

基于神经网络的螺杆膨胀机发电变工况预测方法研究

史松伟¹, 王 昇¹, 赵 诚¹, 孙站望², 徐 旭², 朱万里²

¹绍兴上虞杭协热电有限公司, 浙江 绍兴

²中国计量大学能源环境与安全工程学院, 浙江 杭州

收稿日期: 2025年6月3日; 录用日期: 2025年6月25日; 发布日期: 2025年7月4日

摘 要

螺杆膨胀机是余压发电系统的重要动力设备, 为了获得螺杆膨胀机发电系统的较优运行工况, 本文提出了基于BP神经网络模型、广义回归神经网络模型和卷积神经网络模型的螺杆膨胀机变工况的预测方法, 并对三种神经网络模型的预测性能进行了比较分析。预测结果表明: 广义回归神经网络模型的预测效果最为理想, 卷积神经网络模型预测结果的偏差较大, 它们对螺杆膨胀机的功率和发电量预测的平均相对误差分别为4.07%、4.93%、39.32%和8.34%、12.14%、39.39%。将螺杆膨胀机的功率和发电量分为较高、中等和较低三个范围, 采用广义回归神经网络模型预测了相应范围的入口蒸汽流量、蒸汽压力和蒸汽温度, 最终对螺杆膨胀机发电的运行工况进行了优化, 这对于螺杆膨胀机发电系统的节能减排具有重要意义。

关键词

螺杆膨胀机, 余压发电, 神经网络, 运行工况

Research on Prediction Method of Power Generation Variable Condition of Screw Expander Based on Neural Network

Songwei Shi¹, Sheng Wang¹, Chen Zhao¹, Zhanwang Sun², Xu Xu², Wanli Zhu²

¹Shaoxing Shangyu Hangzhou Association Thermal Power Co., Ltd., Shaoxing Zhejiang

²College of Energy Environment and Safety Engineering, China Jiliang University, Hangzhou Zhejiang

Received: Jun. 3rd, 2025; accepted: Jun. 25th, 2025; published: Jul. 4th, 2025

Abstract

The screw expander is a critical power equipment in the residual pressure power generation

文章引用: 史松伟, 王昇, 赵诚, 孙站望, 徐旭, 朱万里. 基于神经网络的螺杆膨胀机发电变工况预测方法研究[J]. 动力系统与控制, 2025, 14(3): 221-236. DOI: 10.12677/dsc.2025.143023

system. To obtain the optimal operating conditions of the screw expander power generation system, this paper proposes a prediction method for the variable operating conditions of the screw expander based on the BP neural network model, the generalized regression neural network model and the convolutional neural network model. It conducts a comparative analysis of the prediction performance of the three neural network models. The prediction results show that the prediction effect of the generalized regression neural network model is the most ideal. In contrast, the deviation of the prediction results of the convolutional neural network model is relatively large. The average relative errors of their predictions for the power and power generation of the screw expander are 4.07%, 4.93%, 39.32% and 8.34%, 12.14%, 39.39% respectively. The power and power generation of the screw expander were divided into three ranges: high, medium and low. The generalized regression neural network model was adopted to predict the corresponding range of inlet steam flow, steam pressure, and steam temperature. Finally, the operating conditions of the screw expander power generation were optimized, which is of great significance for energy conservation and emission reduction of the screw expander power generation system.

Keywords

Screw Expander, Residual Pressure Power Generation, Neural Network, Operating Conditions

Copyright © 2025 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

近年来, 基于螺杆膨胀机发电的蒸汽余压节能技术得到了热电企业的广泛关注, 其作为一种新型的节能机械, 可为当今企业节约能源、降低成本和提高经济效益[1], 开源节流将成为企业未来能源发展的战略核心[2]。通过研究如何优化螺杆膨胀机发电系统, 使其在合理工况范围内高效运行, 为节能减排政策做出一定程度的贡献, 成为重要话题之一。

