

时序卷积网络在转子热固耦合应力预测及寿命评估中的应用

李伟业¹, 冯建欣¹, 文思果¹, 张小龙², 袁奇¹, 李浦¹

(1. 西安交通大学能源与动力工程学院, 710049, 西安; 2. 西安陕鼓动力股份有限公司, 710075, 西安)

摘要: 针对透平机械转子启动过程中,瞬态热应力由于计算成本高而难以实现快速预测的问题,提出了一种基于时序卷积网络(TCN)的压缩机转子表面温度场和应力场预测方法。采用有限元方法计算压缩机转子在冷态启动工况下的温度场、应力场和使用寿命,基于 TCN 模型开展转子的温度场和应力场预测及寿命评估,并与长短时记忆(LSTM)网络、门控循环单元(GRU)和 Transformer 3 种神经网络模型的预测结果进行对比。模拟结果表明:冷态启动工况下,TCN 模型在预测转子瞬态热应力时的性能表现最优,相较于 Transformer、LSTM 和 GRU 模型,其热应力预测决定系数分别提高了 0.03%、0.60%、0.36%,综合加载等效应力预测决定系数分别提高了 0.10%、0.48%、0.02%;与传统的有限元热固耦合分析方法相比,TCN 模型的计算效率显著提高,耗时仅为有限元方法的 0.25%。所提方法提升了预测的准确性,可为透平机械转子瞬态热应力的快速预测和寿命评估提供技术支持。

关键词: 时序卷积网络;压缩机转子;热应力;寿命评估

中图分类号: TK14 **文献标志码:** A

DOI: 10.7652/xjtuxb202510008 **文章编号:** 0253-987X(2025)10-0087-09

Application of Temporal Convolutional Network in Rotor Thermo-Mechanical Coupling Stress Prediction and Life Assessment

LI Weiye¹, FENG Jianxin¹, WEN Siguo¹, ZHANG Xiaolong², YUAN Qi¹, LI Pu¹

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

2. Xi'an Shaangu Power Co., Ltd., Xi'an 710075, China)

Abstract: To address the challenge of rapidly predicting transient thermal stress during the startup of turbomachinery rotors, which is difficult due to high computational costs, a compressor rotor surface temperature field and stress field prediction method based on temporal convolutional network (TCN) is proposed. The finite element method is utilized to compute the temperature field, stress field, and service life of the compressor rotor under cold startup conditions. A TCN model is then employed for temperature field and stress field prediction and life assessment of the rotor, and the results are compared with those obtained from three other neural network models: long short-term memory (LSTM), gated recurrent unit (GRU), and Transformer. Simulation results demonstrate that under cold startup conditions, the TCN model exhibits optimal performance in predicting transient thermal stress of the rotor. Compared to the Transformer,

收稿日期: 2025-04-02。 作者简介: 李伟业(2000—),男,硕士生;李浦(通信作者),男,副研究员,博士生导师。

基金项目: 国家自然科学基金资助项目(12372058,12372057)。

网络出版时间: 2025-06-06

网络出版地址: <https://link.cnki.net/urlid/61.1069.T.20250605.1433.002>

LSTM, and GRU models, the coefficient of determination for thermal stress predictions improves by 0.03%, 0.60%, and 0.36%, respectively, while the coefficient of determination for equivalent stress predictions under combined loading increases by 0.10%, 0.48%, and 0.02%. Moreover, the computational efficiency of the TCN model is significantly improved compared to traditional finite element thermo-mechanical coupled analysis, with a computation time only 0.25% that of the finite element method. This proposed method enhances prediction accuracy and provides technical support for the rapid prediction of transient thermal stresses and life assessment of turbomachinery rotors.

