

采用动力学模态分解和长短期记忆网络的 压缩空气储气装置流场动态预测方法

苏浩^{1,2}, 王同生¹, 邹瀚森¹, 余柯宇¹, 席光^{1,2}, 姚尔人¹

(1. 西安交通大学能源与动力工程学院, 710049, 西安; 2. 西安交通大学未来技术学院, 710049, 西安)

摘要: 针对压缩空气储能系统储气装置内运行参量瞬态演化特性难以快速精准预测的问题, 提出了一种基于动力学模态分解和长短期记忆神经网络的流场降阶预测模型, 实现了储气装置内复杂非线性流场时空演化特征的解耦建模, 建立了储气装置内全局运行参量精准表征与快速流场预测方法。采用动力学模态分解对储气装置内工质合速度、温度和压力等关键物理量的时空全阶数据集解耦降阶, 实现表征流场演化特征主导模态的准确提取; 通过构建长短期记忆神经网络模型预测低维动力系统的时序演化特性, 重构高维时空流场并实现流场全阶参数的动态精准预测。实验结果表明, 储气装置压力场预测的平均相对误差为 0.05%, 速度场预测的平均相对误差为 0.19%, 体积分数场预测的平均相对误差为 0.83%, 模型在保证预测精度的同时计算成本降低 4 个数量级。该方法可实现压缩空气储能系统储气装置内流场的高精度实时预测, 在确保预测精度的同时显著提升计算效率, 为实现系统全工况灵活高效调控提供参考。

关键词: 压缩空气储能; 储气装置; 流场预测; 解耦降阶; 神经网络

中图分类号: TK02 **文献标志码:** A

DOI: 10.7652/xjtub202603004 **文章编号:** 0253-987X(2026)03-0001-13

Dynamic Flow Field Prediction Method for Compressed Air Storage Tanks Using Dynamic Mode Decomposition and Long Short-Term Memory Network

SU Hao^{1,2}, WANG Tonsheng¹, ZOU Hansen¹, YU Keyu¹, XI Guang^{1,2}, YAO Erren¹

(1. School of Energy and Power Engineering, Xi'an Jiaotong University, Xi'an 710049, China;

2. School of Future Technology, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To address the challenge of rapidly and accurately predicting the transient evolution of operational parameters in within the air storage tanks of compressed air energy storage (CAES) systems, this study proposes a reduced-order flow field prediction model based on dynamic mode decomposition (DMD) and long short-term memory (LSTM) network. This model achieves decoupled modeling of the spatiotemporal evolution features of the complex nonlinear flow fields inside storage tanks and establishes a method for accurate global parameter characterization and rapid flow field prediction. DMD decouples and reduces the full-order spatiotemporal datasets of key physical quantities (e. g., velocity, temperature, and pressure) within the storage tanks, enabling accurate extraction of dominant modes governing flow field evolution. An LSTM network model

is then constructed to predict the temporal evolution characteristics of the low-dimensional dynamical system, reconstruct high-dimensional spatiotemporal flow fields, and achieve dynamic and precise prediction of full-order flow parameters. The experimental results demonstrate that the average relative errors for pressure field prediction is 0.05%, 0.19% for the velocity field, and 0.83% for the volume fraction field. The model reduces computational cost by four orders of magnitude while maintaining prediction accuracy. This method enables high-precision real-time flow field prediction for the air storage tanks of CAES systems, significantly improving computational efficiency without sacrificing prediction accuracy, and provides valuable insights for flexible and efficient regulation of such systems under all operating conditions.

Keywords: compressed air energy storage; air storage tank; flow field prediction; data downgrading; neural network

压缩空气储能系统作为一种长时、大规模物理储能技术,具有储能容量大、运行寿命长、建设周期短、生态环境友好等优势,在提高电网调节能力和增强可再生能源消纳领域具有重要的应用潜力^[1]。在用电低谷期,压缩空气储能系统通过压缩机将空气加压并存储于储气装置中;在用电高峰期,储气装置中的高压空气经换热器加热后驱动透平机组膨胀做功,实现电能的稳定输出^[2]。

储气装置是连接压缩空气储能系统储能和释能过程的核心设备^[3],该装置在频繁的压缩-释能循环中承受交变压力与温度载荷,掌握其运行过程的热力学特性是实现系统高效、稳定运行的关键^[4]。众多学者采用数学解析解的方式研究了储气装置内高压空气的热力学变化过程^[5-7],但该方法仅能通过均值结果描述储气装置内热力学特性的变化过程^[8]。然而,即使在储气装置前采用两级冷凝除湿预处理,进入储气装置内的高压空气仍为含湿空气,导致运行过程中储气装置内相对湿度发生动态波动行为,这不仅可以改变空气的比热容与导热系数等关键热物性参数,更因节流降压效应导致冷凝析湿行为,致使无法准确预测储气装置内工质的质量和能量^[9]。因此,储气装置内高压空气的温度、压力等热力参数呈现高度非线性耦合特征^[10],需精准捕捉非定常流场激变引发的全局热力参数动态演化特性,以实现储气装置内热力学动态特性的全面、准确预测。然而,传统的全阶模型因计算资源消耗大,在储气装置流场实时预测方面存在局限^[11],而研究过程中需针对不同水蒸气体积分数的影响进行大量重复计算,进一步凸显了发展高效建模实时预测方法的必要性。

在流体动力学建模领域,传统基于 Navier-Stokes 方程的全阶模型(FOM)虽能实现微秒级精度的流场解析,但单次三维瞬态仿真通常需要部署

百万级网格单元并消耗数千核小时的计算资源,严重制约了流场实时预测能力^[12]。为此,构建具有等效物理特征的降阶模型(ROM)成为当前研究热点。ROM 技术通过数据驱动方式,采用本征正交分解(POD)、动力学模态分解(DMD)等特征提取方法,将原数万维的流场状态空间投影至低维的特征子空间,并结合 Galerkin 投影建立降阶控制方程^[13]。相较于全阶模型,降阶模型节省大量计算时间,同时能保持较高的流场重构精度。

现有降阶模型构建方法主要形成两大技术路线:①基于有源自回归(ARX)、带有外部输入的有源自回归(NARX)等非线性回归模型的系统辨识法,是通过建立输入参数与输出响应之间的黑箱映射关系实现的,其优势在于仅需数百量级的样本即可完成模型训练;②基于 POD、DMD 等模态分解的特征重构法,通过提取流场序列中的主导相干结构构建物理可解释的低维子空间^[14]。传统的降阶方法主要为基于线性投影的技术,即本征正交分解及其变体。POD 通过提取流场快照数据协方差矩阵的主成分,获得一组最优的正交基。在预测阶段,需要结合 Galerkin 投影方法将原始控制方程投影至 POD 模态张成的低维空间,构建降阶动力学方程进行求解;或者采用自回归模型等数据驱动方法直接预测 POD 模态系数的时间演化。