为解决以上出现的问题, 国内外学者对螺杆机做了相关研究, 并给出了相应优化方案。鉴于传统的转子制造工艺通常存在加工周期长、成型精度低的问题, 张成虎[3]等人采用网格划分序列法计算, 采用积分求解方法, 获得了双螺杆膨胀机的转子轮廓和啮合规律, 武萌[4]和付洁[5]对螺杆膨胀机的转子型线和结构方面给出了优化方案。在大膨胀比工况下, 作用在螺杆上的轴向力和径向力可能会急剧增加, 导致轴承磨损加剧、设备运行可靠性降低。因此, 肖文明[6]提出了一种可消除膨胀机转子轴向力的平衡式双螺杆膨胀机。由于螺杆膨胀机在设计时螺杆与壳体之间存在一定的间隙, 会导致工质泄漏的问题, 其中赵兆瑞[7]等人开发了一种优化双螺杆膨胀机轮廓的新方法, 刁安娜[8]等人认为合理减小膨胀机齿顶间隙是提高容积效率最有效的途径。为应对部分膨胀机对工质的适应性较差的问题, 周岳[9]等人根据螺杆膨胀机的特性提出了有机工质的筛选准则, Papes [10]通过 3D-CFD 分析了螺杆膨胀机吸气压力损失的问题, 何永宁[11]等人实验测量了在不同工况下 R245fa 的压力损失值, 并讨论了其对吸力系数的影响, Nikolov [12]设计了一种不带定时齿轮的注油双螺杆膨胀机, 并在以 R245fa 为工质的 ORC 发电系统中进行了实验研究。此外, 螺杆机在运行过程中还需要考虑到变工况的影响。卢鑫海[13]提出了一种速度型的膨胀机的结构形式, 为膨胀机能够适应工质变工况做功的条件为热力发电的正向热力循环系统在变工况的运行条件下提供了选择方案, 赵丽[14]等人分析了膨胀机多工况仿真计算模型与结果, 并认为膨胀机不在设计工况下运行也能保持比较高的效率。上述文献, 研究学者通过探索螺杆膨胀机的新型结构, 结合

数值模拟与实验验证等方法,提升了螺杆膨胀机的效率、可靠性和适应性。但是,对螺杆膨胀机变工况下的实时调节策略仍需深化。

由于计算机技术的进步和社会需求的变化,神经网络在许多领域的预测任务中逐渐取代了传统的统计方法,成为一种主流的选择。某些电力系统可通过误差反向传播神经网络(Back Propagation Neural Network, BPNN)来预测其工作特性,例如,寇文珍等人[15]通过 BPNN 与遗传算法的方法预测了光伏电站的发电功率;苏世杰等人[16]基于 BPNN 对电力负荷的概率密度进行预测,提高了预测精度。也可通过广义回归神经网络(Generalized Regression Neural Network, GRNN)对电力系统进行预测,张二辉等人[17]基于 GRNN 的风力发电场设备温度自适应预测方法,使预测值更接近实际值;全新宇[18]基于 GRNN,建立了有源配电网网供负荷预测的模型,验证了所提方法具有更高的预测准确性。卷积神经网络(Convolutional Neural Network, CNN)也可对电力系统的工作特性进行预测,如吴强[19]运用 CNN 预测了电力系统长期和短期负荷状态;周飞燃等人[20]采用了 CNN-LSTM-Attention 神经网络构建主蒸汽温度预测模型对未来时刻主蒸汽温度的变化进行了预测。通过上述研究可知,神经网络模型在预测方面相较于其他统计方法具有一定优劣,优势在于其擅长处理复杂的非线性关系,可自动提取数据特征,可适应高维大数据,在图像、语音等领域表现突出。劣势包括依赖大量数据且训练时间长,模型解释性差(黑箱问题),小样本条件或需透明决策时表现可能不佳。因此,神经网络预测适用于数据量大、模式复杂的场景。但是,目前研究学者大多通过单一神经网络模型对发电系统进行预测,无法增强模型泛化能力、缺乏准确性,也不能够为优化模型的选择提供多视角评估。

因此,针对螺杆膨胀机变工况电力性能预测的问题,本文首先采用模糊数学理论,计算入口蒸汽压力和蒸汽温度这两个敏感因素分别对功率和发电量的影响权重。随后,基于三种神经网络模型,通过主要工况的蒸汽参数,对螺杆膨胀机的输出功率及发电量进行理论预测。最后,选择预测性能最优的神经网络模型对螺杆膨胀机的运行工况进行优化。

2. 螺杆膨胀机发电系统

螺杆膨胀机是螺杆压缩机的逆运转机器[21],基于容积式膨胀原理的高效热能回收装置,主要由一对螺杆转子、缸体、轴承、同步齿轮等部件组成[22]。其核心为精密啮合的阴阳转子,通过工质在转子槽容积变化过程中发生膨胀做功,将热能转化为机械能。工作原理可大致分为四个阶段:进气阶段,高压工质进入转子腔;膨胀阶段,转子旋转使容积扩大,工质压力降低并推动转子旋转;排气阶段,低压工质排出;密封阶段,转子继续旋转完成工质隔离,形成连续循环。其膨胀过程接近等熵膨胀,热力学效率可达 70%~85%。本文所研究的蒸汽压差螺杆膨胀机发电热力系统主要由螺杆膨胀机和发电机等装置组成,如图 1 所示。压缩空气从进汽管道输出后从而进入螺杆膨胀机,最终推动螺杆膨胀机的齿轮完成膨胀做功,做功时齿轮转子带动发电机发电,做功结束后的气体通过排气管道排出室外。蒸汽进入系统机组发电或拖动水泵等设备膨胀做功降压后,进入低压分汽缸送至工艺设备使用。热用户仅将减压阀改作系统旁路备用。为保证螺杆膨胀机发电稳定,机组采用性能可靠的机械液压调节系统来控制螺杆机的转速,当热电厂供汽干管的蒸汽压力变化或者热用户用汽量的变化引起发电负荷的增加或减少时,螺杆膨胀机可通过调速系统的调节,使机组转速维持不变,从而保证机组发电和频率始终恒定。

