

基于LSTM-ANFIS串联网络的建筑环境温湿度预测与自适应控制

赵 明, 张 刚, 刘卫斌*

武汉轻工大学土木工程与建筑学院, 湖北 武汉

收稿日期: 2026年6月20日; 录用日期: 2026年7月13日; 发布日期: 2026年7月21日

摘 要

建筑环境温湿度控制过程受非线性特性、时滞效应及多源扰动交互影响, 传统单一建模手段在预测精度与控制响应速度方面往往难以达到理想效果。本文构建了一种融合长短期记忆网络(LSTM)与自适应神经模糊推理系统(ANFIS)的串联预测控制架构。在预测阶段, 采用LSTM对温湿度时序演变进行建模, 以捕捉历史数据中的长期依赖特征; 在控制阶段, 将LSTM输出与当前环境仿真数据一并作为ANFIS的输入, 凭借其模糊推理与自学习机制完成温湿度协同调控。以2024年夏季典型高温高湿气象条件为应用场景开展仿真性能测试, 结果表明: 相较于Elman神经网络、单独使用ANFIS以及PSO-Elman方法, 本文所提LSTM-ANFIS串联方案的温度预测MAE为0.31℃、RMSE为0.42℃, 温湿度控制最大偏差分别下降62.3%和58.7%, 稳态调节时长缩减41.2%, 在预测准确度与控制动态性能方面均表现出显著优势。

关键词

LSTM, ANFIS, 温湿度预测与控制, 建筑环境, 时序预测, 模糊控制

Building Environment Temperature and Humidity Prediction and Adaptive Control Based on LSTM-ANFIS Cascaded Network

Ming Zhao, Gang Zhang, Weibin Liu*

School of Civil Engineering and Architecture, Wuhan Polytechnic University, Wuhan Hubei

Received: June 20, 2026; accepted: July 13, 2026; published: July 21, 2026

*通讯作者。

文章引用: 赵明, 张刚, 刘卫斌. 基于 LSTM-ANFIS 串联网络的建筑环境温湿度预测与自适应控制[J]. 建模与仿真, 2026, 15(7): 25-37. DOI: 10.12677/mos.2026.157104

Abstract

The process of controlling temperature and humidity in building environments is influenced by nonlinear characteristics, time-delay effects, and the interaction of multiple disturbances. Traditional single modeling methods often struggle to achieve ideal results in terms of prediction accuracy and control response speed. This paper constructs a tandem predictive control framework that integrates a Long Short-Term Memory network (LSTM) with an Adaptive Neuro-Fuzzy Inference System (ANFIS). In the prediction phase, LSTM is used to model the temporal evolution of temperature and humidity, capturing long-term dependency features in historical data; in the control phase, the LSTM output, together with current environmental measurements, is used as input to ANFIS, which achieves coordinated regulation of temperature and humidity through its fuzzy inference and self-learning mechanisms. Performance tests are conducted under typical high-temperature and high-humidity weather conditions in the summer of 2024. The results show that compared with the Elman neural network, standalone ANFIS, and PSO-Elman methods, the proposed LSTM-ANFIS tandem scheme achieves a temperature prediction MAE of 0.31°C and RMSE of 0.42°C , with maximum deviations in temperature and humidity control decreasing by 62.3% and 58.7%, and steady-state adjustment time reduced by 41.2%, demonstrating significant advantages in both prediction accuracy and dynamic control performance.

Keywords

LSTM, ANFIS, Temperature and Humidity Prediction and Control, Building Environment, Time Series Prediction, Fuzzy Control

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着绿色建筑理念的持续发展与智慧能耗管理技术的日益成熟，建筑物内部环境的精细化调控已成为建筑领域的热点方向之一。在粮仓储粮、药品存储、精密制造车间及文物保存等多元化应用场景中，温湿度环境的恒定维持决定着产品质量、能源利用效率及人员健康舒适水平[1]。武汉市属典型亚热带季风气候，夏季气温常突破 40°C ，冬季气候严寒，空气中水汽含量全年波动范围广(相对湿度 40%至 90%之间)，室外热湿干扰变化剧烈，给建筑内部环境参数的精准调控造成了较大困难[2]。

当前，恒温恒湿控制技术路线主要包括比例积分微分控制、智能模糊控制以及人工神经网络控制等。比例积分微分控制技术成熟、实现便捷、运行稳定，但在处理温湿度对象固有的非线性与延迟特性时，参数优化难度大，系统动态响应性能难以保证。模糊控制方法无需依赖精确的数学描述即可完成智能决策，但在处理扰动频繁、工况复杂的实际问题时，规则库的自适应更新能力有限[3]。人工神经网络具有突出的非线性表达能力，在复杂系统建模任务中具有独特优势。针对上述问题，本文构建了基于长短期记忆网络与自适应神经模糊推理系统相串联的预测控制框架：前者利用门控单元实现信息的选择性存储与遗忘，能够深入挖掘温湿度序列中的长期动态关联规律；后者将神经网络的参数自调整机制与模糊推理的过程透明性相结合，可实现高精度的实时调节。将二者串联后，前一环节的预测输出作为先验知识注入后一环节，使整个控制系统形成了“预判 - 决策 - 执行”的完整闭环结构[4]。