动力学模态分解是由 Schmid 研究团队提出的一种基于数据驱动的流场特征提取方法,该方法通过解析非稳态流动过程的实验观测数据或计算流体力学(CFD)模拟结果,能够有效辨识复杂流动系统的显著动力学模态特征^[15]。其核心优势在于建立具有物理可解释性的降阶模型,通过有限维度的动力学系统实现对原始高维流动现象的本质特征描述。其核心特性体现在其模态参数的数学完备性:

每个分解模态严格对应线性时不变系统的本征频率及特征增长率,这一数学属性使其在具有周期特性的动力学流动研究中展现出显著适用性^[16]。相较于传统流场降阶方法,DMD方法的建模优势主要表现在两个方面:通过矩阵特征值的谱分析直接揭示流动演化特性,避免了传统方法中控制方程重构的复杂性;时空融合解析机制有效整合了基于时域输入输出响应的系统辨识方法与依赖空域样本集的特征提取技术,实现了动力学特征与空间结构的协同表征。这种双域耦合的建模范式为复杂流动系统的机理分析提供了新型数学框架^[17]。

针对非稳态过程预测这一复杂动力学问题,长短期记忆神经网络(LSTM)作为深度学习中具有门控机制的循环神经网络架构,展现出显著的时序建模优势^[18],其核心机理通过遗忘门、输入门和输出门的协同调控,有效克服了传统循环神经网络在长期依赖建模中存在的梯度消失/爆炸问题^[19]。凭借其特有的细胞状态记忆机制,LSTM方法能够实现跨时间步长的时序特征提取,特别适用于流场重构中涉及高维时空演化特性的预测任务。相较于传统预测方法,LSTM方法的非线性映射能力使其在捕捉湍流脉动等非平稳瞬态过程时表现出更强的适应性,同时无需依赖先验的物理方程约束^[20]。这种数据驱动的建模范式为计算流体力学中复杂流动系统的实时预测提供了新的解决方案。

针对压缩空气储气装置内流场强瞬变、高非线性以及复杂时空演化的特点,传统降阶模型在预测精度和长期稳定性方面面临一定的挑战。为了更有效地捕捉储气装置流场的复杂非线性动力学特征并实现稳定、准确的动态预测,本文提出融合动态模态分解(DMD)与长短期记忆(LSTM)神经网络的降阶预测模型(DMD-LSTM),该方法可深度融合DMD的空间特征提取能力与LSTM的非线性时序建模能力两种技术的独特优势。通过将DMD在空间模式提取方面的优势与LSTM在时间序列非线性预测方面的优势相结合,DMD-LSTM模型更具鲁棒性,可以更高效地实现储气装置内复杂流场的动态预测。模型在DMD构建的低维空间运行,确保计算的高效性;同时,LSTM网络通过捕捉非线性动力学特征,大幅提升对储气装置瞬态流动的预测精度。

1 研究方法

本研究所依赖的流场基础数据集以及预测结果的验证基准均来源于高精度计算流体动力学数值模

拟,本文基于 ANSYS FLUENT 建立了数值仿真模型,采用多相流流体体积函数(VOF)内嵌入 Lee 蒸发-冷凝传质机理的方法,分析储气装置内充入湿空气工况的流场变化情况,气体状态方程为 R-K-S 真实气体状态模型,湍流方程为 SST $k-\omega$ 湍流模型,充气入口类型为速度入口。

1.1 动力学模态分解

动力学模态分解的预处理流程需对瞬态流场数据进行结构化处理。通过数值模拟获取 N 个瞬态流场样本,并组织为时序排列的瞬态数据集 $\{x, x, \dots, x_N\}$,其中各样本 x_i 表征第 i 时刻的流场状态列向量,且相邻样本间保持等时间步长 Δt 。每一时刻的流场的 x_i (如速度、压力、温度等) 可以表示成基本流动 $\bar{x}$ (平均流) 和脉动量 x'_i 的叠加,即

$$x_i = \bar{x} + x'_i \quad (1)$$

根据 DMD 的理论框架,系统动力学可表述为线性传递关系

$$x_{i+1} = Ax_i \quad (2)$$

式中: A 为高维动力系统矩阵。对于本质非线性的物理系统,该过程实质为全局动力学的线性近似建模。值得注意的是,系统矩阵 A 的维度与流场自由度数呈正相关,直接求解存在维数灾难问题,需采用数据驱动的降阶方法进行求解^[13]。为实现系统矩阵的特征提取,可利用 $1 \sim N$ 时刻的流场快照构造时序延迟数据矩阵,定义 $X = [x, x, \dots, x_{N-1}]$ 与 $Y = [x, x, \dots, x_N]$ 分别作为前和后两个状态矩阵。该构造方法有效建立了流场演化的离散映射关系,为后续模态分解奠定数据基础。根据式(1)的假定,有

$$Y = [x_2, x_3, x_4, \dots, x_N] =$$

$$[Ax_1, Ax_2, Ax_3, \dots, Ax_{N-1}] = AX \quad (3)$$

DMD 的核心目标在于通过矩阵运算技术,从高维数据中辨识主导动力学模态及其对应的特征参数。基于线性动力学假设,现有算法实现路径主要分为两类:其一基于时滞坐标系的伴随矩阵理论,通过构造有限维伴随矩阵(Companion Matrix)实现无穷维算子的低秩近似;其二则融合本征正交分解技术的手段,借助奇异值分解(SVD)对原始算子实施相似变换,建立具有降维特性的系统动力学模型^[21]。研究结果表明,后者通过 POD 正交基底构建,显著提升了算法在含噪环境下的数值稳定性,尤其在存在测量噪声或数值误差的工程场景中展现出更强的计算稳定性^[22]。

相较于基于友矩阵的 DMD 架构,DMD 的相似变换结合奇异值分解的方法展现出显著的理论优

势。首先,该方法突破了基于友矩阵的 DMD 对时序连续性约束条件的依赖,其数学模型仅需获取相邻时刻的流场增量数据对即可构建动力学算子;其次,通过引入 SVD 技术对数据矩阵进行最优低秩近似,有效增强了算法在噪声污染场景下的数值稳定性,模态分解过程如图 1 所示。图 1 中表达了一种近似相等的关系,通过高度概括、符号化的示意图直观表达为核心运算关系:快照矩阵 $\approx$ 模态矩阵 $\times$ 频谱矩阵 $\times$ 动态矩阵。