Keywords: temporal convolutional network; compressor rotor; thermal stress; lifespan assessment

转子作为汽轮机、燃气轮机、压缩机等旋转机械的关键部件,在工作过程中承受温度以及包括离心力、热应力、气动应力在内的机械载荷,不同启动工况下的温度和应力时变耦合关系复杂,很有可能导致转子热疲劳失效。因此,开展转子瞬态热应力快速预测和寿命评估,对提升设备的安全性和可靠性具有重要意义。

近年来,随着计算技术的发展,有限元分析(FEA)已广泛应用于结构强度分析和寿命预测。在涡轮转子热应力研究领域,众多学者开展了广泛深入的研究。徐宁等^[1]基于热弹耦合理论和有限元仿真,研究了涡轮转子在瞬态热冲击下的热应力。王军利等^[2]基于热固耦合数值模拟,揭示了双螺杆压缩机转子在温度载荷下的变形与应力分布规律,为压缩机优化设计提供了理论依据。曹源^[3]针对滚动活塞式压缩机的温度不均、应力集中及振动问题,提出了一种融合转子传热方程与热应力场分析的启停精准控制方法,实验验证了其控制精度的提升与运行平稳性。周祚等^[4]开展瞬态应力分析与启动曲线优化,有效降低了转子在启动过程中承受的热应力,延长了转子寿命。陈思远等^[5]以300 MW汽轮机调节级转子为对象,研究了蒸汽温度变化导致的热应力问题,结果显示稳态工况下温差达到50℃时,最大等效应力增加24%。黄朝晖等^[6]采用ANSYS流热固耦合方法,对国产液体火箭发动机涡轮泵转子的裂纹问题开展研究,结果显示裂纹的产生原因是启动时气流的冲击应力过高。上述研究为转子设计与安全评估提供了重要的理论基础。

随着人工智能和深度学习技术的迅速发展,基于神经网络的复杂多物理场快速预测已成为动力设备智能诊断和智慧运维的重要途径^[7-8]。长短时记忆(LSTM)网络作为一种经典的递归神经网络,在处理序列数据时表现出色,尤其适用于复杂机械系统的时变参数预测。Yan等^[9]开发了基于有序神经

元LSTM网络的齿轮寿命预测模型,通过提取信号中的关键频域特征预测了齿轮剩余寿命。LSTM网络在汽轮机转子热应力预测领域也得到了广泛应用。杨晨等^[10]基于LSTM网络预测汽轮机转子热应力,通过历史数据学习复杂的温度-应力关系,提高了热应力的预测精度。唐成顺等^[11]应用LSTM网络进行了转子表面应力预测。

时序卷积网络(TCN)具有多个显著优点。首先,TCN模型通过因果卷积和扩张卷积可以并行处理序列数据;其次,TCN模型能够捕捉序列中任意位置的全局依赖关系。因此,TCN模型因其强大的时序建模能力在多变量时间序列预测中表现出色,已逐渐成为研究热点。刘辉等^[12]提出了一种基于改进灰狼算法优化时序卷积网络的高压直流输电系统故障检测方法,克服了故障信号处理的繁琐过程。虞思思^[13]采用TCN、LSTM等多种网络进行了动态温度测量,结果表明TCN模型的动态温度重建精度更高。邓智等^[14]将位置编码机制和自注意力机制融入TCN模型开展实验,结果表明识别精度有了较大提升,在自治UCR-whorl数据集上,模型识别准确率达到93.41%。袁安妮等^[15]提出一种从局部与全局信息上改进时序卷积神经网络的深度学习算法,有效解决了TCN模型对数据要求高以及捕捉时序数据间相关性差的问题。唐杰等^[16]将时序卷积网络与Transformer神经网络相结合,有效提升了航空管路无扩口接头退化预测的精度和效率。

综上所述,TCN模型已广泛用于故障识别、燃气轮机转子动态响应预测以及复杂多物理场预测。由于转子不同启动工况瞬态热应力变化复杂,传统的热固耦合有限元分析往往耗时严重,因此本文针对某压缩机转子开展了不同边界条件下的热固耦合分析,阐明了热应力随时间的瞬态演化关系。基于4种神经网络模型,开展了危险点温度和应力的同

步预测,旨在为转子寿命预测和应力优化提供高效的分析方法。

1 转子建模

1.1 转子模型与边界条件

图 1 给出了压缩机转子模型示意图,其中空心转子主体部分由两端轴头及中间空心轴组成,轴头与空心轴通过螺栓连接,空心轴上分布有 18 级叶根槽。转子整体长度为 10.8 m,中间空心轴最大直径为 1.344 m。压缩机转子的材料参数如表 1 所示。



图 1 压缩机转子模型示意图

Fig. 1 Schematic diagram of compressor rotor model

表 1 压缩机转子的材料参数

Table 1 Material parameters of the compressor rotor

参数	数值
密度/($\text{kg} \cdot \text{m}^{-3}$)	7 860
弹性模量/GPa	218
泊松比	0.299
屈服强度/MPa	697
抗拉强度/MPa	780