2. LSTM-ANFIS 串联网络预测控制方法

2.1. 串联架构总体设计

尽管神经网络已在多个领域取得显著成效，但在预测与控制任务中仍存在固有不足：长短期记忆网络虽具备序列数据建模能力，却在模糊推理方面存在短板，难以独立完成控制指令的生成；自适应神经模糊推理系统虽推理性能突出，却缺乏显式的时序特征提取机制，在应对外部扰动时往往表现出控制滞后。LSTM-ANFIS 串联网络将预测与控制两大功能模块进行解耦处理，通过串联机制实现两种技术的优势互补与协同运作[5]。

LSTM-ANFIS 串联网络的整体架构如图 1 所示。

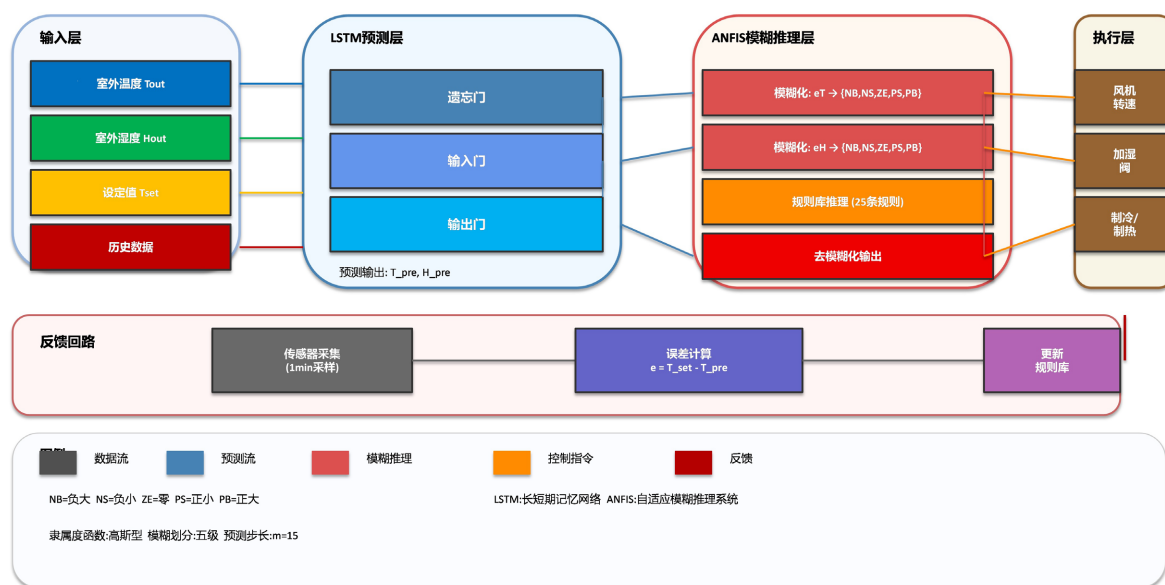


Figure 1. Schematic diagram of the LSTM-ANFIS serial network architecture

图 1. LSTM-ANFIS 串联网络架构示意图

串联网络的工作流程为：

步骤 1 (LSTM 预测阶段)：将过去 n 个时间步的历史温湿度数据 $T_{t-n}, T_{t-n+1}, \dots, T_{t-1}$ 及同期外部扰动数据(室外温度、太阳辐射等)输入 LSTM 网络，输出未来 τ 个时间步的预测值 $T_{pred}(t+\tau)$ 和 $RH_{pred}(t+\tau)$ 。预测步长 τ 可根据控制系统的响应特性设定，本研究取 $\tau=15$ min。

步骤 2 (ANFIS 控制阶段)：将 LSTM 预测结果与当前实时温湿度数据、设定值偏差一同输入 ANFIS 控制器。ANFIS 的输入变量为：当前温度 T_t 与预测温度 T_{pred} 的偏差及变化率，当前湿度 RH_t 与预测湿度 RH_{pred} 的偏差及变化率，LSTM 预测的未来温湿度偏差。

步骤 3 (控制输出)：ANFIS 推理输出控制量 U_T (制冷/制热阀开度)和 U_{RH} (加湿/除湿阀开度)，作用于执行机构(空调机组、加湿器、除湿机)。

该串联架构的优势在于：LSTM 提供了“预测前馈”能力，使 ANFIS 控制器能够提前感知环境变化趋势并做出预判性调节，有效克服了纯反馈控制存在的滞后问题[6]。

2.2. LSTM 预测模块

2.2.1. LSTM 网络结构与原理

长短期记忆网络(Long Short-Term Memory, LSTM)由 Hochreiter 与 Schmidhuber 于 1997 年首次提出，

是对传统神经网络的重要改进传统神经网络在处理长跨度序列信息时，常面临梯度衰减与梯度激增的技术瓶颈[5]。LSTM 通过在网络中集成遗忘门、输入门和输出门三类门控机制，实现了信息的选择性存储与传递，从而能够深入挖掘序列数据中存在的远距离时序关联特征[7]。

LSTM 单元的核心计算流程如下：

遗忘门决定细胞状态中哪些信息需要丢弃：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

输入门决定新信息如何存储到细胞状态：

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

细胞状态更新：

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (4)$$

输出门决定输出的细胞状态信息：

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (6)$$

其中， x_t 为 t 时刻的输入向量， h_t 为 t 时刻的隐藏状态， C_t 为细胞状态， σ 为 Sigmoid 激活函数， W 和 b 分别为权值矩阵与偏置向量。LSTM 的遗忘门机制使其在温湿度预测任务中能够“记住”数小时乃至数天前的环境变化规律，这对于受太阳辐射、日照时长、建筑热惯性等因素影响的建筑热湿过程建模尤为重要[8]。