图 1 DMD 的模态分解

Fig. 1 Modal decomposition of DMD

相较于 POD 方法,DMD 技术在流场分析中展现出 3 个方面的显著优势。首先,POD 模态本质上是多频叠加的统计最优空间基函数,其宽频动力学特征导致物理机理阐释困难;而 DMD 模态具有精确的单频特性,其傅里叶特征更便于解析流动结构的动力学本质。其次,POD 方法缺乏动力学建模能力,DMD 方法通过复特征值分解同时获得各阶模态的振荡频率,其幅值信息更直接反映了模态的稳定性特征。最后,在降阶模型构建层面,POD 方法本身不具备动力学建模功能,需借助 Galerkin 投影建立常微分方程系统或构建数据驱动的代理模型^[23];而 DMD 通过特征值分解直接获得时空解耦的线性动力学模型,其时间演化特征由模态的指数增长或衰减参数完全确定,避免了复杂的投影计算过程^[24]。这种时空解耦的模态分解特性正是 DMD 方法在非定常流场分析中的核心优势所在。

1.1.1 标准方法

在流场数据分析中,当采样数量 N 增至某一临界值后,所构建的流场快照序列 $\{x, x, \dots, x_N\}$ 已能充分表征系统的主要动力学特性。基于此,可通过数学归纳法建立以下假设:当快照数量超过该临界值时,后续流场快照与前期快照集合同存在线性关联。这一假设的数学推论表明,第 N 个流场快照可表示为前 $N-1$ 个快照的线性组合

$$\mathbf{x}_N = c_1 \mathbf{x}_1 + c_2 \mathbf{x}_2 + \dots + c_{N-1} \mathbf{x}_{N-1} = \mathbf{X} \mathbf{c} \quad (4)$$

式中: $c = c_1, \dots, c_{N-1}$ 为多项式的系数,则式(4)可进一步表示为

$$\mathbf{A} \mathbf{X} = \mathbf{Y} = \mathbf{X} \mathbf{S} \quad (5)$$

式中: $\mathbf{S}$ 为友矩阵,表达式为

$$\mathbf{S} = \begin{bmatrix} 0 & \cdots & 0 & 0 & c_1 \\ 1 & \ddots & \vdots & \vdots & \vdots \\ 0 & \ddots & 0 & 0 & c_{N-3} \\ \vdots & \ddots & 1 & 0 & c_{N-2} \\ 0 & \cdots & 0 & 1 & c_{N-1} \end{bmatrix} \quad (6)$$

矩阵 $\mathbf{S}$ 中的未知量仅有 c ,所以可求得使残差 r 最小的 c 用以构造矩阵 $\mathbf{S}$

$$r = \mathbf{x}_N - \mathbf{X} \mathbf{c} \quad (7)$$

经优化过程使残差范数达到极小值时,降阶系统矩阵 $\mathbf{S}$ 的特征谱将收敛于原系统矩阵 $\mathbf{A}$ 的主导模态特征值。值得注意的是,此类通过降阶过程提取的特征值在数值分析中被称为 Ritz 特征值,其收敛性验证需满足 Arnoldi 正交化过程的数学约束条件。矩阵 $\mathbf{S}$ 的特征分解为

$$\mathbf{S} = \mathbf{T}^{-1} \mathbf{\Lambda} \mathbf{T} \quad (8)$$

其中 $\mathbf{\Lambda} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_{N-1})$ 。在动力模态分解的数学框架下,设谱矩阵 $\mathbf{\Lambda}$ 表征降阶系统 $\mathbf{S}$ 的特征值对角化形式,其对应的特征向量构成正交矩阵 $\mathbf{T}^{-1}$ 的列空间。基于正交分解原理,构造模态矩阵 $\mathbf{D} = \mathbf{X} \mathbf{T}^{-1}$,其列向量 $\mathbf{d}$ 表征系统的本征模态。为构建完备的时空流场重构体系,需引入具有时域演化特性的 Vandermonde 矩阵

$$\tilde{\mathbf{T}} = \begin{bmatrix} 1 & \lambda_1 & \cdots & \lambda_1^{N-2} \\ \vdots & \vdots & & \vdots \\ 1 & \lambda_m & \cdots & \lambda_m^{N-2} \end{bmatrix} \quad (9)$$

对于具有互异特征值的友矩阵,其可对角化特性保证了存在非奇异矩阵 $\mathbf{T}$,使得该友矩阵可通过基变换实现对角化。根据矩阵分解理论,构造满足 $\mathbf{D} = \mathbf{X} \mathbf{T}^{-1}$ 的对角矩阵 $\mathbf{D}$ 时,矩阵 $\mathbf{T}$ 在映射过程中保持与原始友矩阵的线性同构关系。基于此数学对应性,流场瞬态快照可构建为以下形式

$$\begin{aligned} \mathbf{X} &= [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{N-1}] = \mathbf{D} \tilde{\mathbf{T}} \\ &= [\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_m] \begin{bmatrix} 1 & \lambda_1 & \cdots & \lambda_1^{N-2} \\ \vdots & \vdots & & \vdots \\ 1 & \lambda_m & \cdots & \lambda_m^{N-2} \end{bmatrix} \end{aligned} \quad (10)$$

其中 m 为 DMD 方法所选择的模态数,因此任何一个时刻的流场瞬态快照都可以用前 m 个快照表示,即

$$\mathbf{x}_i = \sum_{j=1}^m \lambda_j^{i-1} \mathbf{d}_j \quad (11)$$

将第 j 个模态所对应的频率 ω_j 和增长率 g_j 分别定义为

$$\omega_j = \text{Im}\{\lg(\lambda_j)\}/\Delta t \quad (12)$$

$$g_j = \text{Re}\{\lg(\lambda_j)\}/\Delta t \quad (13)$$

1.1.2 相似变换

实现 DMD 的另一种途径可通过矩阵相似性原理构建,这一途径的优势是通过截断奇异值分解(SVD)过程可自适应地提取主导模式对应的低维子空间,继而利用投影算子建立维度降低的相似变换体系。这样不仅有效克服了高维矩阵直接分解带来的计算复杂性,同时严格保持了系统关键动态特性的数学等价性。原始流场瞬态快照 $\mathbf{X}$ 的动力学特性可通过构造低维相似矩阵 $\tilde{\mathbf{A}}$ 进行降维表征,其中 $\tilde{\mathbf{A}}$ 与原始高维矩阵 $\mathbf{A}$ 满足相似关系。为确定该相似变换对应的正交投影子空间,可采用矩阵分解进行处理,通过对 $\mathbf{X}$ 进行奇异值分解可得

$$\mathbf{X} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^H \quad (14)$$

$$\mathbf{A} = \mathbf{U}\tilde{\mathbf{A}}\mathbf{U}^H \quad (15)$$

式中: $\mathbf{\Sigma}$ 是对角矩阵,其主对角线元素为按降序排列的奇异值,构成能量谱系。通过在奇异值分解过程中实施秩截断策略,即只保留前 r 个主要奇异值并舍弃剩余的小奇异值,该操作实现了最优低秩近似,能够有效抑制数值噪声。分解产生的酉矩阵 $\mathbf{U}$ 和 $\mathbf{V}$ 满足标准正交性约束条件: $\mathbf{U}^H\mathbf{U} = \mathbf{I}$ 且 $\mathbf{V}^H\mathbf{V} = \mathbf{I}$, 其中上标 H 表示共轭转置运算。在此基底框架下,系统降维矩阵 $\mathbf{A}$ 的求解可被构建为 Frobenius 范数最小化问题,表达式如下

$$\min_{\mathbf{A}} \|\mathbf{Y} - \mathbf{A}\mathbf{X}\|_F^2 \quad (16)$$

结合式(14)和式(15),式(16)可整理为

$$\min_{\mathbf{A}} \|\mathbf{Y} - \mathbf{U}\tilde{\mathbf{A}}\mathbf{\Sigma}\mathbf{V}^H\|_F^2 \quad (17)$$