建立转子有限元模型,转子主体部分(除螺栓外)为轴对称模型,故采用 2D 轴对称有限元模型,分析压缩机转子不同启动工况下的热固耦合应力并开展寿命评估。空心转子二维轴对称有限元模型网格如图 2 所示。单元数为 9 万,节点数为 28 万,对空心轴的齿根和接触面局部进行网格加密。



图 2 压缩机转子模型的网格划分

Fig. 2 Mesh division of the compressor rotor model

转子热固耦合计算边界条件具体设置如下。

(1)位移约束:在转子端面添加轴向位移约束,在中心线位置添加径向约束,保证静态求解无刚体位移。

(2)接触对:将轴头和转子端面、止口接触设置为绑定接触。

(3)热边界条件^[17]:转子轴颈外表面给定表面

温度的第一类边界条件,即室温 20 ℃;转子中心给定热流密度为 0 的绝热边界条件;转子外表面为与气体强制对流换热的第三类边界条件,具体如图 3 所示。换热系数的计算式为

$$h = \frac{Nu\lambda_c}{R_a} \quad (1)$$

$$Nu = 0.1Re^{0.68} \quad (2)$$

$$Re = \frac{uR_a}{\nu} \quad (3)$$

式中: h 为传热系数; Nu 为努塞尔数; Re 为雷诺数; λ_c 为气流导热系数; R_a 为光轴外缘半径; u 为外缘处圆周速度; ν 为气流运动黏度系数。

(4)等效齿根载荷:在各级叶根顶部面施加向上的拉力载荷,其值为各级叶片的等效离心力。

(5)离心力载荷:对模型整体施加工作转速对应的离心力载荷。




图 3 转子热边界条件

Fig. 3 Thermal boundary conditions of the rotor

1.2 启动工况介绍

计算冷态短时长启动工况下的转子温度、应力和寿命,冷态启动的初始温度为室温,启动工况的边界条件随时间变化,属于瞬态工况,分为 5 个阶段,如图 4 所示。过程简要介绍如下。

(1)第 1 阶段(从 0 时刻到 L0 工况):升速、升功率。该阶段内转速从 0 升至额定转速,功率从 0 升至 40% 额定功率。

(2)第 2 阶段(从 L0 工况到 L1 工况):升功率。




图 4 压缩机转子启动工况的不同阶段

Fig. 4 Different stages of compressor rotor startup conditions

该阶段内功率升至额定功率。

(3) 第 3、4 阶段(从 L1 工况降至 L2 工况,从 L2 工况降至 L3 工况):降功率。

(4) 第 5 阶段(持续 L3 工况):机组以该功率稳定运行。

2 基于 TCN 的压缩机转子应力预测及寿命评估模型

2.1 样本数据构造

本节开展了冷态短时长启动压缩机热固耦合应力分析。计算总时长为 20 ks,冷态启动过程中第 18 级叶根槽底部 A 点处容易发生疲劳损伤,温度梯度较大,热应力最大,即最危险,如图 5 所示。整个启动过程中,A 点的温度和热应力变化如图 6 所示。由图可见,转子应力先快速升高,然后又急速下降,在 5 ks 左右出现第 2 个峰值,接着继续下降,在约 20 ks 时趋于稳定,此时最大应力出现。




图 5 应力预测部位示意图

Fig. 5 Schematic diagram of stress prediction location




图 6 危险点 A 的温度和热应力随时间的变化

Fig. 6 Variation of temperature and thermal stress of danger point A with time

选取第 18 级叶根槽底部 A 点作为监测点,因其作为转子危险部位,在冷态启动过程中最易出现应力集中和疲劳损伤,是评估转子安全性的关键位置。该点的温度和应力在启动过程中会随时间变

化,相邻时间点的样本数据之间具有一定的相关性。因此,可将温度和应力预测视为时间序列建模问题,选用 TCN 模型作为基本框架,有限元仿真计算得到的冷态短时长启动危险点的应力和温度作为原始数据。为了提高模型性能和训练效率,对样本数据进行归一化处理。将数据转换到一个标准范围内,使数据在训练过程中更稳定,从而提高神经网络收敛性。本文采用最小-最大归一化将数据线性地缩放至 $[0,1]$,经过归一化处理后的数据形式可表示如下