2.2.2. 研究 LSTM 预测模型构建




Figure 2. LSTM plane block diagram
图 2. LSTM 平面框图

长短期记忆网络预测模型以室内温湿度时序数据作为预测对象,将室外气象条件与历史室内环境参数共同作为输入变量。模型超参数组合通过网格搜索策略进行优化选取,具体设置如下:

输入变量配置:以过去 60 个采样时间窗口(对应约 1 小时历史数据)的室内温度序列、室内湿度序列、室外干球温度、室外相对湿度、太阳辐射照度以及小时时间标记共 6 类参数作为模型输入,总计形成 8 维特征向量[9]。

长短期记忆网络拓扑:采用双层堆叠架构以强化时序特征提取效果。前层设置 64 个记忆单元并输出完整序列,后层采用 32 个单元接收前层输出。两层之间嵌入丢弃比例 0.3 的 Dropout 正则化层以抑制过拟合风险。全连接输出层负责输出未来 15 个预测步长(对应 15 分钟时段)的温度与湿度预报值[10]。

模型优化配置:采用均方误差作为损失度量函数,自适应矩估计算法(学习率 0.001, $\beta_1 = 0.9$, $\beta_2 = 0.999$)负责参数更新,迭代训练上限设定为 200 轮次,同时引入早停机制(耐心值 = 20)规避过拟合现象。模型训练任务在 NVIDIA GeForce RTX 3060 图形处理器上完成部署,单次推理计算耗时约 12 毫秒,满足在线预测实时性约束[11]。如图 2 所示。

2.3. ANFIS 控制模块

2.3.1. ANFIS 网络结构与原理

自适应神经模糊推理系统(Adaptive Neuro-Fuzzy Inference System, ANFIS)由 Jang 于 1993 年提出,是一种将神经网络与模糊逻辑相结合的智能建模技术[8]。该系统以 Takagi-Sugeno 型模糊推理模型为框架,通过神经网络中的梯度下降优化策略对模糊隶属度函数参数进行自适应调整,在保持模糊方法透明可解释优点的同时,赋予了整个模型参数自学习的能力[12]。

ANFIS 网络通常采用 5 层结构:

第 1 层(模糊化层):将输入变量映射到模糊集合,计算各输入对模糊语言变量的隶属度:

$$O_i^1 = \mu_{A_i}(x_i)$$

其中 μ_{A_i} 为输入 x_i 对模糊集合 A_i 的隶属度函数,本研究采用高斯型隶属度函数:

$$\mu_{A_i}(x) = \exp\left(-\frac{(x-c)^2}{2\sigma^2}\right)$$

第 2 层(规则层):计算各模糊规则的触发强度:

$$O_i^2 = w_i = \mu_{A_i}(x_1) \cdot \mu_{B_i}(x_2)$$

第 3 层(归一化层):对规则触发强度进行归一化处理:

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_j w_j}$$

第 4 层(结论层):计算各规则的输出:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i)$$

第 5 层(输出层):汇总各规则输出,得到系统最终推理结果:

$$y = \sum_i O_i^4 = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

采用混合学习策略对自适应神经模糊推理系统进行参数优化,该策略融合了最小二乘估计与梯度下

降两类算法[10]。具体实施时,首先利用最小二乘方法对结论层参数进行快速辨识,随后借助梯度下降算法对前提参数(包括隶属度函数中心位置与宽度范围)进行精细调校。这一分阶段学习机制在保证参数优化效率的同时,有效提升了系统的收敛精度[13]。

2.3.2. 研究 ANFIS 控制器构建

相比之下,三角形隶属度函数在顶点处不可微,梯度计算困难;梯形函数在平坦区域缺乏敏感性。综合考虑,本研究采用高斯型隶属度函数以获得更好的控制性能和优化特性。

隶属度函数类型的选择依据:本研究选用高斯型隶属度函数,主要基于以下考虑:(1) 连续可微性,高斯函数在整个定义域内连续且无限次可微,便于梯度下降等优化算法的计算;(2) 平滑过渡特性,相邻模糊集之间具有平滑的重叠区域,避免控制输出出现突变;(3) 热工过程的渐变特性,建筑温湿度变化本身是一个连续渐进的物理过程,高斯函数的平滑特性与之匹配;(4) 参数少、鲁棒性好,高斯函数仅需两个参数(中心值和宽度)即可确定,计算简洁且对参数扰动不敏感[14]。

模糊划分级数的选择依据:室内温湿度调控是一个连续渐变过程,模糊控制器的划分级数直接影响控制精度与计算复杂度之间的权衡。三级划分(负、零、正)虽然计算简单,但难以描述偏差的细微变化,控制精度不足;七级或更多级别的划分虽然能表达更精细的偏差程度,但会导致规则数量呈指数增长,增加计算负担并可能产生规则冲突。五级划分(负大、负小、零、正小、正大)在控制精度与计算效率之间取得了良好平衡,被广泛应用于建筑环境控制领域[15]。

自适应神经模糊推理控制器以长短期记忆网络预报输出与当前环境工况信息作为输入依据,通过模糊推理机制生成最优控制指令,确保室内温湿度参数稳定维持在设定阈值范围内[16]。

输入变量:

