∶2 划分,前 80%作为训练集,后 20%作为测试集。为了消除数据的量纲并提升计算效率,对样本数据进行归一化处理,具体公式如下:

$$x_n=\frac{x-x_{\min}}{x_{\max}-x_{\min}} \tag{28}$$

式中:x 为样本数据,$x_{\min}$为样本数据中最小的值,$x_{\max}$为样本数据中最大的值,x_n 为数据归一化之后的值。

本实验采用 Windows 10 操作系统,Intel Core CPU i5-11400H,16 GB RAM;所提出模型在 MATLAB R2023b 中运行。

3.2　ITSO 算法性能对比

为了验证 ITSO 算法的优越性,将 ITSO 算法和 TSO 算法在 $F_1\sim F_4$ 基准测试函数上进行测试。设置优化维度 D 为 30,种群大小 N 为 30,最大迭代次数 T_{max}为 500,分别独立运行 20 次,取平均值。$F_1\sim F_4$ 基准测试函数在搜索空间内的最小值均为 0,参数范围如表 1 所示,两种算法的测试结果如表 2 所示,收敛曲线如图 11 所示。其中,Mean 为均值,Std 为标准差。Mean 表示这些算法的求解精度,Std 反应这些算法在求解过程中的稳定性。从图 11 和表 2 可以看出,所提出的 ITSO 算法在求解精度和求解速度上均优于 TSO 算法。

表 1　基准测试函数

基准函数	范围
$F_1(x)=\sum_{i=1}^{D}x_i^2$	$[-100,100]$
$F_2(x)=\sum_{i=1}^{D}\lvert x_i\rvert+\prod_{i=1}^{D}\lvert x_i\rvert$	$[-10,10]$
$F_3(x)=\sum_{j=1}^{D}\left(\sum_{i=1}^{j}x_i\right)^2$	$[-100,100]$
$F_4(x)=\max_i\{\lvert x_i\rvert,1\leqslant i\leqslant D\}$	$[-100,100]$

表 2 两种算法性能对比

函数	性能	TSO	ITSO
F_1	Mean	4.12×10^{-227}	0
	Std	0	0
F_2	Mean	4.18×10^{-116}	0
	Std	1.72×10^{-115}	0
F_3	Mean	1.04×10^{-214}	0
	Std	0	0
F_4	Mean	1.97×10^{-114}	0
	Std	1.06×10^{-113}	0

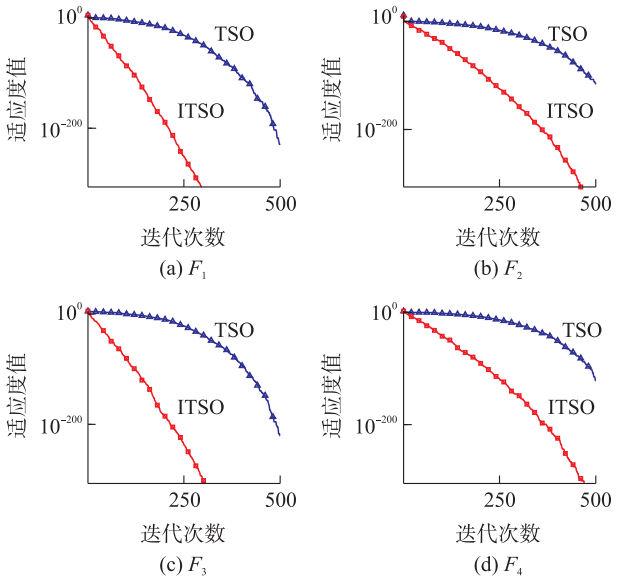

图 11 基准函数收敛曲线图

3.3 参数设置

在网络训练前，设置 ITSO-TCN-BiGRU-SA 的网络基本参数，本文选用 Adam 优化器，激活函数选用 ReLU 函数，采用单头自注意力机制，卷积核大小设为 5，Dropout 系数为 0.1，最大训练次数为 100 次。学习率、扩张系数、过滤器数、BiGRU 隐藏层神经元数量、自注意力机制的键值、正则化参数采用 ITSO 算法进行优化，初始鱼群规模设置为 10，最大迭代次数设置为 50。ITSO 算法在温度模型和湿度模型上搜寻到的最优参数如表 3 和表 4 所示。

表 3 温度模型最优参数

模型参数	参数范围	最优参数
学习率	[0.000 1,0.01]	0.003
过滤器数	[1,128]	3
扩张系数	[1,2,4,8,16]	[1,2,4]
BiGRU 隐藏层神经元个数	[1,200]	79
键值	[2,100]	4
正则化参数	[0.000 01,0.001]	0.000 03