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

式中: x 为原始数据; $x_{\min}$ 、 $x_{\max}$ 分别为数据的最小值和最大值。

经过归一化处理后的样本数据如表 2 所示,其中 t 为归一化时间, T_A 为 A 点归一化后的温度, P_A 为 A 点归一化后的应力。

表 2 归一化处理后的样本特征数据


Table 2 Normalized sample feature data

t	T_A	P_A
0	0	0
18	0.137	0.700
40	0.261	0.942
74	0.377	0.999
85	0.417	1.000
198	0.593	0.564
253	0.703	0.601
297	0.773	0.569
364	0.841	0.398
455	0.900	0.244
610	0.953	0.100
1 000	1.000	0.028

2.2 模型结构和算法设计

采用 TCN、Transformer、LSTM 和门控循环单元(GRU)模型开展压缩机转子的热应力和寿命预测。TCN 是一种处理时序数据的深度学习网络结构,可通过一系列的卷积层来处理时序数据,有效捕捉时序数据中的时间动态特征。Transformer 是一种基于自注意力机制的深度学习模型,在序列任务处理中表现出色。LSTM 是一种特殊的循环神经网络(RNN),旨在解决处理长序列数据时遇到的梯度消失和梯度爆炸问题。GRU 也是循环神经网络的一种变种,旨在解决不能长期记忆和反向传播中的梯度问题。

图 7 展示了 TCN 的模型结构^[18]。图中,输入序列时间步为 t ,每个时间步可能有多个特征^[19];因果卷积确保输出仅依赖当前和过去的时间步;空洞卷积通过空洞率 $M = 2^n$ ($n = 0, 1, 2, \dots$) 逐步扩大感受野。通过多层堆叠,TCN 模型可以覆盖更长的历史依赖,转子热应力预测中的典型历史依赖为转子整体热膨胀与局部应力集中的滞后关系,如叶根槽热量传递到轮毂的延迟。

图 7 TCN 模型结构^[18]Fig. 7 TCN model structure^[18]

由于神经网络模型的学习结果需要通过误差评价指标进行衡量,因此采用以下 3 种误差评价指标^[20]对模型训练效果进行定量评价。

均方根误差 E_{RMSE} 的计算式可写为

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

平均绝对误差 E_{MAE} 的计算式可写为

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

决定系数 R^2 的计算式可写为

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

式中: n 为样本数; y_i 为第 i 个样本的真实值; $\hat{y}_i$ 为第 i 个样本的预测值; $\bar{y}$ 为样本的平均值。

2.3 损失函数和优化算法

神经网络训练过程中,损失函数和优化算法共同作用于模型的学习和改进过程。损失函数是用于评估神经网络预测结果与真实结果之间差异的量化工具,其核心目的是指导模型的训练过程。本文采用的均方差损失函数 f_{MSE} ,连续且可导,适合于梯

度下降优化算法,且对大误差较为敏感,可有效调整模型以减少大误差的影响。其计算公式^[21-22]为

$$f_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (8)$$

优化算法通过调整神经网络的参数,使得损失函数最小化。采用自适应学习率优化算法 Adam^[23-24],结合梯度下降和动量思想更新神经网络的参数。Adam 算法在训练过程中使用梯度的一阶矩(动量)和二阶矩(方差)来调整每个参数的学习率,其计算式可写为

$$\begin{cases} m_t = \beta_1 m_{t-1} + (1 - \beta_1) \frac{\partial L}{\partial \theta} \\ v_t = \beta_2 v_{t-1} + (1 - \beta_2) \left(\frac{\partial L}{\partial \theta} \right)^2 \end{cases} \quad (9)$$

式中: m_t 为梯度一阶矩估计; v_t 为梯度二阶矩估计; L 为损失函数; θ 为模型参数; t 为迭代步数; β_1 、 β_2 为超参数,分别取 0.900 和 0.999。

为了使参数正常更新^[25],需要作出如下的偏差修正

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}; \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (10)$$

式中: $\hat{m}_t$ 、 $\hat{v}_t$ 分别为修正的梯度一阶估计值和二阶估计值; β_1^t 、 β_2^t 为当前迭代步数的超参数,分别取 0.900 ^{t} 和 0.999 ^{t} 。