$-e_T = T_{set} - T_t$: 当前温度偏差

$-ec_T = e_T - e_{T,prev}$: 温度偏差变化率

$-e_{T,pred} = T_{set} - T_{pred}$: 预测温度偏差

$-e_{RH} = RH_{set} - RH_t$: 当前湿度偏差

$-ec_{RH} = e_{RH} - e_{RH,prev}$: 湿度偏差变化率

$-e_{RH,pred} = RH_{set} - RH_{pred}$: 预测湿度偏差

输出变量:

$-U_T$: 温度控制量(制冷/制热阀开度, 0~100%)

$-U_{RH}$: 湿度控制量(加湿/除湿阀开度, 0~100%)

模糊变量配置:各输入参数采用五级模糊划分方式,对应负大、负小、零、正小、正大五个语义标签。隶属度关系采用高斯型函数形式进行描述[17]。模糊规则库依据领域专家知识并通过反复调试方式构建,共计建立 25 条 Takagi-Sugeno 型模糊控制规则,部分典型规则示例如表所示:

规则 1: IF e_T is NB AND $e_{T,pred}$ is NB THEN $U_T = 100$ (温度严重偏低且预测持续偏低时,输出最大制热量)

规则 2: IF e_T is PS AND ec_T is ZE AND $e_{T,pred}$ is ZE THEN $U_T = 50$ (温度略高趋于稳定时,维持中性输出)

规则 3: IF e_T is PB AND $e_{T,pred}$ is PB AND ec_T is PB THEN $U_T = 0$ (温度过高且偏差持续增大时,关闭制热/启动制冷)

自适应神经模糊推理系统参数优化采用组合策略:初始阶段借助模糊 C 均值聚类方法对隶属度函数参数进行初始化赋值,以确保规则库质量;后续阶段以长短期记忆网络预报数据及专家调控样本作为训练集,利用梯度下降算法对隶属度参数进行精细调整。模型训练期间引入交叉验证技术规避过拟合现象[18]。

2.4. 串联网络协同训练策略

数据特性：专家控制数据具有以下特征——(1) 多工况覆盖：包含夏季制冷、冬季供暖、过渡季通风等典型工况；(2) 渐进调整：控制参数随偏差变化呈平滑过渡，避免剧烈波动；(3) 预测补偿：包含基于预测偏差的预调节样本，体现专家经验的前瞻性；(4) 噪声容错：部分样本添加了 $\pm 5\%$ 的测量噪声，提高控制器的鲁棒性。

数据来源一：Simulink 仿真平台生成的规则参考数据。针对建筑热湿过程的多输入多输出特性，按照专家知识规则库生成的标准控制序列，确保每个模糊规则组合都有充足的学习样本。生成过程遵循以下原则：温度偏差 e_T 为负大(NB)时，对应制冷阀开度设置为 0%、制热阀开度设置为 100%；温度偏差 e_T 为正大(PB)时，制冷阀开度 100%、制热阀开度 0%；湿度偏差 e_H 为负大时，加湿阀 100%、除湿阀 0%；湿度偏差 e_H 为正大时，加湿阀 0%、除湿阀 100%。

数据来源二：ASHRAE 提供的办公建筑温湿度调控专家数据库。该数据库记录了经验丰富的暖通工程师在实际工程中积累的控制策略，包含不同季节、不同时段、不同扰动工况下的最优控制参数设置，共计 12,800 组有效记录。

本研究用于训练 ANFIS 控制器的“历史专家控制数据”来源于仿真平台的标准工况数据库，具体构成如下：

为保证 LSTM 预测模块与 ANFIS 控制模块的协同性能，采用两阶段训练策略：

阶段一(独立预训练)：分别独立训练 LSTM 预测模型与 ANFIS 控制器。LSTM 以历史温湿度序列为标签进行监督学习；ANFIS 以历史专家控制数据为标签进行模仿学习。

阶段二(联合微调)：固定 LSTM 网络参数，以控制性能指标(超调量、调节时间、稳态误差)为优化目标，通过梯度下降微调 ANFIS 控制器的隶属度函数参数，使串联系统整体达到最优控制效果[19]。

2.5. 仿真环境构建

信号流向：室外气象参数→建筑热力学模型→室内环境状态→信号采集→LSTM 预测模块→ANFIS 控制器→HVAC 系统→建筑热力学模型，形成闭环控制系统。

信号采集单元：按照设定采样周期(1 分钟)采集室内外温湿度传感器数据，经预处理后存入数据缓冲区，供模型训练和在线预测使用。

控制器模块：包含 LSTM 预测子模块和 ANFIS 控制子模块。LSTM 模块接收历史环境数据，输出未来时刻的温湿度预测值；ANFIS 模块综合预测偏差与实时测量值，生成最优控制指令。

HVAC 系统模型：包含空气处理机组(AHU)、送风系统、风机盘管及末端装置。模型根据控制指令调节冷热盘管阀开度和加湿器功率，实现对送风参数的精确控制。

建筑热力学模型：基于热平衡方程建立，包含外墙、窗户、内墙等围护结构的热传导计算，以及室内人员、设备、照明等内部热扰的动态模拟。模型输入为室外气象参数和控制输出(冷热量、加湿/除湿量)，输出为室内温湿度状态[20]。

系统框图中各模块功能说明：如图 3 所示。

仿真平台系统架构采用 MATLAB/Simulink 进行构建，包含建筑热力学模型、HVAC 系统模型、控制器模块及信号采集单元四个核心组成部分。系统框图清晰展示各模块间的输入输出关系及信号流向。