螺杆膨胀机在特性方面具有三大技术优势:首先,其适应性强,可处理气液两相流及低品位热源,对工质种类兼容性高;其次,其结构紧凑且转速低,无需复杂减速机构,运行稳定性优于传统汽轮机;第三,螺杆膨胀机采用非接触式密封技术,阴、阳转子间隙通过油膜实现动态密封,磨损小且维护成本低。此外,其负荷性能优异,在较高负荷范围内的效率波动小于 5%,适合工业余热波动场景。并且,螺杆膨胀机的热电转换效率较传统蒸汽轮机提升明显,成为分布式能源系统的关键装备。




Figure 1. Diagram of the power generation system of the vapor differential pressure screw expander
图 1. 蒸汽压差螺杆膨胀机发电系统图

3. 神经网络模型

神经网络是一个结构巨量并行，信息分布存储、全局作用的网络，网络的信息处理由神经元之间的相互作用所完成[23]。

3.1. BP 神经网络模型

BPNN，即误差反向传播神经网络，是神经网络模型中应用最广泛的一种[24]。BPNN 通过信号的正向传播与误差的反向传播两个阶段，使神经元间的权值得到不断的修正，当误差满足精度要求时，停止计算[25]。如图 2 所示，BPNN 由输入层、隐藏层和输出层 3 部分组成。其中，输入层分别为入口蒸汽流量、蒸汽压力和蒸汽温度三个变工况，输出层输出螺杆膨胀机的功率与发电量的预测结果。对隐藏层创建一个含有 10 个隐藏神经元的前馈网络，隐藏层起到了对输入数据进行特征提取和转换的作用。




Figure 2. Schematic diagram of the BP neural network
图 2. BP 神经网络示意图

BPNN 的输出预测结果如下：

$$y_n = \sum_{n=1}^s f \left(\sum_{i=1}^l w_{ij} x_i - b_j \right) n_{jk} - a_c \quad (1)$$

式中： y_n ——预测输出结果； f ——激活函数； w_{ij} ——第 i 个神经元到第 j 个神经元的连接权重； x ——输入层第 i 个神经元的输出结果； b_j ——第 j 个神经元的偏置； n_{jk} ——隐含层第 j 个神经元与输出层第 k 个神经元的连接权值； a_c ——输出层第 c 个神经元的阈值； l ——隐藏层神经元个数； s ——输出层神经元个数。

3.2. 广义回归神经网络

GRNN，它是一种径向基神经网络[26]。广义回归算法是处理多个变量之间数据关系的数理统计方法，

即根据统计数据建立因变量(Y)与 k 个自变量($x_1, x_2, x_3, x_4, \dots, x_k$)之间线性相关的近似数学表达式[27]。GRNN 模型一般由输入层、模式层、求和层、输出层组成, 如图 3 所示。




Figure 3. Generalized regression neural network schematic

图 3. GRNN 原理图

设变工况参数 X 和输出参数 y 的联合概率密度函数为 $f(X, y)$, Y 为输入为 X 条件下的理论预测输出:

$$Y = E[y|X] = \frac{\int_{-\infty}^{+\infty} y f(X, y) dy}{\int_{-\infty}^{+\infty} f(X, y) dy} \quad (2)$$

对于未知的概率密度函数 $f(X, y)$, 可以由样本观测值估计得到:

$$f(X, y) = \frac{1}{(2\pi)^{(n+1)/2} \sigma^{n+1} n} \sum_{i=1}^m e^{\left[\frac{(X-X_i)(X-X_i)^T}{2\sigma^2} \right]} e^{\left[\frac{(X-Y)^2}{2\sigma^2} \right]} \quad (3)$$

式中: σ ——平滑参数; X_i , Y ——随机变量样本观测值; m ——变工况参数数量; n ——随机变量的维数。

3.3. 卷积神经网络

CNN 是一种前馈人工神经网络[28]。CNN 主要由输入层、卷积层、池化层、全连接层、输出层构成。输入层输入变工况参数, 卷积层提取功率和发电量的局部特征, 池化层用于降低输入参数的维度有助于控制过拟合, 全连接层将前面层提取的特征映射到输出空间, 最后由输出层输出发电性能的理论预测结果。

CNN 模型的激活函数有 Tanh 函数、ReLU 函数和 Leaky ReLU 函数等。其中 Tanh 函数的输出范围为 $(-1, 1)$, 其表达式为:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$

ReLU 函数可以有效抑制梯度消失, 其输出范围为 $(0, +\infty)$ 。其表达式为:

$$f(x) = \begin{cases} \max(0, x), & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (5)$$