表 4 湿度模型最优参数

模型参数	参数范围	最优参数
学习率	[0.000 1,0.01]	0.003 6
过滤器数	[1,128]	5
扩张系数	[1,2,4,8,16]	[1,2,4]
BiGRU 隐藏层神经元个数	[1,200]	84
键值	[2,100]	38
正则化参数	[0.000 01,0.001]	0.000 18

3.4 实验对比分析

为了验证本文提出模型的有效性，使用 TCN、TCN-BiGRU、TCN-BiGRU-SA、TSO-TCN-BiGRU-SA 模型以及本文提出的 ITSO-TCN-BiGRU-SA 模型在分别在温度数据集和湿度数据集中进行训练和验证。将均方根误差(RMSE)、均方误差(MSE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和判定系数(R^2)作为评价指标。

图 12 和图 13 所示分别为不同模型在温度和湿度上的预测曲线。

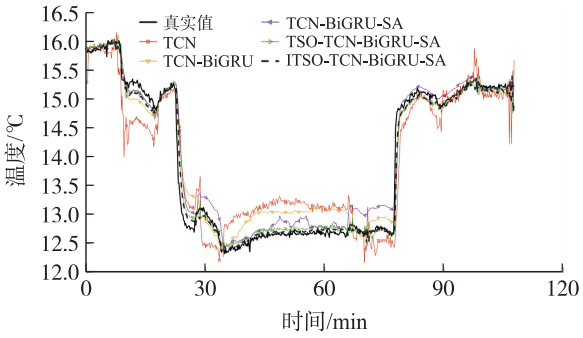

图 12 温度模型预测曲线对比

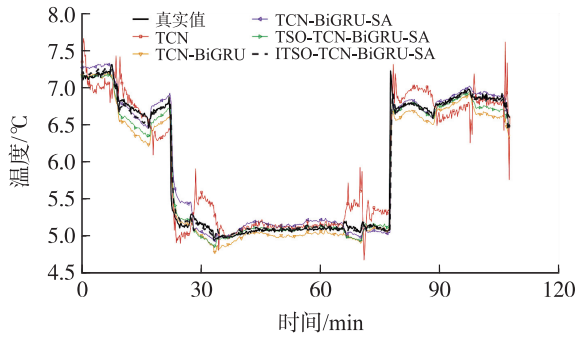

图 13 湿度模型预测曲线对比

图 14 和图 15 所示分别比较了 TSO-TCN-BiGRU-SA、ITSO-TCN-BiGRU-SA 在温度模型和湿度模型上的适应度值变化曲线。

表 5 和表 6 中使用评价指标 RMSE、MSE、MAE、MAPE 和 R^2 来评估各模型在温度和湿度数据集上的优缺点。

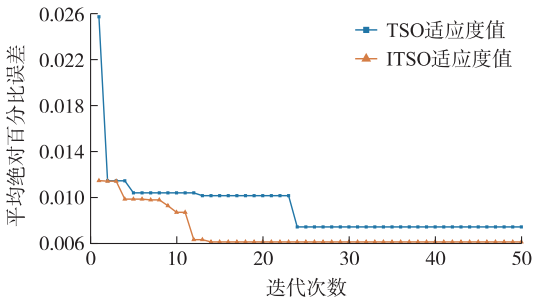

图 14　温度模型适应度变化曲线

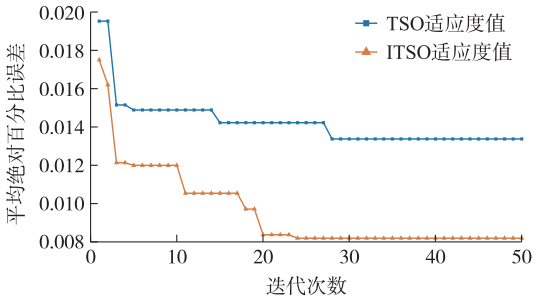

图 15　湿度模型适应度变化曲线

表 5　温度模型结果对比

模型	RMSE	MSE	MAE	MAPE	R2
TCN	0.436 3	0.190 4	0.351 9	2.600%	88.703%
TCN-BiGRU	0.288 8	0.083 4	0.214 5	1.617%	95.050%
TCN-BiGRU-SA	0.234 7	0.055 1	0.164 8	1.235%	96.729%
TSO-TCN-BiGRU-SA	0.167 6	0.028 1	0.103 0	0.748%	98.335%
ITSO-TCN-BiGRU-SA	0.140 4	0.019 7	0.086 5	0.617%	98.830%