Adam 算法对神经网络参数进行更新的公式为

$$\theta_{t+1} = \theta_t - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \quad (11)$$

式中: θ_{t+1} 为更新后参数向量; θ_t 为当前参数向量; α 为神经网络模型的学习率; ϵ 为数值稳定项,取 10^{-8} 。

构建预测模型后,设置超参数进行模型训练。具体为:学习率为 0.001,迭代次数为 10 000,批处理大小为 16,时间步长为 75。图 8 展示了训练过程中 4 种预测模型损失函数的变化情况。从图中可以看出,在同等遍历次数下,TCN 模型总体来说损失函数值最小,说明其收敛速度较快且具有较高的稳定性。相比之下,Transformer 和 LSTM 模型的损失函数下降较为缓慢,且在整个训练过程中波动较大。GRU 模型的表现介于 Transformer 和 TCN 模型之间,初始损失下降较快,但后续训练中存在较大波动。总体而言,TCN 模型损失函数的下降速度更快、最终损失值更低且更稳定,因此在 4 种预测模型中具有更优的预测性能。




图 8 预测模型训练过程损失函数的变化

Fig. 8 Changes in loss function during prediction model training process

2.4 寿命预测理论

采用局部应力-应变法预测压缩机转子的低周疲劳寿命^[26], 计算思路为: 转子存在应力集中的部位由于反复发生塑性形变而产生初始疲劳裂纹, 进而发展为疲劳断裂, 因而其疲劳寿命的决定因素主要是这些危险点。局部应力-应变法可分为对称循环计算法和非对称循环计算法, 本文采用对称循环法来计算空心转子的低周疲劳寿命。转子材料的应力-应变关系式可表示为

$$\epsilon_a = \frac{\Delta\sigma}{E} + \left(\frac{\Delta\sigma}{1200} \right)^{1/0.076} \quad (12)$$

式中: ϵ_a 、 $\Delta\sigma$ 分别为循环应变和循环应力幅值; E 为弹性模量。

实际循环应变幅值和总应变关系如下

$$\frac{\Delta\epsilon}{2} = \frac{\epsilon_{\max} - \epsilon_{\min}}{2} = \epsilon_a \quad (13)$$

式中: $\Delta\epsilon$ 为循环总应变; $\epsilon_{\max}$ 、 $\epsilon_{\min}$ 分别为最大和最小循环应变。

根据材料 $\epsilon-N$ 之间的关系计算转子的疲劳寿命, 表示为

$$\Delta\epsilon = 0.0067 (2N)^{-0.073} + 0.54 (2N)^{-0.88} \quad (14)$$

$$d = \frac{1}{2N} \quad (15)$$

式中: N 为低周疲劳裂纹的循环次数; d 为一次启、停工的低周疲劳裂纹萌生寿命损耗。


3 预测结果与分析

基于压缩机转子冷态启动的有限元模拟结果, 采用危险部位的瞬态温度-应力数据构建预测模型。这些数据可以按启动时间范围进行分类。选取训练数据的 20% 作为测试集^[27]。为了排除启动初期和末期的干扰, 构建训练集和测试集时排除了启动时


间范围前、后各 1% 的数据。

3.1 冷态工况下的温度和应力预测

冷态短时长启动工况下, 采用 TCN、Transformer、LSTM、GRU 模型预测的和有限元分析得到的转子危险点 A 的温度和应力对比如图 9 所示。



(a) 温度



(b) 热应力

图 9 冷态短时长启动工况下温度和热应力的网络模型预测结果与有限元结果的对比

Fig. 9 Comparison of network model prediction results and finite element results for temperature and thermal stress under cold short-duration start-up condition

由图 9 可以看出, 对于温度预测, TCN 模型的预测结果与有限元结果最为接近, 且随着时间变化持续保持准确性, 其他 3 种模型预测结果与有限元结果存在差异, 尤其是在稳态期间。应力预测中, TCN 模型的预测结果与有限元仿真数据高度吻合, 尤其是在其他模型差异更大的危险位置。这种强大的性能在放大部分区域尤为明显, 表明 TCN 模型能够高精度地捕捉应力的突然变化。

仿照热应力预测方法, 对综合加载等效应力进行预测, 得到的转子危险点 A 的温度和应力对比如图 10 所示。





图 10 冷态短时长启动工况下综合加载等效应力的网络模型预测结果与有限元结果的对比

Fig. 10 Comparison of network model prediction results and finite element results for the comprehensive loading equivalent stress under cold short-duration startup condition