Leaky ReLU 函数在 ReLU 函数的基础上对负值部分增加了一个线性系数, 避免输入负值时网络参数无法正常更新, 其表达式为:

$$f(x) = \begin{cases} x, & x \geq 0 \\ ax, & x < 0 \end{cases} \quad (6)$$

4. 结果与分析

4.1. 蒸汽参数对发电性能的敏感度分析

为了进一步认识蒸汽参数对螺杆膨胀机发电性能的影响, 本节基于蒸汽压差螺杆膨胀机发电热力系统获得的实验数据, 采用模糊数学理论[29]对入口蒸汽流量、蒸汽压力和蒸汽温度对功率和发电量的影响权重进行研究。模糊数学理论根据参数对研究对象所起作用的不同进行分类(促进或阻碍作用), 其计算方法如下[30]:

4.1.1. 选取指标及建立指标特征矩阵

根据研究内容选取相应的影响因素建立相关指标的特征矩阵。设 m 种状态下, 以某两个影响指标(如入口蒸汽压力和蒸汽温度)对螺杆机功率和发电量进行评估。则 m 种状态下的 2 个指标特征值矩阵为

$$X = [x_{ij}]_{2 \times m} \quad (7)$$

4.1.2. 隶属度矩阵 T

指标矩阵中的各指标根据其对研究对象的影响不同, 采用不同的方式进行处理。考虑到本实验研究的敏感因素(入口蒸汽压力和蒸汽温度)对功率和发电量均属于越大越优型, 因此都采取效益型相对隶属度计算公式。对于越大越优型指标, 取 j 的指标 i 的标准最大特征值 x_{ij} 对优的指标相对隶属度为 1, 取指标标准特征值最小值对优的指标相对隶属度为 0, 从而构成指标连续、统一的两级。相对隶属度计算公式为:

$$r_{ij} = \frac{x_{ij} - x_{\min}}{x_{\max} - x_{\min}} \quad (8)$$

根据上述方法, 指标特征矩阵转化为隶属度矩阵 T

$$T = [t_{ij}]_{2 \times n} \quad (9)$$

4.1.3. 选取合适的权重矩阵

指标特征矩阵中各指标对研究对象的影响程度, 一般而言并不相同, 有些指标影响程度大一些, 而有些指标影响相对较小一些。根据指标影响程度, 建立权重矩阵, 权重矩阵中同一列各指标的权重系数和必为 1。

$$W = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2n} \end{bmatrix} \quad (10)$$

4.1.4. 二级模糊式识别模型

选取二级模糊模式识别模型对权重矩阵与隶属度矩阵进行计算。功率或发电量 j 与影响因素的广义

海明权距离分别为 d_{jg} , d_{jb} (下标 g 和 b 分别表示优、劣)。

$$d_{jg} = \sum_{i=1}^m w_j (1 - r_{ij}) = 1 - \sum_{i=1}^m w_j r_{ij} \quad (11)$$

$$d_{jb} = \sum_{i=1}^m w_j (r_{ij} - 0) = \sum_{i=1}^m w_j r_{ij} \quad (12)$$

设功率或发电量 j 对优的相对隶属度以 u_j 表示; 对劣的相对隶属度以 u_j^c 表示, 按模糊集合的余集定义, 有

$$u_j^c = 1 - u_j \quad (13)$$

由模糊集合理论中广义权重的定义, 功率或发电量 j 对优的权距离为

$$D_{jg} = u_j d_{jg} \quad (14)$$

对劣的权距离为

$$D_{jb} = (1 - u_j) d_{jb} \quad (15)$$

为建立优化准则, 功率或发电量 j 的加权距劣距离平方的总和最小, 则指标函数为

$$u_j = \frac{1}{1 + \left[\frac{1 - \sum_{i=1}^m w_j r_{ij}}{\sum_{i=1}^m w_j r_{ij}} \right]^2} = \frac{1}{1 + \left(\frac{d_{jg}}{d_{jb}} \right)^2} \quad (16)$$

通过计算可知, 入口蒸汽压力与蒸汽温度两个敏感因素对螺杆机轴功率的影响权重系数分别为 0.6136 与 0.3864, 而对系统发电量的影响权重系数分别为 0.7458 与 0.2542。以上结果表明, 入口蒸汽压力和蒸汽温度对发电性能的影响均属于越大越优型并为后文提供了理论依据。同时, 可以发现蒸汽温度对发电性能的贡献不如蒸汽压力的显著。在本研究的工况范围内, 蒸汽的焓值主要取决于其压力和相态(饱和蒸汽或过热蒸汽), 相较于蒸汽温度, 蒸汽的焓降对蒸汽压力的变化更为敏感, 当入口蒸汽压力增加时, 一方面, 蒸汽的焓值随之增加, 从而导致螺杆机膨胀过程中释放更多能量来提高输出功率。另一方面, 由于蒸汽温度的变化对蒸汽流量的影响较小, 而蒸汽压力的提高会显著增加蒸汽的密度和蒸汽流量, 所以蒸汽压力的增加能够保证螺杆膨胀机输出较高的轴功率。