表 6　湿度模型结果对比

模型	RMSE	MSE	MAE	MAPE	R2
TCN	0.224 3	0.050 3	0.166 4	2.790%	93.530%
TCN-BiGRU	0.174 4	0.030 4	0.125 7	2.058%	96.089%
TCN-BiGRU-SA	0.153 6	0.023 6	0.092 0	1.606%	96.959%
TSO-TCN-BiGRU-SA	0.136 3	0.018 6	0.080 5	1.336%	97.610%
ITSO-TCN-BiGRU-SA	0.114 7	0.013 1	0.048 6	0.818%	98.308%

在 TCN 后加入 BiGRU 模块,由 TCN 负责捕获局部特征,BiGRU 负责通过双向前后关系增强模型,从而能够在更全面的层面上更深入地理解序列数据,进而提升预测效果,TCN-BiGRU 温湿度模型在预测精度上均优于单一的 TCN。在 TCN-BiGRU 模型中加入自注意力机制模块后,TCN-BiGRU-SA 温湿度模型的预测精度均优于 TCN-BiGRU。加入了优化算法后,TSO-TCN-BiGRU-SA 温度模型的 MAPE 相比 TCN-BiGRU-SA 减小了 0.487%,R^2 提升了 1.606%,ITSO-TCN-BiGRU-SA 的 MAPE 相比 TSO-TCN-BiGRU-SA 减小了 0.131%,R^2 提升了 0.495%。TSO-TCN-BiGRU-SA 湿度模型的 MAPE 相比 TCN-BiGRU-SA 减小了 0.27%,R^2 提升了 0.651%,ITSO-TCN-BiGRU-SA 的 MAPE 相比 TSO-TCN-BiGRU-SA 减小了 0.518%,R^2 提升了 0.698%。

同时,从图 14 和图 15 中可以看出 ITSO 算法收敛速度明显快于 TSO 算法,并且 ITSO 算法取得了比 TSO 算法更小的适应度值,验证了基于 Levy 算子和非线性自适应权重的 ITSO 算法的有效性。

本文所提出的 ITSO-TCN-BiGRU-SA 温度模型的 MAPE 相较于 TCN、TCN-BiGRU、TCN-BiGRU-SA 和 TSO-TCN-BiGRU-SA 模型分别降低了 1.983%、1.000%、0.618%、0.131%,R^2 相较于对比模型分别提升了 10.127%、3.78%、2.101%、0.495%;ITSO-TCN-BiGRU-SA 湿度模型的 MAPE 相较于 TCN、TCN-BiGRU、TCN-BiGRU-SA 和 TSO-TCN-BiGRU-SA 模型分别降低了 1.972%、1.240%、0.788%、0.518%,R^2 相较于对比模型分别提升了 4.778%、2.219%、1.349%、0.698%。综上可知,本文提出的混合模型相较于其他对比模型具有更高的预测精度,证明了该模型的有效性。

4　结论

为了建立精准的溶液除湿空调模型传热传质模型,本文提出了一种基于 ITSO 与 TCN-BiGRU-SA 融合的系统出口空气温湿度预测模型。首先,将 TCN-BiGRU-SA 作为预测模型的主体,其中 TCN 层、BiGRU 层和 SA 层的有效结合可以选择性地从不同时间步长中提取关键特征,捕获序列中的长期依赖性和重要信息,从而提高模型在序列建模和预测任务中的性能。接着,采用 Levy 算子和非线性自适应权重对 TSO 算法做出改进,并将得到的 ITSO 算法在四个基准测试函数上进行测试,结果表明其收敛速度和精度均优于 TSO 算法。再将 ITSO 算法引入 TCN-BiGRU-SA 模型,为网络寻找最优超参数。最后,在溶液除湿空调实验平台中将 ITSO-TCN-BiGRU-SA 与 TCN、TCN-BiGRU、TCN-BiGRU-SA、TSO-TCN-BiGRU-SA 模型进行对比,结果表明 ITSO-TCN-BiGRU-SA 预测模型具有较强的适用性和较高的精度。

参考文献:

[1] Ohene E, Chan A P C, Darko A. Review of Global Research Advances Towards Net-Zero Emissions Buildings [J]. Energy and Buildings, 2022, 266: 112142.

[2] Sangi R, Müller D. A Novel Hybrid Agent-Based Model Predictive Control for Advanced Building Energy Systems [J]. Energy Conversion and Management, 2018, 178: 415-427.