因此,原始系统矩阵 $\mathbf{A}$ 可近似为

$$\mathbf{A} \approx \tilde{\mathbf{A}} = \mathbf{U}^H\mathbf{Y}\mathbf{V}\mathbf{\Sigma}^{-1} \quad (18)$$

降维矩阵 $\tilde{\mathbf{A}}$ 与原始高维矩阵 $\mathbf{A}$ 通过相似变换关系相连接,根据线性代数中的谱定理,二者共享相同的谱结构,则降维矩阵包含原始矩阵的主要特征值,第 j 个 DMD 模态为

$$\Phi_j = \mathbf{U}\mathbf{w}_j \quad (19)$$

式中: $\mathbf{w}_j$ 为特征向量,记降维矩阵的第 j 个特征值为 μ_j ,该模态的动力学参数的数学定义遵循式(12)、(13)所确立的规范。通过上述 DMD 方法,实现了流场动态特征模态的有效提取。在此基础上,通过降维矩阵 $\tilde{\mathbf{A}}$ 的谱分析特性,可重构流场的时空演化规律,系统的高维状态变量 x_i 可通过奇异值分

解实现维度约简,其映射关系可表述为

$$\mathbf{z}_j = \mathbf{U}^H\mathbf{x}_i \quad (20)$$

式中: $\mathbf{z}_j$ 为原始高维系统 x_i 所映射的子空间,降维后的系统控制方程为

$$\mathbf{z}_{i+1} = \mathbf{U}^H\mathbf{x}_{i+1} = \mathbf{U}^H\mathbf{A}\mathbf{x}_i = \mathbf{U}^H\mathbf{A}\mathbf{U}\mathbf{z}_i = \tilde{\mathbf{A}}\mathbf{z}_i \quad (21)$$

将特征向量 $\mathbf{w}_j$ 作为列向量组合为矩阵 $\mathbf{W}$,包含降维矩阵 $\tilde{\mathbf{A}}$ 奇异值的对角阵为 $\mathbf{N}$,则降维矩阵 $\tilde{\mathbf{A}}$ 的特征分解为

$$\tilde{\mathbf{A}} = \mathbf{W}\mathbf{N}\mathbf{W}^{-1}, \mathbf{N} = \text{diag}(\mu_1, \mu_2, \dots, \mu_r) \quad (22)$$

所以任何一个时刻的流场快照可以近似估计为

$$\begin{aligned} \mathbf{x}_i &= \mathbf{A}\mathbf{x}_{i-1} = \mathbf{U}\tilde{\mathbf{A}}\mathbf{U}^H\mathbf{x}_{i-1} \\ &= \mathbf{U}\mathbf{W}\mathbf{N}\mathbf{W}^{-1}\mathbf{U}^H\mathbf{x}_{i-1} = \mathbf{U}\mathbf{W}\mathbf{N}^{i-1}\mathbf{W}^{-1}\mathbf{U}^H\mathbf{x}_1 \end{aligned} \quad (23)$$

根据每个 DMD 模态被定义为 Φ_j ,可以将其作为列向量组合为矩阵 Φ ,有

$$\Phi = \mathbf{U}\mathbf{W} \quad (24)$$

定义 DMD 模态振幅 α

$$\alpha = \mathbf{W}^{-1}\mathbf{z}_1 = \mathbf{W}^{-1}\mathbf{U}^H\mathbf{x}_1, \alpha = [\alpha_1, \alpha_2, \dots, \alpha_r]^T \quad (25)$$

式中: α_i 表征第 i 个模态的振幅,其物理意义反映了该模态对初始流场快照 x_1 的动力学贡献权重。在 DMD 方法框架下,各阶模态依据其对应的振幅进行优先级排序,该排序准则保证了主导模态在流场重构中的优先表征权。通过联立式(24)的模态展开与式(25)的模态振幅,并代入流场重构方程式(23),可建立时空解耦的预测模型,由此导得任意时刻的流场可解析表示为

$$\mathbf{x}_i = \Phi\mathbf{A}^{i-1}\alpha = \sum_{j=1}^r \Phi_j (\mu_j)^{i-1} \alpha_j \quad (26)$$

流场快照可写为

$$\begin{aligned} \mathbf{X} &= [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{N-1}] = \Phi\mathbf{D}_a\mathbf{V}_{\text{and}} = \\ &[\Phi_1, \Phi_2, \dots, \Phi_r] \begin{bmatrix} \alpha_1 & & & \\ & \ddots & & \\ & & \ddots & \\ & & & \alpha_r \end{bmatrix} \begin{bmatrix} 1 & \mu_1 & \dots & \mu_1^{N-2} \\ \vdots & \vdots & & \vdots \\ 1 & \mu_r & \dots & \mu_r^{N-2} \end{bmatrix} \end{aligned} \quad (27)$$

流场演化过程的数学表征可由式(27)中的 Vandermonde 矩阵 $\mathbf{V}_{\text{and}}$ 实现,其中包含了 r 个原始流场矩阵的特征值。

1.2 神经网络预测

流场动态预测属于时间序列预测问题,常用于时间序列预测的神经网络主要包括门控循环神经网络(GRU)、循环神经网络(RNN)和长短期记忆网络(LSTM),这些模型专门设计用于处理时间依赖数据,并能捕捉时间序列中复杂的模式和趋势^[25]。RNN 通过循环结构处理序列数据,而 LSTM 相较

于 RNN 有更强的记忆能力,在长序列中表现较好,能够自适应地利用历史数据进行建模,并对未来数据序列进行预测^[26]。




图 2 LSTM 神经网络结构

Fig. 2 LSTM neural network structure

长短期记忆网络作为循环神经网络的改进架构,通过独特的记忆单元设计有效缓解了传统 RNN 存在的梯度消失问题,从而增强了对长时序依赖关系的建模能力^[27]。其结构创新主要体现在以记忆块替代传统循环神经网络中的隐层神经元单元,每个记忆块内部包含精密的门控机制,用于动态调控细胞状态(cell state)的存储与更新过程^[28]。如图 2 所示的结构示意图中,LSTM 记忆块通过遗忘门(forget gate)、输入门(input gate)与输出门(output gate)3 个协同工作的门控单元构建了信息流的动态调节机制,各门控单元的数学模型可形式化表述如下。