4.2. 基于变工况运行的发电性能预测

本文研究对象为 LGP1600-SB 型螺杆膨胀机, 记录机组 325 h 实际运行数据, 记录周期为 1 h, 采集数据包括螺杆膨胀机的入口蒸汽流量、蒸汽压力、蒸汽温度、膨胀机功率、发电量, 共记录 325 组有效数据。分别用 BPNN、GRNN、CNN 通过记录的实验数据预测螺杆膨胀机的功率与发电量。以入口蒸汽流量、蒸汽压力和蒸汽温度作为输入参数并通过综合分析, 系统评价了三种神经网络模型的预测性能。

图 4 和图 5 分别为不同神经网络对功率和发电量的理论预测。

观察图 4 可知, 三种神经网络都可预测出功率实验数据的大致变化趋势, 但 CNN 存在较大偏差, BPNN 和 GRNN 预测曲线更贴近功率的实验数据, 表明这两种神经网络具有有效的泛化能力。由图 5 可知, CNN 无法预测出发电量实验数据的大致变化趋势, 而 BPNN 和 GRNN 可预测出发电量的大致变化趋势, 但 BPNN 预测曲线存在较大偏差, 预测性能较差。因此, GRNN 对螺杆膨胀机发电系统的预测曲线拟合度更为理想。随后分别将功率和发电量的实验数据与理论预测采用相对误差进行计算。相对误差 RE 越小, 表示神经网络模型的预测效果越好。




Figure 4. Theoretical prediction of power by different neural networks

图 4. 不同神经网络对功率的理论预测




Figure 5. Theoretical prediction of power generation by different neural networks

图 5. 不同神经网络对发电量的理论预测

图 6 和图 7 分别为三种神经网络预测的功率与发电量的平均相对误差。由图 6 可知, GRNN 对功率的理论预测的相对误差分别为 3.93%、4.18%、4.09%、4.08%; BPNN 预测的相对误差分别为 4.89%、4.96%、4.95%、4.90%; CNN 预测的相对误差分别为 37.14%、42.44%、38.71%、38.99%。其三者对功率预测的平均相对误差分别为 4.07%、4.93%和 39.32%。结果表明, GRNN 对功率的理论预测效果最好。由图 7 可知, GRNN 对发电量的理论预测的相对误差分别为 7.85%、8.52%、8.56%、8.44%; BPNN 预测的相对误差分别为 11.91%、12.12%、12.24%、12.31%; CNN 预测的相对误差分别为 41.62%、35.84%、

38.83%、41.27%。三者对发电量预测的平均相对误差分别为 8.34%、12.14%和 39.39%。结果表明，在螺杆膨胀机发电热力系统性能预测中，GRNN 预测精度最优，这得益于其收敛快、小数据适应性强等特性；BPNN 受学习率、隐藏层数等超参数影响较大，容易出现预测偏差；而 CNN 虽在图像处理中优势明显，但对低维工况数据易出现过拟合，预测结果表现最差。




Figure 6. The average relative error of the power of the three models

图 6. 三种模型功率的平均相对误差




Figure 7. The average relative error of the power generation of the three models

图 7. 三种模型发电量的平均相对误差

通过对比三种不同神经网络模型的理论预测,选择预测效果最优的 GRNN 模型来预测入口蒸汽流量、蒸汽压力和蒸汽温度。在螺杆膨胀机变工况运行场景中,其发电性能受入口蒸汽流量、入口蒸汽压力及蒸汽温度动态耦合影响显著,呈现出强非线性、时变迟滞特性。尤其在余热波动频繁的工业场景下,热源参数与膨胀机内部非稳态流动的交互作用,导致传统机理模型难以精确表征。预测表明, BPNN 因固定拓扑结构限制,在入口蒸汽流量骤降时,因工况变化引起的物性突变无法被有效捕捉,对功率和发电量的预测偏差分别超过 4.93% 和 12.14%;而 CNN 对非图像类工况参数的时序-空间关联的预测能力存在局限性,对影响发电性能的非线性工况的预测误差峰值接近 43%。相比之下, GRNN 通过动态调整隐层节点激活阈值及突触权重分布,能更好地捕捉到变量间的复杂关系。此外,螺杆膨胀机的动态运行过程涉及多物理场耦合,GRNN 的结构更适合处理这种高维非线性映射。综合发电能力 GRNN 相较于 BPNN 和 CNN 分别提升了 2.33% 和 33.15%,该模型显著提升了螺杆膨胀机在热电联产系统变工况下的实时控制精度,支撑了变工况运行时的预测效率。