[3] Yin Y, Qian J, Zhang X. Recent Advancements in Liquid

Desiccant Dehumidification Technology[J]. Renewable and Sustainable Energy Reviews,2014,31:38-52.
[4] Chen X,Riffat S,Bai H,et al. Recent Progress in Liquid Desiccant Dehumidification and Air-Conditioning: A Review[J]. Energy and Built Environment,2020,1(1):106-130.
[5] Oleolo I,Abdullah H,Mustapha I,et al. Long Short-Term Memory Neural Network Model for the Control of Temperature in a Multi-Circuit Air Conditioning System[J]. CFD Letters,2022,14(12):84-98.
[6] He Z, Jiang T, Jiang Y, et al. Gated Recurrent Unit Models Outperform Other Machine Learning Models in Prediction of Minimum Temperature in Greenhouse Based on Local Weather Data[J]. Computers and Electronics in Agriculture,2022,202:107416.
[7] Li X,Han Z,Zhao T,et al. Modeling for Indoor Temperature Prediction Based on Time-Delay and Elman Neural Network in Air Conditioning System[J]. Journal of Building Engineering,2021,33:101854.
[8] Elmaz F,Eyckerman R,Casteels W,et al. CNN-LSTM Architecture for Predictive Indoor Temperature Modeling[J]. Building and Environment,2021,206:108327.
[9] Guo Z,Moayedi H,Foong L K,et al. Optimal Modification of Heating,Ventilation,and Air Conditioning System Performances in Residential Buildings Using the Integration of Metaheuristic Optimization and Neural Computing[J]. Energy and Buildings,2020,214:109866.
[10] Wan R,Mei S,Wang J,et al. Multivariate Temporal Convolutional Network:A Deep Neural Networks Approach for Multivariate Time Series Forecasting[J]. Electronics,2019,8(8):876.
[11] 张擎,杨晓婧,金鑫宁,等. 基于电子鼻和电子舌与 1D-CNN-LSTM 模型的花椒产地快速溯源检测[J]. 传感技术学报,2024,37(5):904-912.
[12] 熊嘉豪,姜晨希,陈永毅,等. 基于 TCN-SE 神经网络模型的智能连续血压估计方法[J]. 传感技术学报,2022,35(11):1499-1505.
[13] 王彬,晏学成,张海利,等. 基于 GRU 神经网络的恒温晶振频率漂移预测[J]. 电子器件,2024,47(2):502-508.
[14] 王鹏,方凯,汪晨,等. 基于多模态数据融合的室温预测算法研究[J]. 传感技术学报,2023,36(7):1048-1054.
[15] Niu Z,Zhong G,Yu H. A Review on the Attention Mechanism of Deep Learning[J]. Neurocomputing,2021,452:48-62.
[16] Xie L,Han T,Zhou H,et al. Tuna Swarm Optimization:A Novel Swarm-Based Metaheuristic Algorithm for Global Optimization[J]. Computational Intelligence and Neuroscience,2021,2021(1):9210050.
[17] Zhang J,Wang J S. Improved Whale Optimization Algorithm Based on Nonlinear Adaptive Weight and Golden Sine Operator[J]. IEEE Access,2020,8:77013-77048.
[18] Gong R,Li J,Wang C. Remaining Useful Life Prediction Based on Multisensor Fusion and Attention TCN-BiGRU Model[J]. IEEE Sensors Journal, 2022, 22(21):21101-21110.
[19] Zhan X,Kou L,Xue M,et al. Reliable Long-Term Energy Load Trend Prediction Model for Smart Grid Using Hierarchical Decomposition Self-Attention Network[J]. IEEE Transactions on Reliability,2022,72(2):609-621.
[20] Ou X,Cai W,He X,et al. Dynamic Modeling and Validation of a Liquid Desiccant Cooling and Dehumidification System[J]. Energy and Buildings,2018,163:44-57.
[21] Ou X,Cai W,He X,et al. Dynamic Model Development of Heat and Mass Transfer for a Novel Desiccant Regeneration System in Liquid Desiccant Dehumidification System[J]. Applied Thermal Engineering,2018,145:375-385.
[22] Ou X,Cai W,He X,et al. Experimental Investigations on Heat and Mass Transfer Performances of a Liquid Desiccant Cooling and Dehumidification System[J]. Applied Energy,2018,220:164-175.

王浙宇(2000—),男,硕士研究生,研究方向为深度学习,室内空气温湿度控制,zy1332171855@163.com;

欧县华(1990—),男,博士,浙江工业大学讲师,研究方向为数据驱动控制、移动机器人、室内空气温湿度控制,xhou@zjut.edu.cn;

王心恺(1999—),男,硕士研究生,研究方向为室内空气温湿度控制,18868447091@163.com;

何熊熊(1965—),男,博士,浙江工业大学教授,研究方向为数据驱动、迭代学习控制、信号处理,hxx@zjut.edu.cn。