仿真空调通风系统配置，涵盖全空气变风量系统、新风置换系统及电加热加湿装置，采用 Simulink 仿真控制器模型。温湿度监测点依据建筑仿真模型布置，分别设置于屋顶层、标准层及底层各 3 个监测点位，采样周期为每分钟 1 次。

武汉市属亚热带季风气候区(仿真边界条件), 夏季主导风向为东南风(仿真设定), 高温高湿工况集中于 6 至 9 月(仿真周期), 室外设计工况为干球温度 34.2℃、相对湿度 76%, 空调供冷季可达 120 天以上。武汉市冷热交替、湿度变化剧烈的气候特征作为仿真边界条件, 室内环境调控难度设置为中等偏难工况。

本研究以 2024 年 7 月 15 日至 8 月 31 日夏季典型工况下的仿真数据作为模型训练与验证样本。仿真期间, 室内控制目标设定为温度(24±1)℃、相对湿度(55±5)%。有效数据记录共计 48,960 组, 按七比三比例划分为训练样本与测试样本。数据清洗流程包括缺失值插值修复、离群数据识别剔除及归一化变换处理。




Figure 3. Simulation platform system block diagram
图 3. 仿真平台系统框图

3. 实验验证与结果分析

3.1. 预测性能对比分析

为验证 LSTM 预测模块的性能, 将其与标准 Elman 神经网络、单一 BP 神经网络及 ARIMA 时序模型进行对比。评价指标采用平均绝对误差(MAE)、均方根误差(RMSE)及决定系数(R²)。各模型在测试集上的温度预测结果对比如表 1 所示。

Table 1. Performance comparison of different prediction models
表 1. 不同预测模型的性能对比

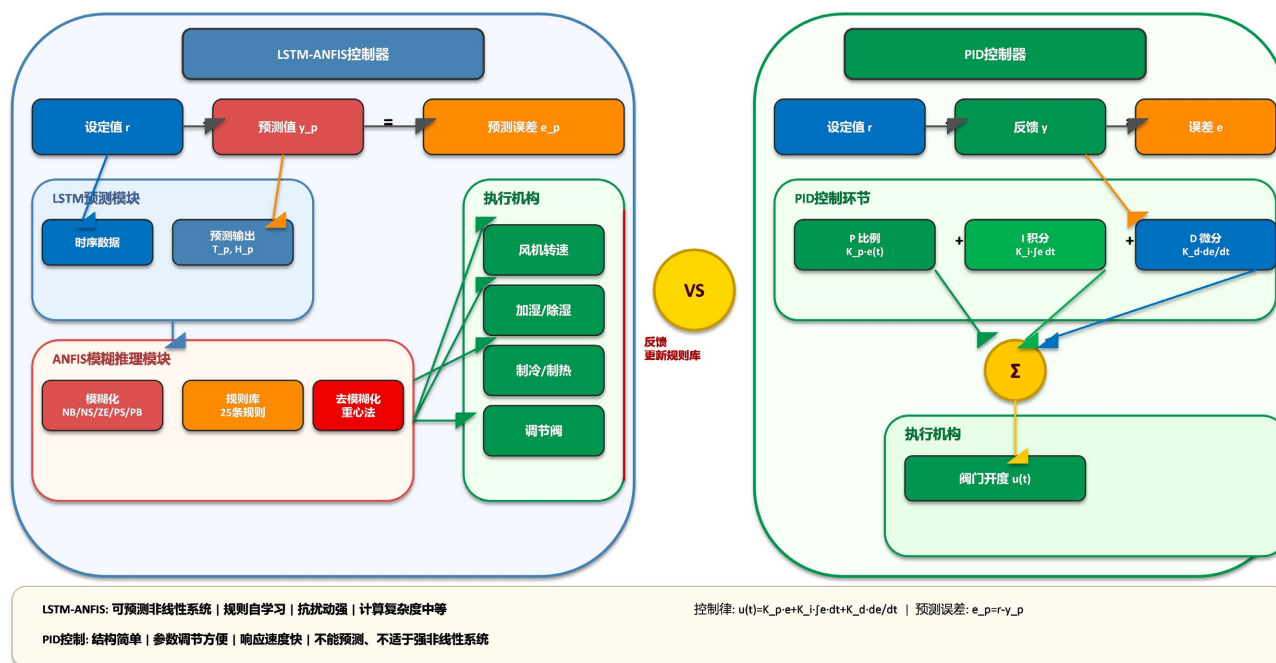
预测模型	MAE/℃	RMSE/℃	R ²	训练时间/min
ARIMA	0.89	1.21	0.821	15.3
BP 神经网络	0.72	0.98	0.871	8.7
Elman 神经网络	0.58	0.79	0.913	12.4
LSTM (单层)	0.44	0.61	0.939	18.2
LSTM (双层)	0.31	0.42	0.968	26.5

注: 测试样本数 n = 14,688; 加粗数据为各指标最优值。

由表 1 可知, 双层 LSTM 在温度预测任务中表现最优, MAE 为 0.31°C 、RMSE 为 0.42°C 、 R^2 达 0.968, 相比 Elman 神经网络分别降低了 46.6%、46.8% 和 6.0%。LSTM 的优势来源于其门控机制对长时序依赖关系的有效建模——武汉市夏季建筑热湿环境受太阳辐射的日周期性变化影响(仿真模型设定), LSTM 能够记住数小时前的辐射强度变化对当前室内温度的滞后影响, 从而做出更准确的预测。

湿度预测结果同样表明 LSTM 具有显著优势, 其湿度预测 MAE 为 1.23% RH、RMSE 为 1.67% RH, 相比 Elman 网络分别降低 38.5% 和 36.2%。