4.3. 蒸汽参数的变工况预测和优化




Figure 8. The range of variable conditions under different powers

图 8. 不同功率下各变工况的范围

由 GRNN 基于螺杆膨胀机的功率对入口蒸汽流量、蒸汽压力和蒸汽温度进行预测。通过分析试验数据,可将功率分为较低、中等、较高三个等级,即较低功率(<800 kW),中等功率(800 kW~1000 kW),较高功率(>1000 kW)。图 8(a)~(c)分别为不同功率条件下入口蒸汽流量、蒸汽压力和蒸汽温度的工况范围。如图 8 所示,随着功率的增加,蒸汽流量和蒸汽压力均有不同程度的上升趋势。入口蒸汽流量和蒸汽压力范围的最小值呈现逐渐上升趋势,且其最小范围在中等到较高功率条件下变化明显。




Figure 9. Prediction and optimization results of variable operating parameters based on power

图 9. 基于功率对变工况参数预测优化结果比例分布

从较低到较高功率条件下入口蒸汽流量预测的范围依次为 11.500~13.250 kg/s、11.944~13.583 kg/s、12.972~13.389 kg/s。蒸汽压力预测的范围依次为 623,000~779,000 Pa、658,000~782,000 Pa、737,000~765,000 Pa。蒸汽温度预测的范围依次为 522.45~534.65 K、522.45~537.65 K、525.05~537.35 K。在蒸汽流量方面,从较低到较高功率条件下工况范围的上下限波动幅度分别为 1.750 kg/s、1.639 kg/s 和 0.417 kg/s, 缩减幅度的比例分别为 6.34%和 74.55%, 从中等到较高功率条件下缩减幅度显著减少。这说明随功率的提高,

膨胀机对蒸汽流量的最小范围要求也随之提升。对于蒸汽压力，从较低到较高功率条件下工况范围的上下限波动幅度分别为 156,000 Pa、124,000 Pa 和 28,000 Pa，缩减幅度的比例分别为 20.51%和 77.42%，从中等到较高功率幅度显著减少。由此可见，膨胀机对蒸汽压力的范围要求也随功率的提高而升高，这表明在高功率条件下其稳定性更强。在低功率运行时膨胀机可能处于敏感的非线性区域，微小的功率变化可能引发蒸汽流量和蒸汽压力明显的输出或性能波动。高功率运行时，膨胀机的效率可能接近峰值，导致输出变化不明显。膨胀机在低功率条件下对蒸汽流量和蒸汽压力高度敏感，而在高功率条件下可能受限于环境条件或外部负载等外部条件限制，导致变工况参数的上下限在一个相对较窄的区间。然而，蒸汽温度的变化较为温和，从较低到较高功率条件下工况范围的上下限波动幅度分别为 12.20 K、15.20 K 和 12.30 K，这反映螺杆膨胀机功率的变化对蒸汽温度调节能力影响较小。GRNN 基于功率对入口蒸汽流量、蒸汽压力和蒸汽温度这三个主要变工况参数预测优化可通过图 9(a)~(c)得出，其中三种变工况小于或等于 2.5%的误差分布情况均高于 80%，小于或等于 5%的误差分布情况均高于 95%，这体现了优化结果的可靠性较高。




Figure 10. The range of variable conditions under different power generations

图 10. 不同发电量下各变工况的范围

由图 9(c)可知, 蒸汽温度小于或等于 2.5%的相对误差分布可达到 100%, 反映出功率的变化引起的蒸汽温度非线性变化相对稳定, 致使预测出的数据拟合度较高。结果表明, 基于广义回归神经网络(GRNN)建立的功率预测模型中, 蒸汽流量、蒸汽压力及蒸汽温度三个关键变工况参数的预测平均相对误差分别为 0.729%、1.013%和 0.169%。该误差分布表明模型预测值与实验实测值具有良好的一致性, 验证了 GRNN 算法在变工况参数预测中的准确性, 所提出的优化策略有效实现了预期目标。进一步分析揭示, 蒸汽参数与输出功率间存在显著耦合关系, 这是由于蒸汽流量的质量传递效应、蒸汽压力的热力学势能以及蒸汽温度的焓值特性均对螺杆膨胀机的功率输出特性产生决定性影响。




Figure 11. Prediction and optimization results of variable operating parameters based on power generation

图 11. 基于发电量对变工况参数预测优化结果比例分布

GRNN 基于螺杆膨胀机的发电量对入口蒸汽流量、蒸汽压力和蒸汽温度进行预测。通过分析试验数据, 可将发电量分为较低、中等、较高三个等级, 即较低发电量(<800 kWh), 中等发电量(800~1000 kWh),

较高发电量(>1000 kWh)。图 10(a)~(c)分别为不同发电量条件下的蒸汽流量、蒸汽压力和蒸汽温度的工况范围。如图 10 所示,随着发电量数值的增加,入口蒸汽流量和蒸汽压力范围的最小值和最大值在一个相对稳定的区间,其可调节范围也相对较宽泛。由于蒸汽温度对发电量的影响较小,即使在不同发电量条件下,蒸汽温度整体范围也无明显变化。从较低到较高发电量条件下入口蒸汽流量预测的范围依次为 11.583~13.389 kg/s, 11.806~13.528 kg/s, 11.722~13.583 kg/s。蒸汽压力预测的范围依次为 631,000~765,000 Pa, 623,000~776,000 Pa, 639,000~782,000 Pa。蒸汽温度预测的范围依次为 509.25~536.85 K, 502.05~537.65 K, 522.85~535.35 K。