遗忘门机制通过 sigmoid 激活函数生成介于 0~1 之间的权值矩阵,用于调控细胞状态信息的保留比例

$$f_t = \sigma(W_f [h_{t-1}, x_t] + b_f) \quad (28)$$

输入门系统采用双通道结构,分别执行信息筛选与特征转换功能。

信息筛选表达式为

$$i_t = \sigma(W_i [h_{t-1}, x_t] + b_i) \quad (29)$$

特征转换表达式为

$$\tilde{C}_t = \tanh(W_C [h_{t-1}, x_t] + b_C) \quad (30)$$

细胞状态更新综合前序状态与当前输入特征

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (31)$$

输出门模块结合非线性变换确定最终输出特征

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (32)$$

$$h_t = o_t \tanh(C_t) \quad (33)$$

式中: σ 为 sigmoid 函数; x_t 为 t 时刻的输入; h_t 为 t 时刻的隐藏状态; C_t 为 t 时刻的单元状态; W 和 b 分别是权重与偏置。该架构通过参数化门控单元的协同作用,实现了对信息存储周期的动态控制。记忆块输出的隐状态 h_t 既作为当前时刻的作曲特征表征,又作为时序传播载体输入至下一处理单元,形成具有长期记忆保持能力的递归计算结构^[29]。

基于上述算法原理,实现了 DMD-LSTM 混合降阶预测模型,程序框架如图 3 所示,完整流程步骤概括如下。

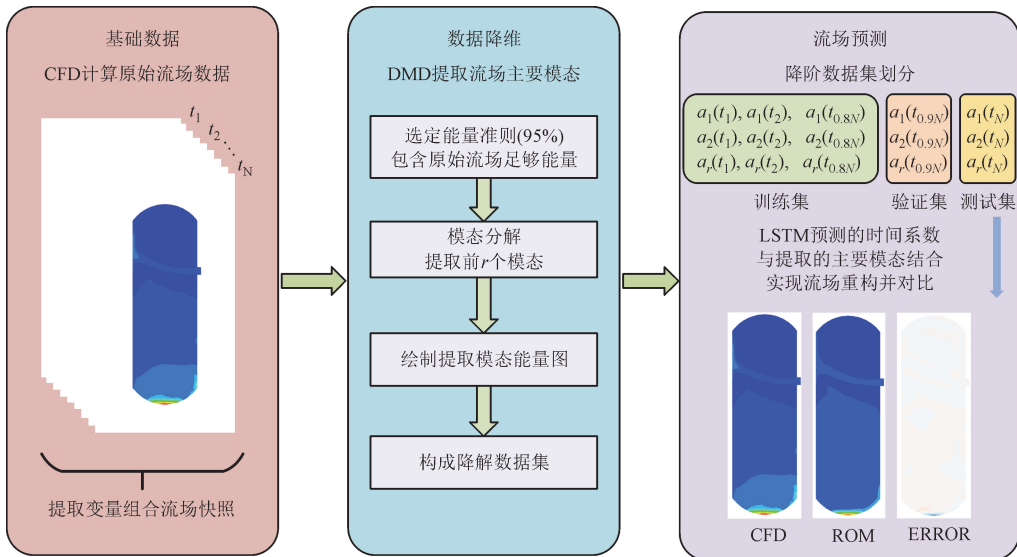


图 3 DMD-LSTM 混合降阶模型程序流程框架

Fig. 3 Framework for the DMD-LSTM hybrid reduced-order modelling procedure

步骤 1 基于储气装置的三维几何模型构建数值计算域,采用计算流体力学方法进行数值模拟,生成全阶流场物理量的时空分布数据集。

步骤 2 引入动力学模态分解算法对全阶流场数据集进行时空特征分析,通过谱分析方法辨识主导模态及其对应的时间演化特性。基于保留原始流场 95% 能量的模态能量准则选取最优截断阶数,建立降阶模型的空间基底矩阵和时间系数矩阵,实现高维流场数据的低维特征表征。

步骤 3 构建长短期记忆神经网络架构,将降阶模型所得到的各个时刻的时间系数序列 $a_1, a_2, a_3, \dots, a_r$ 划分为训练集、验证集与测试集进行时序预测建模。采用 Adam 优化器对神经网络模型中的超参数进行全局寻优,以提升模型泛化能力。将预测得到的时间系数与 DMD 空间基底进行张量重构运算,建立降阶空间到原物理空间的映射关系,最终获得全阶流场变量的空间预测分布。

2 结果与讨论

2.1 研究对象

本文研究对象为压缩空气储能实验系统中的储气装置,该储气装置为圆柱形罐体结构,顶部与底部均为圆顶结构,其中圆柱形半径为 0.85 m,高为 4.4 m,圆顶部分的球体半径为 0.6 m,储气装置的容积为 12 m³。

针对压缩空气储能系统储气装置充气过程非定常流场动态变化特性,分析对象包含速度场、温度场、压力场和水的体积分数。其中速度场采用三维状态下计算得到的合速度作为研究变量,水的体积分数则更能体现压缩空气储气装置中水的蒸发与冷凝现象。为了探究充气过程中储气装置内的流场动态变化,分别计算充入空气中的水蒸气体积分数为 0.1%、2%、3% 这 4 种典型工况,以更好地捕捉储气装置充气过程中蒸发冷凝等流场动态特性。

2.2 流场降阶与预测模型

计算所采用的数据集是充气过程总计 3 600 s 的储气装置动态流场,对其进行 DMD 处理实现流场降阶,提取流场主要模态与特征。在动力模态分解的理论框架下,对快照矩阵实施谱特征分析,建立基于模态能量权重的量化评估体系。通过求解 Koopman 算子的近似特征系统,构建模态振幅时变发展模型,据此实施模态贡献度排序计算。采用降阶模态筛选策略,选取前 19 阶主导模态构建低维特征空间,实现流场动力学特征的稀疏表征与时空重

构。模态累计包含的能量如图 4 所示。




图 4 DMD 分解模态累计能量

Fig. 4 DMD Decomposition Modal Accumulated Energy

采用 LSTM 神经网络预测,将充气过程为 3 600 s、时间间隔为 10 s 的降阶时间系数数据集进行划分,80% 为训练集,10% 为验证集以及 10% 为测试集,以测试集的流场数据作为标准与 CFD 结果进行对比,评价流场预测效果。

2.3 流场预测效果评价

在数值模拟领域,不同计算方法的时效性对比研究对于工程优化具有重要意义。在相同的计算资源配置下,针对压缩空气储气装置充气过程开展了不同计算方法的对比实验。数值仿真结果表明,基于有限体积法的计算流体力学全阶模型数值模拟完成计算耗时约 1.47 h,这主要源于 Navier-Stokes 方程的复杂数值求解过程。相比之下,数据驱动的深度学习方法在相同硬件条件下展现出显著优势,本研究所采用的动力学模态分解与长短期记忆神经网络协同的混合降阶模型表现出卓越的计算效率,神经网络的训练过程仅需 62 s 即可完成,并且模型迭代效果较好,损失函数如图 5 所示。该模型通过 DMD 方法提取主导流动模态后,利用 LSTM 网络进行时间系数预测,最终实现流场特征的高分辨率重建。实验结果表明,该混合 ROM 的计算耗时稳定维持在 0.3~0.5 s 区间内,其时间成本不足传统 CFD 模拟的 0.01%,这种量级上的效率提升在工程实时监