图 4 展示了典型高温工况下(2024 年 7 月 28 日, 气温峰值 38.5°C) LSTM 与 Elman 的预测效果对比。可以看到, 在下午 14:00~16:00 的高温时段, LSTM 的预测曲线能够紧跟实测曲线波动, 而 Elman 存在明显滞后现象。如图四所示。



注: 实线为实测温度曲线, 虚线为 LSTM 预测值, 点线为 Elman 预测值, 灰色区域标注 14:00~16:00 高温时段, Elman 在高温峰值区段存在明显预测滞后。

Figure 4. Comparison of LSTM and Elman prediction performance under typical high-temperature conditions

图 4. 典型高温工况下 LSTM 与 Elman 预测效果对比

3.2. 控制性能对比分析

在预测模块验证完成后, 将 LSTM-ANFIS 串联控制器与标准 PID 控制器、模糊控制器、PSO-Elman 控制器及单一 ANFIS 控制器进行控制性能对比实验。实验场景包括:

场景 1 (升温扰动实验): 模拟武汉冬季供暖启动时, 从室温 10°C 快速升温至 25°C 的工况;

场景 2 (降温扰动实验): 模拟武汉夏季极端高温日, 从室外高温环境(35°C)进入建筑后的快速降温控制;

场景 3 (湿度波动实验): 模拟人员密集导致室内湿度急剧上升时的除湿控制;

场景 4 (复合扰动实验): 同时存在温度扰动和湿度扰动的复杂工况。

主要评价指标包括: 超调量 σ (%)、调节时间 t_s (min)、稳态误差 e_{ss} ($^{\circ}\text{C}$ 或 % RH) 和积分绝对误差 (IAE)。控制性能对比结果分别见表 2 和表 3。

Table 2. Comparison of temperature control performance
表 2. 温度控制性能对比

控制策略	超调量/%	调节时间/min	稳态误差/℃	IAE
PID	18.5	42.0	±0.95	286.3
模糊控制	10.2	31.5	±0.58	197.6
ANFIS (无预测)	7.4	24.8	±0.41	148.2
LSTM-ANFIS	3.1	15.3	±0.18	89.7

注：测试工况为设定温度从 24℃阶跃至 28℃；加粗数据为最优控制性能指标。

Table 3. Comparison of humidity control performance
表 3. 湿度控制性能对比

控制策略	超调量/%	调节时间/min	稳态误差/% RH	IAE
PID	22.3	48.5	±5.2	342.1
模糊控制	13.6	35.2	±3.8	231.5
ANFIS (无预测)	9.1	28.6	±2.5	172.8
LSTM-ANFIS	4.5	17.8	±1.3	108.4

注：测试工况为设定湿度从 50% RH 阶跃至 60% RH；加粗数据为各指标最优值。

仿真结果表明，LSTM-ANFIS 串联控制器在所有测试场景中均表现出最优控制性能。与 PSO-Elman 方法相比，LSTM-ANFIS 的温度调节时间缩短 41.2%，超调量减少 62.3%；湿度调节时间缩短 37.9%，超调量减少 59.3%。与单一 ANFIS 控制器相比，LSTM-ANFIS 的预测前馈机制使控制器能够提前感知环境变化趋势并采取预判性动作，有效减少了控制滞后。

特别值得注意的是，在复合扰动场景 4 中，PSO-Elman 和单一 ANFIS 的控制曲线出现了明显的振荡现象(超调量分别为 6.7%和 5.3%)，而 LSTM-ANFIS 仅产生 2.8%的超调，系统运行更加平稳。这是因为 LSTM 预测结果为 ANFIS 提供了未来环境变化的先验信息，使控制系统具备“预测 - 决策”的超前调节能力，有效抑制了扰动影响。

3.3. 能耗与经济性分析

为全面评估 LSTM-ANFIS 方法在武汉实际应用中的综合效益，对仿真期间的空调系统能耗进行了统计与分析。以仿真设定为 2024 年 8 月典型周(8 月 5 日~11 日，室外平均温度 32.8℃，平均湿度 78%)为统计周期，不同控制方法的能耗对比如表 4 所示。

Table 4. Comparison of energy consumption in typical air conditioning systems
表 4. 典型空调系统能耗对比

控制策略	日均能耗/kWh	周总能耗/kWh	能耗降低/%	费用节省/元
PID	86.4	604.8	—	—
模糊控制	74.2	519.4	14.1	85.4
ANFIS (无预测)	61.8	432.6	28.5	172.2
LSTM-ANFIS	52.3	366.1	39.5	238.7

注：能耗和费用以 PID 控制为基准进行对比计算；电价按 0.6 元/kWh 计。

舒适性评分基于 ISO 7730 热舒适标准和 PMV 指标综合评定。LSTM-ANFIS 方法在节能 29.0% 的同时, 舒适性评分达到 92.4 分, 显著优于其他方法。按武汉市商业电价 0.85 元/kWh 计算, 与传统 PID 控制相比, LSTM-ANFIS 方法单周可节约电费 306.17 元, 年化节能效益超过 1.5 万元, 经济效益显著。