由图 10 可以看出,TCN 模型的预测结果与有限元仿真数据高度吻合,尤其是在其他模型差异更大的危险位置。这种强大的性能在放大区域尤为明显,表明 TCN 模型能够高精度地捕捉应力的突然变化。

3.2 预测指标量化结果

采用平均绝对误差 E_{MAE} 、均方根误差 E_{RMSE} 、决定系数 R^2 3 种评价指标对 4 种神经网络预测模型的训练效果进行定量评价,得到的结果如图 11 所示。由图可见,在两种应力预测模型下,TCN 模型的 E_{MAE} 与 E_{RMSE} 均明显低于 Transformer、LSTM 和 GRU 模型;对于决定系数 R^2 ,TCN 模型在所有工况下的表现也呈现最优,即 R^2 越接近 1,表明 TCN 模型能够更好捕捉有限元数据中所有系统性变化(如温度上升导致的应力非线性增长)。预测结果与实际结果高度吻合,表明 TCN 模型在处理数据时具有更好的预测能力和精度。



(a) 热应力预测结果误差对比



(b) 综合加载等效应力预测结果误差对比

图 11 冷态启动工况下预测与仿真结果误差评价指标的对比

Fig. 11 Comparison of error evaluation indices obtained by prediction and simulation under cold startup condition

3.3 寿命预测结果

采用 4 种神经网络模型预测转子危险点 A 的疲劳寿命,并与有限元结果进行对比,如图 12 所示。由图可见,LSTM 模型的预测效果较差,TCN、Transformer、GRU 模型的预测效果相对较好,但 TCN 模型无疑是表现最为出色的神经网络模型,其在危险点 A 疲劳寿命预测更接近有限元结果。




图 12 冷态启动工况下疲劳寿命的神经网络模型预测结果与有限元结果对比

Fig. 12 Comparison of neural network prediction and finite element results for fatigue life under cold startup condition

表 3 给出了预测模型与有限元方法计算热应力的耗时对比。由表可见,采用 TCN 模型进行预测,单个启动工况的耗时在 6 s 左右,而采用有限元方法时,计算耗时在 40 min 左右。这表明本文所构建的预测模型能够快速预测压缩机转子的危险点温度、应力和寿命。

表 3 预测模型与有限元方法的耗时对比

Table 3 Comparison of time consumption between the prediction model and the finite element method

模型	预测时间/min	训练时间/min
TCN	0.1	5
Transformer	0.1	10
LMST	0.1	6
GRU	0.1	5
有限元	40.0	

4 结 论

本文建立了基于 TCN 的冷态启动工况压缩机转子表面温度、应力、寿命预测模型,提出了快速预测转子表面温度、应力、寿命的分析方法,并与其他神经网络模型的预测结果进行对比,得到如下主要结论。

(1)开展冷态启动工况下的压缩机转子瞬态热固耦合分析,发现最大热应力出现在压缩机第 18 级叶根槽倒圆角位置,这是由于此处的温度梯度较大所导致的。

(2)提出了一种基于 TCN 模型的压缩机转子表面温度场和应力场同步预测方法,并与 LSTM、GRU 和 Transformer 这 3 种神经网络模型进行对比,结果表明,TCN 模型在冷态启动预测转子瞬态热应力方面具有显著优势,相较于 Transformer、LSTM 和 GRU 模型,热应力预测平均绝对误差分别降低了 2.63%、51.74%、47.89%,均方根误差分别降低了 6.93%、42.67%、34.00%,决定系数分别提高了 0.03%、0.60%、0.36%;综合加载等效应力预测平均绝对误差分别降低了 50.0%、77.9%、14.3%,均方根误差分别降低了 4.96%、13.40%、1.07%,决定系数分别提高了 0.10%、0.48%、0.02%。

(3)基于局部应力-应变法开展了冷态启动工况危险点寿命预测,发现相较于其他模型,TCN 模型的寿命预测结果与有限元结果最为接近,误差仅为 4.9%,这表明该模型能准确预测压缩机转子冷态启动危险点的应力应变规律,计算效率得到显著提高。

参考文献:

- [1] 徐宁,王庆超,刘占生,等. 基于热弹耦合的涡轮转子瞬态热冲击研究 [J]. 哈尔滨工程大学学报, 2016, 37(7): 936-942.
- XU Ning, WANG Qingchao, LIU Zhansheng, et al.