在蒸汽流量方面,从较低到较高发电量条件下工况范围的上下限波动幅度分别为 1.806 kg/s、1.722 kg/s 和 1.861 kg/s, 缩减比例幅度分别为 4.65%和-8.07%(即增加了 8.07%)。对于蒸汽压力,从较低到较高发电量条件下工况范围的上下限波动幅度分别为 134,000 Pa、153,000 Pa 和 143,000 Pa, 缩减比例幅度分别为 -14.18%和 6.54%, 蒸汽流量和蒸汽压力整体保持相对稳定。在蒸汽温度方面,从较低到较高发电量条件下工况范围的上下限波动幅度为 27.60 K、35.60 K 和 12.50 K, 缩减比例幅度分别为-28.98%和 64.89%。在中等发电量条件下蒸汽温度有所波动可能是外部用电和用电用户等因素影响,而在较高发电量条件下蒸汽温度的可调节范围更窄,这反映了发电系统在高负荷运行时对蒸汽温度的范围限制相对苛刻。

GRNN 基于发电量对入口流量、蒸汽压力和蒸汽温度这三种主要变工况参数预测优化可通过图 11(a)~(c)得出,其中三种变工况小于或等于 2.5%的误差分布情况均高于 59%,小于或等于 5%的误差分布情况均高于 85%,这体现了优化结果的可靠性较高。基于发电量预测的蒸汽流量、蒸汽压力和蒸汽温度三种变工况参数的平均相对误差分别为 1.596%、2.793%和 0.476%,说明变工况参数的预测值与实际值偏差较小,优化结果达到预期。其中,蒸汽流量与蒸汽压力由于其数量级较高,实际运行时非线性波动较大,因此平均相对误差略大于蒸汽温度。并且,由于发电系统的发电量与螺杆膨胀机的功率呈正相关,本文旨在获得发电系统更高发电性能的研究。因此,GRNN 对螺杆膨胀机发电系统发电性能预测的较优工况范围,即若螺杆膨胀机发电系统满足以下工况条件即可获得较高的发电量,其中蒸汽流量的较优工况范围为 11.722~13.583 Kg/s,蒸汽压力的较优工况范围为 639,000~782,000 Pa,蒸汽温度的较优工况范围为 522.85~535.35 K。

5. 结论

(1) 入口蒸汽压力对发电性能的影响权重远大于入口蒸汽温度的影响权重,以入口蒸汽压力与入口温度作为影响因素对功率的影响权重为 0.6136 与 0.3864,而对发电量的权重为 0.7458 与 0.2542。并且蒸汽的焓降对入口蒸汽压力的变化更为敏感,入口蒸汽压力对功率和对发电量的影响略胜一筹。

(2) 对螺杆膨胀机热力系统的发电性能进行预测,结果表明,GRNN 表现较优,而 CNN 的表现较差。其中 GRNN 模型对功率和发电量预测的平均相对误差分别为 4.07%和 8.34%;BPNN 模型对功率和发电量预测的平均相对误差分别为 4.93%和 12.14%;CNN 模型对功率和发电量预测的平均相对误差分别为 39.32%和 39.39%。

(3) 较高发电量条件下的蒸汽流量较优工况范围为 11.722~13.583 Kg/s,蒸汽压力较优工况范围为 639,000~782,000 Pa,蒸汽温度较优工况范围为 522.85~535.35 K。通过 GRNN 模型获得合理运行工况范围可减少螺杆膨胀机发电热力系统非必要工况下的能源损耗,避免设备在低效或超负荷区间运行,提升螺杆膨胀机发电热力系统的能源利用效益。