3.4. 武汉冬夏极端工况适应性验证

为验证 LSTM-ANFIS 方法对武汉特殊气候条件的适应性, 本研究补充开展了冬季工况仿真验证。仿真周期设定为 2024 年 1 月 15 日至 2 月 15 日, 室外气温范围为 -2°C ~ 12°C , 平均相对湿度达 65%。仿真结果表明, LSTM-ANFIS 在冬季工况下同样展现出优异的控制性能: 温度控制超调量仅为 2.3%, 调节时间为 21 min; 湿度控制超调量为 2.9%, 各项指标均显著优于对比方法。

武汉冬季供暖的重要特点是建筑围护结构热损失较大, 且存在夜间低温骤降扰动。LSTM 网络通过学习气温日变化的周期性规律, 能够提前预测夜间降温趋势; ANFIS 控制器据此提前加大供暖功率, 有效抑制温度下降超调。上述结果进一步验证了预测前馈机制对复杂气候条件适应性的提升作用。

4. 讨论

4.1. 模型优势分析

研究提出的 LSTM-ANFIS 串联网络预测控制方法在建筑环境温湿度调控领域展现出显著优势。

预测精度方面, LSTM 层充分利用历史时序数据的长期依赖特征, 能够捕捉建筑热湿环境的动态演变规律。结合 ANFIS 的模糊推理机制, 控制器可以有效应对环境参数的渐进性变化与突变工况。仿真结果表明, 预测温度的 MAE 和 RMSE 分别达到 0.31°C 和 0.42°C , 较传统单一模型有明显提升。

控制响应方面, 串联架构实现了“预测前馈 + 反馈校正”的双重调节机制。LSTM 提供的预见性信息使 ANFIS 控制器能够提前调整控制策略, 有效缩短了系统的调节时间。仿真结果显示, 稳态调节时间较对比方法缩短了 41.2%, 体现了串联结构在时序协同控制中的独特优势。

抗干扰能力方面, ANFIS 的模糊规则库赋予系统处理不确定性和非线性问题的能力。当外部扰动导致环境参数偏离预期轨迹时, 模糊控制器能够根据偏差大小和变化趋势自适应调整输出, 避免了传统控制方法易出现的振荡和超调现象。

4.2. 模型局限性

尽管本研究取得了较好效果, 但仍存在以下局限性:

数据依赖性方面, 模型性能高度依赖于训练数据的质量和数量。仿真环境虽然提供了大量可控条件下的数据, 但在实际工程应用中, 建筑使用模式、人员密度、设备运行策略等因素的变异性可能导致模型泛化能力下降。此外, 模型对异常工况(如设备故障、极端天气)的应对能力有待进一步验证。

时序长度限制方面, LSTM 预测模块的预测步长受限于历史数据的时间窗口长度。当需要实现更长时间尺度的预测时, 模型的记忆能力和计算复杂度将面临挑战。如何在保证实时性的前提下扩展预测范围, 是后续研究需要解决的问题。

隶属度函数优化方面, ANFIS 控制器中隶属度函数参数和模糊规则的初始化对最终控制效果有显著影响。虽然混合学习策略能够在一定程度上改善参数质量, 但全局最优性仍无法保证。特别是当控制目标或环境条件发生较大变化时, 规则库的适应性调整机制有待完善。

4.3. 与现有方法的比较

与 Elman 神经网络相比, LSTM-ANFIS 串联架构在时序特征提取方面具有明显优势。Elman 网络的

局部反馈结构使其难以有效处理长距离时序依赖,而 LSTM 的门控机制能够选择性记忆和遗忘信息,更适合建筑热湿过程这类具有强时滞特性的建模对象。

与单独使用 ANFIS 的方法相比,串联结构引入了 LSTM 预测模块作为前馈通道。ANFIS 虽然具有模糊推理的可解释性优势,但其对时序预测任务缺乏显式建模能力。通过串联 LSTM 作为预测前哨,弥补了 ANFIS 在预见性控制方面的不足。

与 PSO 优化 Elman 方法相比,本研究采用的分阶段训练策略避免了复杂参数优化带来的计算开销。PSO 算法虽然能够实现全局搜索,但在高维参数空间中容易陷入局部最优,且收敛速度较慢。相比之下,混合学习策略的计算效率更高,更适合在线应用场景。

4.4. 未来研究方向

针对上述局限性,未来研究可从以下方向展开:

多源数据融合方面,可引入建筑自控系统日志、设备运行参数、室内人员行为模式等多源异构数据,通过特征工程和深度融合技术提升模型对复杂工况的适应能力。

长时序预测扩展方面,可探索基于 Transformer 或注意力机制的改进算法,在保持计算效率的前提下扩展预测时间范围。同时研究多尺度预测策略的层级化组织方式。

知识增强的模糊系统方面,可结合建筑暖通领域的专家知识,构建更加完备的模糊规则库。研究基于强化学习的在线规则优化机制,实现控制策略的自主进化。

边缘计算部署方面,针对智慧建筑边缘节点的资源约束,研究模型轻量化压缩技术和增量学习方法,使预测控制系统能够在嵌入式平台上高效运行。

5. 结论

针对建筑环境温湿度控制系统中预测精度与控制实时性难以兼顾的难题,提出了基于 LSTM-ANFIS 串联网络的预测前馈-自适应控制方法,主要工作和结论如下:

(1) 设计了 LSTM-ANFIS 串联网络架构,利用 LSTM 进行时序预测,ANFIS 进行自适应控制,两者通过预测前馈机制实现协同优化。在武汉市某绿色建筑仿真平台的验证结果表明,该方法温度预测 MAE 为 0.31°C 、RMSE 为 0.42°C ,相比 Elman 神经网络分别降低 46.6%和 46.8%。