Transient thermal impact research on turbine rotors based on thermoelastic coupling [J]. Journal of Harbin Engineering University, 2016, 37(7): 936-942.

- [2] 王军利,陆正午,李庆庆,等. 基于热分析的双螺杆压缩机转子的应力疲劳研究 [J]. 机械强度, 2021, 43(4): 928-935.
- WANG Junli, LU Zhengwu, LI Qingqing, et al. Research on stress fatigue of twin screw compressor rotor based on thermal analysis [J]. Journal of Mechanical Strength, 2021, 43(4): 928-935.
- [3] 曹源. 滚动活塞式压缩机转子精准启停控制方法 [J]. 机械与电子, 2025, 43(4): 45-51.
- CAO Yuan. Precise start stop control method for rolling piston compressor rotor [J]. Machinery & Electronics, 2025, 43(4): 45-51.
- [4] 周祚,李嘉,曾帆,等. 周向拉杆转子瞬态应力分析与启动曲线优化 [J]. 舰船科学技术, 2022, 44(11): 125-131.
- ZHOU Zuo, LI Jia, ZENG Fan, et al. Transit stress analysis and start-up curve optimization of a circumferential distributed rod fastening rotor [J]. Ship Science and Technology, 2022, 44(11): 125-131.
- [5] 陈思远,黄畅,王卫良,等. 面向新型电力系统汽轮机高压转子蠕变/疲劳寿命损耗研究 [J]. 热力发电, 2024, 53(10): 106-113.
- CHEN Siyuan, HUANG Chang, WANG Weiliang, et al. Research on creep/fatigue life of high pressure rotor in steam turbine for new power systems [J]. Thermal Power Generation, 2024, 53(10): 106-113.
- [6] 黄朝晖,袁奇,张弘斌,等. 某型火箭发动机涡轮转子流热固耦合强度及疲劳寿命分析 [J]. 西安交通大学学报, 2022, 56(8): 73-84.
- HUANG Chaohui, YUAN Qi, ZHANG Hongbin, et al. Analysis of fluid-thermal-solid coupling strength and fatigue life of a certain rocket engine turbine rotor [J]. Journal of Xi'an Jiaotong University, 2022, 56(8): 73-84.
- [7] 夏雪,闫恩来,李喜武. Transformer 在时间序列预测中的应用综述 [J]. 信息技术与信息化, 2024(3): 124-128.
- XIA Xue, YAN Enlai, LI Xiwu. Overview of the application of transformer in time series prediction [J]. Information Technology & Informatization, 2024(3): 124-128.
- [8] 孟祥福,石皓源. 基于 Transformer 模型的时序数据预测方法综述 [J]. 计算机科学与探索, 2025, 19(1): 45-64.
- MENG Xiangfu, SHI Haoyuan. Survey of transform-

