研究论文

DOI：10.11949/0438-1157.

基于BP神经网络代理模型与自适应多项式回归的高温热泵COP预测

张旭[1]，高标[1]，胡洲宾[1]，胡斌[2]，刘中毅[2]

（[1]国网浙江综合能源服务有限公司，浙江 杭州 310000；[2]上海交通大学，上海 200240）

摘要： 针对高温热泵宽工况性能预测中预测精度与工程部署便利性难以兼顾的问题，提出一种反向传播（BP）神经网络代理模型与误差约束自适应多项式回归相结合的制热性能系数（COP）预测方法。基于环境温度-25～40℃、出水温度95～120℃范围内的84组实验数据，建立2-10-6-1结构BP神经网络，并将其在给定工况域内的响应面投影为低阶显式多项式。采用30次重复独立划分评价模型性能。在固定6项二次多项式结构下，BP神经网络测试集决定系数（R^2）、平均绝对百分比误差（MAPE）和最大相对误差（MaxErr）的平均值分别为0.9977、0.596%和1.664%；代理-二次多项式相应指标为0.9954、1.263%和3.303%，优于直接由实验训练数据拟合的二次多项式（0.9915、1.309%和3.655%）。结果表明，BP网络能够有效表征COP非线性响应；以BP稠密响应面为拟合对象可提升低阶显式关联式的测试精度。所得代理-二次关联式适用于本文机组及给定温度范围内的COP快速估算，可为工程计算和控制器部署提供模型基础。

关键词： 高温热泵；制热性能系数；BP神经网络；代理模型；自适应多项式回归

中图分类号： TK115　　**文献标志码：** AA

文章编号： 0438-1157（XXXX）XX-0001-10

COP prediction of a high-temperature heat pump based on a BP neural network surrogate model and adaptive polynomial regression

ZHANG Xu[1], GAO Biao[1], HU Zhoubin[1], HU Bin[2], LIU Zhongyi[2]

([1]*State Grid Zhejiang Integrated Energy Service Co., Ltd., Hangzhou* 310000, *Zhejiang*, *China*; [2]*Shanghai Jiao Tong University*, *Shanghai* 200240, *China*)

Abstract: To balance prediction accuracy and deployability for high-temperature heat pumps under wide operating conditions, a coefficient of performance(COP) prediction method combining a backpropagation (BP) neural-network surrogate with error-constrained adaptive polynomial regression is proposed. Eighty-four experimental observations covering ambient temperatures from −25 to 40 °C and outlet-water temperatures from 95 to 120 °C were used to develop a 2-10-6-1 BP neural network, whose response surface was projected onto a low-order explicit polynomial. Thirty repeated independent data partitions were used for evaluation. Under an identical six-term quadratic structure, the BP neural network achieved mean test-set values of R^2=0.9977, MAPE=0.596%, and MaxErr=1.664%. The surrogate-quadratic model achieved 0.9954, 1.263%, and 3.303%, respectively, outperforming the quadratic model fitted directly to the experimental training data (0.9915, 1.309%, and 3.655%). The BP surrogate captures the nonlinear COP response, and fitting the BP-generated dense response surface

收稿日期： 2026-07-21　　**修回日期：** 2026-09-14

通信作者： 刘中毅（1995—），男，博士，助理研究员，zyleo@sjtu.edu.cn

第一作者： 张旭（1987—），男，硕士，高级工程师，876101205@qq.com

基金项目： 国网综合能源服务集团有限公司管理科技项目（527899250008）

引用本文： 张旭, 高标, 胡洲宾, 胡斌, 刘中毅. 基于BP神经网络代理模型与自适应多项式回归的高温热泵COP预测[J]. 化工学报, XXXX, XX(XX): 1-10

Citation: ZHANG Xu, GAO Biao, HU Zhoubin, HU Bin, LIU Zhongyi. COP prediction of a high-temperature heat pump based on a BP neural network surrogate model and adaptive polynomial regression[J]. CIESC Journal, XXXX, XX(XX): 1-10

improves the test accuracy of the low-order explicit correlation. The resulting surrogate-quadratic correlation is intended for rapid COP estimation of the investigated unit within the specified temperature range and may support engineering calculation and controller deployment.

Keywords: high-temperature heat pump; coefficient of performance; BP neural network; surrogate model; adaptive polynomial regression

引 言

在工业供热低碳化转型背景下，空气源高温热泵可利用电能驱动，将环境中的低品位热能提升至较高温位，在化工、食品和造纸等领域具有应用潜力[1-2]。与常规热泵相比，高温热泵通常在较大温升条件下运行[3]，其制热性能系数（coefficient of performance，COP）受环境温度、出水温度及系统内部运行参数共同影响。本文实验数据表明，当环境温度由40℃降低至-25℃时，机组COP由约2.75下降至1.24，体现出明显的非线性和工况耦合特征。因此，建立覆盖宽工况范围的COP预测模型，是开展容量匹配、能效评估和运行控制的重要基础[4-5]。