图 5 LSTM 模型训练损失函数

Fig. 5 LSTM model training loss function

测和快速参数优化等场景中具有重要应用价值^[19]。

2.3.1 水的体积分数

为系统评估相变传热过程中质量传递效应对多相流界面的影响机制,本研究通过气液体积分数分布特征定量表征储气装置内非稳态蒸发冷凝现象^[30]。如图 6 所示,基于 DMD-LSTM 混合降阶模型在扩展时间尺度 t_1 、 t_2 、 t_3 、 t_4 上不同工况下的预测性能,工况 1、2、3、4 分别代表充入空气中的水蒸气体积分数(水的体积分数)为 0、1%、2%、3%。本研究通过与 CFD 全阶数值模拟的流场结果进行对比验证,具体包括:①基于 VOF 方法捕捉的界面演化基准解;②降阶模型重构的相分布场;③非平衡态热力学参数驱动的相对误差云图。




图 6 不同工况下 ROM 模型预测结果

Fig. 6 Prediction results of hybrid DMD-LSTM downscaling model under different working conditions

在储气装置充气过程中,水的蒸发与冷凝现象是重要的研究内容,因此选取水蒸气体积分数为 0.01 工况下的预测结果进行更详细的分析,取 $t_1 = 3\,420\text{ s}$ 、 $t_2 = 3\,480\text{ s}$ 、 $t_3 = 3\,540\text{ s}$ 、 $t_4 = 3\,600\text{ s}$ 4 个时刻的预测数据进行分析并观察误差分布,如图 7 所示。




图 7 水蒸气体积分数为 1% 工况下水的体积分数的场分布 CFD 结果与 ROM 模型预测结果对比

Fig. 7 Comparison of CFD results and ROM model predictions of water volume fraction field for 1% working condition with moisture content

基于多物理场耦合的数值验证框架的系统评估结果表明,LSTM 降阶模型在预测储气装置中水的蒸发与冷凝现象时展现出可靠的预测性能。如图 7 所示,模型预测的液态水体积分数场与 CFD 基准解具有显著空间一致性,定量分析结果表明,全场平均相对误差仅为 0.83%,验证了模型的全局可靠性。然而在储气装置底部区域出现较大的局部相对误差的主要原因是该区域稳态冷凝层的固定相界面特性,这种物理量的动态变换趋势对 LSTM 模型的特征提取构成挑战^[31]。尽管如此,模型仍准确捕捉到底部壁面的冷凝现象,且对充气过程中水的体积分数时变趋势预测偏差较小。特别值得指出的是,局部误差集中出现在冷凝水聚集区域的现象,进一步验证了模型物理预测的合理性。上述分析结果证实,LSTM 降阶模型不仅具有远离训练数据区域的泛化能力,更能实现对压缩空气储气装置流场的精准预测,其预测结果与实际情况具有高度吻合性。

2.3.2 温度

基于热力学与传质耦合效应分析,储气装置在非理想充气工况下的温升特性呈现显著湿度依赖性,而储气装置在充气过程中无法确保充入空气完全干燥,并且随着充入储气装置的空气中含水量的增大,温度上升的速率会增大。其机理可归结于湿

空气热物理性质的改变,水蒸气分子具有强极性特征,相较于完全干燥的空气会增强气体介电特性,导致压缩过程中分子间作用力引起的能量耗散加剧。同时,湿空气的热力学特性遵循焓值构成结构,其中水蒸气本身的焓值较大,使得单位质量湿空气携带的热量随含水量呈非线性增长^[32]。充入空气的温度与储气装置原始环境温度存在梯度差异,在快速充放气工况下,湿空气引起的非均匀温度场会诱发局部应力集中,降低设备疲劳寿命,因此温度场在储气装置充气过程中也有研究意义。




图 8 水蒸气体积分数 1% 工况温度场 CFD 结果与 ROM 模型预测结果的对比

Fig. 8 Comparison between CFD results and ROM model prediction of temperature field for 1% moisture content condition

基于图 8 所示 4 个时刻温度场预测结果表明,数值预测模型虽在高温梯度区域呈现非物理振荡模态,但其与 CFD 基准解在宏观演化规律上保持高度吻合。定量误差评估结果表明,最大相对偏差集中分布于储气装置下缘区域,究其机理是多物理场耦合作用。湿空气注入过程引发的非均匀温度场分布主要集中于储罐中上部区域,该区域因相变潜热释放形成显著的温度梯度,其动态特征在谱空间中具有可辨识的模态结构;相较而言,底部区域受瞬态热力学耦合效应影响较弱,且与外部环境存在持续性热交换,导致该区域温度梯度幅值较低,动态特征能量谱密度下降。

深入分析,揭示底部流场重构误差源于两种耦合机制的协同作用。低梯度热力学场在 DMD 模态能

量谱中的贡献率显著衰减,在降阶过程中优先截断其对应模态,导致模态空间对热力学变量的表征不完整,从而引发系统性重构偏差;非稳态边界条件下热质交换过程的强非线性动力学呈现多尺度特征,其主导物理时间尺度与 DMD 方法可分辨的特征时间尺度存在数量级的差异,这种跨尺度失配使得算法无法有效捕捉亚分辨率瞬态过程。在有限快照采样率的制约下,上述因素共同导致流场演化呈现非平稳随机波动特性,致使关键相干结构的动力学模态难以完备表征,最终造成局部区域空间梯度的重构精度损失。

2.3.3 合速度

在上述流场降阶与流场预测中,所处理的流场数据均为标量形式,因此选取在三维状态下计算的合速度进行速度场分析,而非采取某单一方向。合速度计算式如下

$$\|V\| = \sqrt{v_x^2 + v_y^2 + v_z^2} \tag{34}$$

相较于单一方向速度分量分析,该合成速度表征方法具有两方面理论优势。在湍流多尺度动力学研究中,合速度场能够完整保留流场动能的空间分布特征,其能量谱函数与原始矢量场保持拓扑同构关系;通过消除速度分量间的解耦效应,合成速度场可更灵敏地反映剪切层演化、涡旋脱落等典型流动现象的多物理耦合机制。

基于图 9 所示的流场动力学演化特征分析,充气过程中储罐内部形成典型的高速流动区,沿轴向呈现




图 9 水蒸气的体积分数为 1% 工况下速度场 CFD 结果与 ROM 模型预测结果对比

Fig. 9 Comparison between CFD results and ROM model prediction of velocity field for 1% moisture content condition