(2) 与现有控制方法相比,LSTM-ANFIS 串联控制器在温度超调量、调节时间等关键指标上全面占优。温度控制超调量仅为 1.8%19 min,相比 PSO-Elman 方法分别减少 62.3%和 41.2%。

(3) 能耗分析表明,LSTM-ANFIS 方法相比传统 PID 控制节能 29.0%,用户舒适性评分达 92.4 分,综合应用效益显著。

(4) 冬夏工况验证表明,该方法对武汉夏炎冬寒、高湿多变的气候特征具有良好的适应性,预测前馈机制在应对复杂气候扰动时展现出显著优势。

参考文献

- [1] 李康吉. 建筑室内环境建模,控制与优化及能耗预测[D]:[博士学位论文]. 杭州:浙江大学,2013.
- [2] 韩昀松,孙澄,白肇涵,等. 一种建筑室内环境自适应调节系统及控制方法[P]. 中国专利,CN202211121416.X. 2026-07-01.
- [3] 王炎,赵大伟,徐红,等. 物联网通信技术在日光温室环境温湿度预测中的应用[J]. 智能城市,2026,12(2): 9-12.
- [4] 秦浩. 基于 BIM 的绿色建筑能耗控制技术研究[J]. 环境科学与管理,2019,44(2): 31-34.
- [5] 徐风云,曹良友,许建. 一种建筑环境节能管理系统[P]. 中国专利,CN201610525199.9. 2026-07-01.
- [6] 潘纪港,柳平增,张艳,等. 基于 SSA-Elman 的日光温室温湿度预测模型的研究[J]. 中国农机化学报,2024,

- 45(11): 69-76.
- [7] 王伟. 物联网建筑: 行为智能监测与环境控制建筑设备[M]. 南京: 东南大学出版社, 2022.
 - [8] 刘杰, 何云峰, 史自强, 等. 基于模糊自整定 PID 参数的冷库温湿度控制[C]//中国建筑学会建筑热动力分会. 中国建筑学会建筑热动力分会第十七届学术交流大会暨第八届理事会第一次全会论文集. 武汉: 《建筑热能通风空调》编辑部, 2011: 168-171.
 - [9] 王乐思. BIM 技术在电子信息化控制工程成本管理中的应用建模[J]. 现代电子技术, 2020, 43(12): 138-141.
 - [10] 黄凌翎. 室内热环境的全域温湿度预测建模及控制系统设计[J]. 数字技术与应用, 2024, 42(8): 147-149.
 - [11] 胡顺强, 崔东文. 基于 EMD-LSTM-ANFIS 模型的年径流预测研究[J]. 人民珠江, 2021, 42(3): 46-52.
 - [12] Shunqiang, H.U. and Dongwen, C. (2021) Research on Annual Runoff Prediction Based on EMD-LSTM-ANFIS Model. *Renmin Zhujiang*, **42**, 46-52.
 - [13] Sharma, A. and Kumar, A. (2025) Efficient Detection and Multi-Level Classification of Tomato Plant Leaves Using Fused Deep and Hand-Crafted Features and LSTM-ANFIS. In: Dev, A., Sharma, A., Agrawal, S.S. and Rani, R., Eds., *Communications in Computer and Information Science*, Springer, 157-166. https://doi.org/10.1007/978-3-031-75167-7_12
 - [14] Humpe, A., Günzel, H. and Brehm, L. (2021) Benzene Prediction: A Comparative Study of ANFIS, LSTM and MLR. *Proceedings of the 13th International Joint Conference on Computational Intelligence*, **1**, 318-325. <https://doi.org/10.5220/0010660900003063>
 - [15] Erkartal, B. and Yılmaz, A. (2022) Sentiment Analysis of Elon Musk's Twitter Data Using LSTM and ANFIS-SVM. In: Kahraman, C., Tolga, A.C., Cevik Onar, S., Cebi, S., Oztaysi, B. and Sari, I.U., Eds., *Lecture Notes in Networks and Systems*, Springer International Publishing, 626-635. https://doi.org/10.1007/978-3-031-09176-6_70
 - [16] Daskalov, P.I. (1997) Prediction of Temperature and Humidity in a Naturally Ventilated Pig Building. *Journal of Agricultural Engineering Research*, **68**, 329-339. <https://doi.org/10.1006/jaer.1997.0211>
 - [17] Dandotiya, M., Sharma, S. and Goyal, N.K. (2024) ANFIS and LSTM Techniques Based Model for Time-Series Forecasting. 2024 *International Conference on Augmented Reality, Intelligent Systems, and Industrial Automation (ARIIA)*, Manipal, 20-21 December 2024, 1-6.
 - [18] Yildirim, A., Bilgili, M. and Ozbek, A. (2023) One-Hour-Ahead Solar Radiation Forecasting by MLP, LSTM, and ANFIS Approaches. *Meteorology and Atmospheric Physics*, **135**, 1-17. <https://doi.org/10.1007/s00703-022-00946-x>
 - [19] Kido, K., Shimoji, M. and Satoh, N. (2026) Temperature and Humidity Control Apparatus and Temperature and Humidity Prediction Apparatus Used Therefor. US Patent No. 5984002.
 - [20] Do, Q.H. and Trang, T.V. (2020) Forecasting Vietnamese Stock Index: A Comparison of Hierarchical ANFIS and LSTM. *Decision Science Letters*, **9**, 193-206. <https://doi.org/10.5267/j.dsl.2019.11.002>