高温热泵性能预测通常可采用机理模型、经验关联式和数据驱动模型[6]。机理模型具有明确的热力学基础，但通常需要制冷剂热物性、压缩机性能图谱及换热器结构参数，建模和标定工作量较大。低阶经验关联式形式简单、计算快速，便于嵌入仿真与控制程序，但其表达能力受模型阶次限制；高阶多项式虽然可以提高训练数据拟合程度，却可能带来参数冗余和数值不稳定。人工神经网络具有较强的非线性映射能力，已用于制冷与热泵性能预测，但其权重参数难以直接转化为工程人员易于使用的显式计算式[7-8]。颜建国等人[9]针对超临界CO_2流动传热实验数据构建遗传算法（GA）-BP神经网络，实现了不同工况下传热系数的有效预测，但该模型以训练完成的网络权重直接输出预测结果，未进一步提取便于工程人员离线查算或嵌入控制程序的显式表达式。刘根等人[10]采用神经网络描述生物质热解产物分布，并与流程模拟和优化相结合，其神经网络同样作为黑箱模块嵌入更大的流程优化框架，而非转化为独立的显式关联式；陈治宏等人[11]进一步综述指出，机器学习可用于复杂化工过程的监测、预测和优化，但也指出机器学习模型的可解释性和工程可部署性仍是限制其大规模应用的关键瓶颈之一。上述三项工作共同表明：机器学习模型虽然能够对复杂非线性过程实现较高精度的预测，但其权重参数或流程耦合结构通常难以离线转化为简洁的显式计算式，在缺乏网络推理环境（如嵌入式控制器、简化仿真平台）的场合下不便直接部署。由此，如何在保留数据驱动模型响应特征的同时获得结构紧凑的显式关联式，具有实际工程意义。

围绕高温热泵COP预测所依赖的循环性能、工质适配与宽工况数据，国内研究已提供了重要基础。胡斌等人[2]系统梳理了工业高温/蒸汽热泵的循环型式、制冷剂压缩与水蒸气压缩技术，指出应结合低全球变暖潜能值（GWP）工质和工业锅炉替代场景推进技术应用。欧阳洪生等人[12]研究了新型环保工质HP-1的物性及其高温热泵应用特性，实验表明该工质在蒸发温度50～70℃时可实现125℃冷凝温度，机组COP为2.25～4.85。常德鹏等人[13]研究了用于120～150℃蒸汽生产的超高温空气源自由活塞斯特林热泵；何宇佳等人[14]报道了改进式机械过冷跨临界CO_2热泵。上述工作明确了工质、循环构型和运行温度均会影响机组性能，这使得基于机理模型获取性能预测的工作量显著增加，难以适应工程应用需求，但同时说明获得可快速调用的宽工况COP关联式对设计优化和运行评估具有直接价值。

数据驱动方法能够为热泵性能快速预测提供有效工具。Mohanraj等人[15]采用人工神经网络预测直膨式太阳能辅助热泵的功耗、制热量和性能指标，比较结果表明Levenberg-Marquardt（LM）训练算法在其测试条件下具有较高预测精度。Mathioulakis等人[16]研究了空气-水热泵热水器的人工神经网络性能预测，验证了以空气侧和水侧温度为输入的网络可用于不同运行条件下的性能表征。Yu等人[17]对不同工质高温热泵开展实验与智能预测研究，比较了支持向量机和BP神经网络对制热量、输入功率及COP的预测能力。Zhou等人[18]构建了用于地源热泵性能预测的人工神经网络模型，指出经合理训练的前馈网络可在较少输入变量下实现较快的COP估计。上述研究为采用神经网络描

述热泵非线性性能提供了基础，但面向有限规则实验数据的模型压缩与显式关联式提取仍有待进一步研究。

本文基于空气源复叠式高温热泵在环境温度−25～40℃、出水温度95～120℃范围内的84组实验数据，构建BP神经网络代理模型，并在给定工况域内对代理响应面进行稠密查询；随后采用最大相对误差约束下的逐阶多项式回归，提取满足工程计算需求的低阶显式关联式。为避免仅依据单次数据划分评价模型，采用30次重复独立划分，分别考察BP神经网络、代理−二次多项式和直接二次多项式的测试性能。本文的特点在于：在保持两类显式模型项数完全相同的条件下，仅改变多项式的拟合对象，从而定量评估BP代理响应面对于低阶显式关联式精度的贡献；进一步以模型精度与参数规模为依据，形成面向工程部署的模型选型依据。

1 研究对象与实验数据

1.1 空气源高温热泵系统介绍

本文研究的空气源高温热泵机组采用以R410A/R245fa为工质的复叠循环结构。低温级以R410A为工质，从环境空气中回收低品位热能并提升至中间温位，通过级间冷凝蒸发器实现热量耦合，驱动以R245fa为工质的高温级循环进一步升温，最终输出高品位热能。机组结构如图1所示，其系统结构与循环压焓（P–h）图如图2所示。机组主要部件性能参数如表1所示。测试数据通过表2所列传感器同步记录环境温度、冷凝器进出口水温、水侧体积流量、压缩机及整机输入功率等参数。其中，制热量Q依据冷凝器水侧能量平衡由式(1)计算得到，即通过实测水流量V_w与冷凝器出、入口水温差($T_{out}-T_{in}$)确定；热泵系统总输入电功率W_e由Yokogawa WT210数字功率分析仪在机组主电源端测得，包含压缩机、风机的电耗；热源进水温度对应空气源蒸发器入口侧环境温度，用热侧出水温度为冷凝器出口水温；上述84组实验数据用于后续BP神经网络训练、代理响应面生成及显式多项式关联式构建。