- er-based model for time series forecasting [J]. Journal of Frontiers of Computer Science & Technology, 2025, 19(1): 45-64.
- [9] YAN Haoran, QIN Yi, XIANG Sheng, et al. Long-term gear life prediction based on ordered neurons LSTM neural networks [J]. Measurement, 2020, 165: 108205.
- [10] 杨晨, 柴京, 张涛, 等. 基于 LSTM 网络的汽轮机转子热应力预测方法 [J]. 计算机仿真, 2023, 40(2): 123-127.
- YANG Chen, CHAI Jing, ZHANG Tao, et al. Prediction method of steam turbine rotor thermal stress based on long-short-term memory network [J]. Computer Simulation, 2023, 40(2): 123-127.
- [11] 唐成顺, 孙丹, 唐威, 等. 基于 LSTM 循环神经网络的汽轮机转子表面应力预测模型 [J]. 中国电机工程学报, 2021, 41(2): 451-460.
- TANG Chengshun, SUN Dan, TANG Wei, et al. A turbine rotor surface stress prediction model based on LSTM recurrent neural network [J]. Proceedings of the CSEE, 2021, 41(2): 451-460.
- [12] 刘辉, 李永康, 张森, 等. 基于 GWO-TCN 网络的 HVDC 输电线路故障诊断 [J]. 电子测量技术, 2021, 44(22): 168-174.
- LIU Hui, LI Yongkang, ZHANG Miao, et al. Fault diagnosis of HVDC transmission lines based on GWO-TCN networks [J]. Electronic Measurement Technology, 2021, 44(22): 168-174.
- [13] 虞思思. 卷积神经网络在动态温度测量中的应用 [D]. 杭州: 中国计量大学, 2022.
- [14] 邓智, 王正勇, 何小海, 等. 基于改进 TCN 的上扣扭矩序列数据分类 [J]. 电子测量技术, 2024, 47(18): 1-8.
- DENG Zhi, WANG Zhengyong, HE Xiaohai, et al. Classification of make-up torque sequence data based on improved TCN [J]. Electronic Measurement Technology, 2024, 47(18): 1-8.
- [15] 袁安妮, 邹春明, 王勇, 等. 基于改进 TCN 的多元时间序列异常检测算法 [J]. 计算机工程与设计, 2025, 46(2): 416-422.
- YUAN Anni, ZOU Chunming, WANG Yong, et al. Multivariate time series anomaly detection algorithm based on improved TCN [J]. Computer Engineering and Design, 2025, 46(2): 416-422.
- [16] 唐杰, 孙茹. 航空管路无扩口管接头寿命预测方法研究 [J]. 重庆理工大学学报(自然科学), 2025, 39(2): 154-162.
- TANG Jie, SUN Ru. Study on life prediction method of aviation flareless pipe joint [J]. Journal of Chongqing University of Technology (Natural Science), 2025, 39(2): 154-162.
- [17] 史进渊, 杨宇, 邓志成, 等. 大功率电站汽轮机寿命预测与可靠性设计 [M]. 北京: 中国电力出版社, 2011.
- [18] 张蕾, 季媛媛, 李娜, 等. 基于 TCN 与双重注意力机制的光伏功率预测模型 [J/OL]. 计算机技术与发展. (2025-03-10) [2025-04-27]. <https://doi.org/10.20165/j.cnki.ISSN1673-629X.2025.0045>.
- ZHANG Lei, JI Yuanyuan, LI Na, et al. A photovoltaic power prediction model based on TCN and double attention mechanism [J/OL]. Computer Technology and Development (2025-03-10) [2025-04-27]. <https://doi.org/10.20165/j.cnki.ISSN1673-629X.2025.0045>.
- [19] 李吉生, 于艇, 岳鹏, 等. 一种基于 TCN 的核电蓄电池异常检测方法 [J]. 软件导刊, 2025, 24(5): 40-45.
- LI Jisheng, YU Ting, YUE Peng, et al. An anomaly detection method for nuclear power storage batteries based on TCN [J]. Software Guide, 2025, 24(5): 40-45.
- [20] HEATON J. Ian Goodfellow, Yoshua Bengio, and Aaron Courville: deep learning [J]. Genetic Programming and Evolvable Machines, 2018, 19(1): 305-307.
- [21] 王竹晴. 基于神经网络的锂离子电池 RUL 预测方法研究 [D]. 太原: 中北大学, 2019.
- [22] KÖRDING K P, WOLPERT D M. The loss function of sensorimotor learning [J]. Proceedings of the National Academy of Sciences, 2004, 101(26): 9839-9842.
- [23] KINGMA D P, BA J L. Adam: a method for stochastic optimization [EB/OL]. (2014-12-22) [2025-01-12]. <https://arxiv.org/abs/1412.6980v1>.
- [24] 李敏, 李红娇, 陈杰. 差分隐私保护下的 Adam 优化算法研究 [J]. 计算机应用与软件, 2020, 37(6): 253-258.
- LI Min, LI Hongjiao, CHEN Jie. Adam optimization algorithm based on differential privacy protection [J]. Computer Applications and Software, 2020, 37(6): 253-258.
- [25] LIU Mingliang, GRANA D. Accelerating geostatistical seismic inversion using TensorFlow: a heterogeneous distributed deep learning framework [J]. Computers & Geosciences, 2019, 124: 37-45.
- [26] 周祚. 50 MW 燃气轮机转子瞬态热应力与结构优化研究 [D]. 西安: 西安交通大学, 2016.
- [27] HARRINGTON P. Machine learning in action [M]. Beijing: Posts & Telecom Press, 2018: 15-31.

(编辑 李慧敏)