自入口至储罐中上部的渐进式扩展模式。数值验证结果表明,LSTM 深度学习模型在速度场预测方面展现出良好的预测性能,其与 CFD 基准解在速度模量分布上的平均相对误差为 0.19%。进一步通过误差场量化分析可以看出,在流场结构相对稳定的准稳态区域,预测结果与 CFD 原始结果保持高度吻合;但在近壁冷凝效应显著的区域,预测偏差呈现局部放大现象。这种误差分布特征与多相流耦合效应密切相关。当湿空气沿壁面回流时,气液两相界面处发生的非平衡相变过程会显著改变区域流场结构。冷凝液膜的形成导致边界层内速度剖面发生畸变,相变潜热释放引发局部温度梯度突变,并且气液界面会存在波动,这些多物理场耦合机制超出了 LSTM 模型对流场的预测能力范畴,导致这部分壁面附近的预测偏差增大。

2.3.4 压力

储气装置在充气压缩过程中,系统压力随气体质量增加呈单调递增趋势,其演变规律遵循理想气体状态方程与能量守恒定律的耦合作用^[33]。压力不仅直接表征储能介质的热力学状态,更是量化系统势能存储效率的核心指标。

由图 10 揭示的压力场演化特征可知,受限空间内压力梯度趋近于 0,这符合达西定律在低速渗流

场中的压力均衡分布规律,压力场平均相对偏差为 0.05%,压力场空间标准差始终维持在较低水平,这种准静态变化特性显著降低了模型对空间异质性的建模难度,模型预测效果也较好。

3 结 论

本研究提出了一种基于动力学模态分解与长短期记忆神经网络相结合的流场降阶预测模型(DMD-LSTM),实现了压缩空气储能系统中储气装置充气过程非线性复杂流场特性的快速预测,为压缩空气储能系统在全运行域内的灵活高效调控提供参考,具体结论如下。

(1)构建的 DMD-LSTM 流场降阶预测模型在储气装置瞬态流场预测中展现出优异的性能,针对气液两相流中的水的体积分数这个关键物理量,模型成功捕捉到相变过程中的冷凝现象动态演化特征。实验验证结果表明:在最大外推时间域条件下,压力场平均相对偏差为 0.05%,速度场预测的平均相对误差为 0.19%,体积分场预测的平均相对误差为 0.83%。通过构建多物理量验证体系,证实了该模型在储气装置流场预测中对温度、压力和速度场的预测效果均较好。

(2)针对压缩空气储气装置充气过程的数值模拟,所提出的 DMD-LSTM 流场降阶预测模型较传统有限体积法 CFD 全阶模型数值模拟展现出显著的效率优势,相同计算资源条件下计算耗时降低 4 个数量级,为储气装置内热力参量的快速精准预测提供了有效解决方案。

参考文献:

[1] YAO Erren, ZHONG Like, ZHANG Shuqi, et al. Off-design performance evaluation of a combined heating and power system based on compressed air and thermochemical energy storage under optimized operation strategy [J]. Journal of Energy Storage, 2025, 130: 117485.

[2] 郭丁彰,尹钊,周学志,等. 压缩空气储能系统储气装置研究现状与发展趋势 [J]. 储能科学与技术, 2021, 10(5): 1486-1493.

GUO Dingzhang, YIN Zhao, ZHOU Xuezhi, et al. Status and prospect of gas storage device in compressed air energy storage system [J]. Energy Storage Science and Technology, 2021, 10(5): 1486-1493.

[3] GHANBARZADEH T, HABIBI D, AZIZ A. Addressing reliability challenges in generation capacity planning under




图 10 水蒸气体积分数 1% 工况压力场 CFD 结果与 ROM 模型预测结果对比

Fig. 10 Comparison between CFD results and ROM model prediction of pressure field for 1% moisture content condition

- high penetration of renewable energy resources and storage solutions: a review [J]. *Renewable and Sustainable Energy Reviews*, 2025, 212: 115461.
- [4] 姚尔人, 仲理科, 邹瀚森, 等. 压缩空气与热化学复合储能系统反应器动态性能研究 [J]. *西安交通大学学报*, 2024, 58(2): 1-11.
- YAO Erren, ZHONG Like, ZOU Hansen, et al. Dynamic thermodynamic performance study of the reactor within the combined compressed air and thermochemical energy storage system [J]. *Journal of Xi'an Jiaotong University*, 2024, 58(2): 1-11.
- [5] KUSHNIR R, DAYAN A, ULLMANN A. Temperature and pressure variations within compressed air energy storage caverns [J]. *International Journal of Heat and Mass Transfer*, 2012, 55(21/22): 5616-5630.
- [6] ZHOU Shuwei, XIA Caichu, DU Shigui, et al. An analytical solution for mechanical responses induced by temperature and air pressure in a lined rock cavern for underground compressed air energy storage [J]. *Rock Mechanics and Rock Engineering*, 2015, 48(2): 749-770.
- [7] RAJU M, KUMAR KHAITAN S. Modeling and simulation of compressed air storage in caverns: a case study of the Huntorf plant [J]. *Applied Energy*, 2012, 89(1): 474-481.
- [8] 蒋中明, 廖峻慧, 肖喆臻, 等. 压缩空气储能地下储气库热力学改进模型研究 [J]. *长沙理工大学学报(自然科学版)*, 2024, 21(2): 32-41.
- JIANG Zhongming, LIAO Junhui, XIAO Zhezhen, et al. Study on improved model for the thermodynamics of compressed air energy storage underground cavern [J]. *Journal of Changsha University of Science & Technology(Natural Science)*, 2024, 21(2): 32-41.
- [9] 蒋中明, 郭菁, 唐栋. 压气储能地下储气库压缩湿空气热力学模型 [J]. *储能科学与技术*, 2021, 10(2): 638-646.
- JIANG Zhongming, GUO Jing, TANG Dong. A thermodynamic model of compressed humid air within an underground rock cavern for compressed air energy storage [J]. *Energy Storage Science and Technology*, 2021, 10(2): 638-646.
- [10] YANG Chunhe, WANG Tongtao. Deep underground energy storage: aiming for carbon neutrality and its challenges [J]. *Engineering*, 2023, 29(10): 11-14.
- [11] 惠心雨, 袁泽龙, 白俊强, 等. 基于深度学习的非定常周期性流动预测方法 [J]. *空气动力学学报*, 2019, 37(3): 462-469.
- HUI Xinyu, YUAN Zelong, BAI Junqiang, et al. A method of unsteady periodic flow field prediction based on the deep learning [J]. *Acta Aerodynamica Sinica*, 2019, 37(3): 462-469.
- [12] 袁晓明, 刘存飞, 肖浩阳, 等. 基于降阶预测模型的自激振荡消防喷嘴流场预测[J/OL]. *机械工程学报*. (2025-04-09)[访问日期]. <https://link.cnki.net/urlid/11.2187.TH.20250409.1406.040>.
- YUAN Xiaoming, LIU Cunfei, XIAO Haoyang, et al. Self-oscillating fire nozzle flow field prediction based on reduced order prediction model [J/OL]. *Journal of Mechanical Engineering*. (2025-04-09)[访问日期]. <https://link.cnki.net/urlid/11.2187.TH.20250409.1406.040>.
- [13] 舒航, 钟文琪, 陈曦, 等. 基于 POD 和 TFM 的气固流化床流场压力分布预测研究 [J]. *工程热物理学报*, 2024, 45(11): 3391-3397.
- SHU Hang, ZHONG Wenqi, CHEN Xi, et al. Predictive study of pressure distribution in gas-solid fluidized bed flow field based on POD and TFM [J]. *Journal of Engineering Thermophysics*, 2024, 45(11): 3391-3397.
- [14] 沙杨扬. 基于模态分解方法的串列双圆柱绕流流场特性分析 [D]. 哈尔滨: 哈尔滨工业大学, 2021.
- [15] LI Dandan, ZHAO Bidan, LU Shuai, et al. A data-driven method for fast predicting the long-term hydrodynamics of gas-solid flows: optimized dynamic mode decomposition with control [J]. *Physics of Fluids*, 2024, 36(10): 103332.
- [16] 邵昱昌, 王彤. 基于动态模式分解的离心压缩机动态流场分析 [J]. *热能动力工程*, 2018, 33(5): 55-62.
- SHAO Yuchang, WANG Tong. Dynamic flow field analysis of centrifugal compressor based onDMD [J]. *Journal of Engineering for Thermal Energy and Power*, 2018, 33(5): 55-62.
- [17] PAN Shaowu, ARNOLD-MEDABALIMI N, DURAISAMY K. Sparsity-promoting algorithms for the discovery of informative Koopman-invariant subspaces [J]. *Journal of Fluid Mechanics*, 2021, 917: A18.
- [18] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述 [J]. *计算机应用*, 2018, 38(S2): 1-6.
- YANG Li, WU Yuqian, WANG Junli, et al. Research on recurrent neural network [J]. *Journal of Computer Applications*, 2018, 38(S2): 1-6.
- [19] JIA Xuyi, GONG Chunlin, JI Wen, et al. An accuracy-enhanced transonic flow prediction method fusing deep learning and a reduced-order model [J]. *Physics of Fluids*, 2024, 36(5): 056101.
- [20] VLACHAS P R, BYEON W, WAN Zhongy, et al.