基金项目

浙江省自然科学基金资助项目(ZCLQN25A0201)。

参考文献

- [1] 孙富德. 螺杆膨胀机在火力发电厂中的应用[J]. 山东煤炭科技, 2002(3): 27-29.
- [2] 杜祥琬. 中国能源中长期发展战略[J]. 中国经济和信息化, 2011(2): 22-23.
- [3] Zhang, C., Gao, J., Fu, J., Li, Y. and Lin, J. (2019) Research on Structural Parameter Optimization and Thermal Performance of Twin-Screw Expander. *International Journal of Low-Carbon Technologies*, **14**, 386-393. <https://doi.org/10.1093/ijlct/ctz026>
- [4] 武萌. 双螺杆膨胀机新型交叉轴锥形螺杆转子的性能研究[D]: [硕士学位论文]. 东营: 中国石油大学(华东), 2024.
- [5] 付洁. 基于转子型线分析的双螺杆膨胀机热力性能研究[D]: [硕士学位论文]. 哈尔滨: 哈尔滨工业大学, 2019.
- [6] 肖文明. 平衡式双螺杆膨胀机流体动态特性研究[D]: [硕士学位论文]. 上海: 华东交通大学, 2021.
- [7] Zhao, Z., Yuan, H., Tian, Y. and Zhang, H. (2021) A Novel Method for Rotor Profile Optimization of High temperature Screw Expanders Employed in Waste Heat Recovery Systems. *International Journal of Energy Research*, **45**, 8551-8563. <https://doi.org/10.1002/er.6392>
- [8] 刁安娜, 韩冰, 冯明志, 等. 无油螺杆膨胀机工作过程模拟及热力性能分析[J]. 化工设备与管道, 2018, 55(5): 49-53.
- [9] 周岳, 卢笋, 谢楷. 螺杆膨胀机有机朗肯循环有机工质研究[J]. 化工设备与管道, 2019, 56(2): 47-52.
- [10] Papes, I., Degroote, J. and Vierendeels, J. (2015) New Insights in Twin Screw Expander Performance for Small Scale ORC Systems from 3D CFD Analysis. *Applied Thermal Engineering*, **91**, 535-546. <https://doi.org/10.1016/j.applthermaleng.2015.08.034>
- [11] He, Y., Wu, H., Zhang, Y., Jin, T. and Xing, Z. (2022) Experimental Research on the Effects of Suction Ports on Twin Screw Expander Performance. *Applied Sciences*, **12**, Article 3979. <https://doi.org/10.3390/app12083979>
- [12] Nikolov, A. and Brümmer, A. (2017) Investigating a Small Oil-Flooded Twin-Screw Expander for Waste-Heat Utilisation in Organic Rankine Cycle Systems. *Energies*, **10**, Article 869. <https://doi.org/10.3390/en10070869>
- [13] 卢鑫海. 多工况反动式速度型 CO₂ 膨胀机的设计及其关键技术研究[D]: [硕士学位论文]. 石家庄: 石家庄铁道大学, 2023.
- [14] 赵丽, 李敏霞, 马一太. R22 转子式膨胀机的多工况仿真计算与运转试验[J]. 工程热物理学报, 2014, 35(3): 440-444.
- [15] 寇文珍, 唐仲杰, 崇磊, 等. 基于 BP 神经网络和遗传算法的光伏电站功率预测[J]. 光源与照明, 2024(11): 123-125.
- [16] 苏世杰, 杨雷, 李俊楠, 等. 基于优化 BP 神经网络的电力负荷概率密度预测[J]. 电子设计工程, 2024, 32(22): 124-127+132.
- [17] 张二辉, 徐兴朝, 郑卫剑, 等. 基于广义回归神经网络的风力发电场设备温度自适应预测方法[J]. 自动化与仪表, 2024, 39(10): 72-75.
- [18] 全新宇, 张宇泽, 张长生, 等. 基于广义回归神经网络的有源配电网网供负荷预测方法[J]. 供用电, 2020, 37(12): 40-45.
- [19] 吴强. 电力系统负荷预测中数据挖掘技术的应用研究[J]. 电力设备管理, 2024(22): 14-16.
- [20] 周飞燃, 曾德良, 胡勇. 基于神经网络预测的主蒸汽温度控制方法研究[J]. 热能动力工程, 2024, 39(10): 148-158.
- [21] 郑娱泉. 螺杆膨胀机的研究[J]. 四川工业学院学报, 1991(3): 150-164.
- [22] 曹滨斌. 螺杆膨胀机余热回收系统分析[D]: [硕士学位论文]. 天津: 天津大学, 2007.
- [23] 洪毅, 吴杰, 宋明. 人工神经网络的研究[J]. 湖南大学学报(自然科学版), 1993(3): 79-85.
- [24] 李晓峰, 刘光中. 人工神经网络 BP 算法的改进及其应用[J]. 四川大学学报(工程科学版), 2000(2): 105-109.
- [25] 刘天舒. BP 神经网络的改进研究及应用[D]: [硕士学位论文]. 哈尔滨: 东北农业大学, 2011.
- [26] 郭艳莉. 基于灰色-广义回归神经网络的私人汽车拥有量分析及预测[D]: [硕士学位论文]. 北京: 华北电力大学(北京), 2023.
- [27] 沈跃云, 高小涛, 孟硕. 600 MW 墙式燃烧锅炉氮氧化物排放浓度与主要运行因素的多元线性回归研究[J]. 热能动力工程, 2011, 26(6): 726-731.

- [28] 王玺琨. 基于 CNN 的交互行为识别技术研究[D]: [硕士学位论文]. 北京: 北方工业大学, 2024.
- [29] 周浩亮. 模糊数学基本理论及其应用[J]. 建井技术, 1994(4): 70-80.
- [30] 胡春波, 王坤, 曾卓雄, 等. 液滴破碎模糊计算研究[J]. 西北工业大学学报, 2003(5): 536-539.