- Data-driven forecasting of high-dimensional chaotic systems with long short-term memory networks [J]. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 2018, 474(2213): 20170844.
- [21] ROWLEY C W, DAWSON S T M. Model reduction for flow analysis and control [J]. *Annual Review of Fluid Mechanics*, 2017, 49: 387-417.
- [22] TOWNE A, SCHMIDT O T, COLONIUS T. Spectral proper orthogonal decomposition and its relationship to dynamic mode decomposition and resolvent analysis [J]. *Journal of Fluid Mechanics*, 2018, 847: 821-867.
- [23] 郭子漪, 赵建福, 李凯, 等. 基于 POD-Galerkin 降维方法的热毛细对流分岔分析 [J]. *力学学报*, 2022, 54(5): 1186-1198.
- GUO Ziyi, ZHAO Jianfu, LI Kai, et al. Bifurcation analysis of thermocapillary convection based on POD-Galerkin reduced-order method [J]. *Chinese Journal of Theoretical and Applied Mechanics*, 2022, 54(5): 1186-1198.
- [24] 寇家庆, 张伟伟. 动力学模态分解及其在流体力学中的应用 [J]. *空气动力学报*, 2018, 36(2): 163-179.
- KOU Jiaqing, ZHANG Weiwei. Dynamic mode decomposition and its applications in fluid dynamics [J]. *Acta Aerodynamica Sinica*, 2018, 36(2): 163-179.
- [25] 张驰, 郭媛, 黎明. 人工神经网络模型发展及应用综述 [J]. *计算机工程与应用*, 2021, 57(11): 57-69.
- ZHANG Chi, GUO Yuan, LI Ming. Review of development and application of artificial neural network models [J]. *Computer Engineering and Applications*, 2021, 57(11): 57-69.
- [26] 杨志刚, 李侯静, 夏超, 等. 基于 LSTM-POD 的汽车湍流尾迹的高时间分辨速度场重构 [J]. *汽车工程*, 2024, 46(7): 1302-1313.
- YANG Zhigang, LI Yujing, XIA Chao, et al. A high time-resolution reconstruction on the automotive turbulent wake based on LSTM-POD [J]. *Automotive Engineering*, 2024, 46(7): 1302-1313.
- [27] 孔德天, 董义道, 张来平, 等. 基于混合神经网络的非定常流场预测方法 [J]. *四川大学学报(自然科学版)*, 2024, 61(6): 135-143.
- KONG Detian, DONG Yidao, ZHANG Laiping, et al. An unsteady flow-field prediction method based on hybrid neural network [J]. *Journal of Sichuan University (Natural Science Edition)*, 2024, 61(6): 135-143.
- [28] YU Yong, SI Xiaosheng, HU Changhua, et al. A review of recurrent neural networks: LSTM cells and network architectures [J]. *Neural Computation*, 2019, 31(7): 1235-1270.
- [29] HUANG Zhiwen, LI Tong, HUANG Kexin, et al. Predictions of flow and temperature fields in a T-junction based on dynamic mode decomposition and deep learning [J]. *Energy*, 2022, 261, Part A: 125228.
- [30] 任甲辉, 李嘉成, 樊昱豪, 等. 高压气动减压阀内部湿空气凝结特性 [J]. *液压与气动*, 2024, 48(10): 75-84.
- REN Jiahui, LI Jiacheng, FAN Yuhao, et al. Condensation characteristics of wet air within high pressure pneumatic pressure-reducing valve [J]. *Chinese Hydraulics & Pneumatics*, 2024, 48(10): 75-84.
- [31] WANG Zhikai, GONG Ka, FAN Wei, et al. Prediction of swirling flow field in combustor based on deep learning [J]. *Acta Astronautica*, 2022, 201: 302-316.
- [32] 武书弘, 邹瀚森, 姚尔人, 等. 压缩空气储能储气装置充气过程的动态热力特性研究 [J]. *西安交通大学学报*, 2025, 59(2): 41-49.
- WU Shuhong, ZOU Hansen, YAO Erren, et al. Thermodynamic characteristics of air storage device during charging process [J]. *Journal of Xi'an Jiaotong University*, 2025, 59(2): 41-49.
- [33] GUO Cong, XU Yujie, ZHANG Xinjing, et al. Performance analysis of compressed air energy storage systems considering dynamic characteristics of compressed air storage [J]. *Energy*, 2017, 135: 876-888.

(编辑 武红江)