图1 空气源高温热泵测试机组

Fig. 1 Air−source high−temperature heat pump test unit

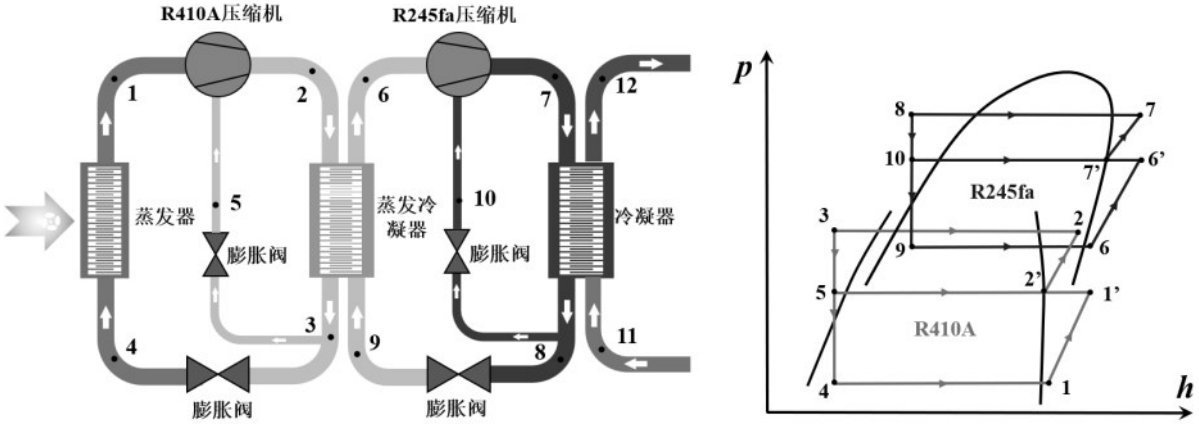


图2 复叠式高温热泵热力学循环及P–h图

Fig. 2 Thermodynamic cycle and P–h diagram of the cascade high−temperature heat pump

1.2 实验工况与数据采集

实验在180℃级高温热泵实验室专用测试台架上开展。实验工况以环境温度T_a和出水温度T_o为控制变量，其中T_a设置为−25～40℃共14个水平，T_o设

表1　主要部件及性能参数

Table 1　Main components and performance parameters

部件	类型	关键性能参数
低温级压缩机	涡旋式补气增焓型(变频)	额定排气量611m³/h,电机额定功率11kW
高温级压缩机	涡旋式补气增焓型(定频)	额定排气量2469m³/h,电机额定功率24.2kW
冷凝器	高效罐壳式换热器	换热面积13.38m²,设计换热量130kW设计压力2.8MPa
蒸发器	翅片管式(U型)	迎风面积3.487m²;风量23500m³/h
级间冷凝蒸发器	板式换热器	换热面积20.71m²,设计换热量55kW设计压力4.5MPa
节流装置	电子膨胀阀	调节范围0~100%;过热度设定5K
制冷剂充注量	R410A/R245fa	14kg/17kg

置为95~120℃共6个水平,形成14×6共84组稳态工况。各工况稳定运行30 min后采集环境温度、冷凝器进出口水温、水流量、压缩机输入功率及关键测点压力。测试仪器及精度见表2。本文数据未包含独立的非网格验证工况,即84组样本构成14×6全因素规则网格,未设置位于网格节点之外的独立验证工况,因此后续评价仅用于表征给定工况域内的预测性能。

$$Q = \rho_w c_p V_w \left(T_{out} - T_{in}\right) \tag{1}$$

$$COP = Q/w_e \tag{2}$$

式中,ρ_W为水的密度(kg/m³),C_p为水的定压比热容(kJ/(kg·K)),V_w为体积流量(m³/s),T_{out}和T_{in}分别为冷凝器出口、入口水温(℃),W_e为热泵系统总输入电功率(kW)由Yokogawa WT210在机组主电源端测得,包含压缩机、风机的电耗。

表2　实验所用测试仪器

Table 2　Specifications of the instruments used in the experiments

测量参数	测量仪器	类型	量程	精度/%
压力(MPa)	压力传感器	PT-304	0~1.6MPa	±0.2
温度(℃)	温度传感器	PT100	-20~200℃	±1
流量(m³/h)	涡街流量计	Opine FM210	15~150m³/h	±1
功率(kW)	数字功率分析仪	Yokogawa WT210	15~600V 5~200mA	±0.1

2　数学模型及计算方法

2.1　BP神经网络模型

2.1.1　网络拓扑结构　如图3所示,本文构建三层前馈神经网络(2个隐含层),结构记为2-10-6-1,即输入层2个节点(T_a和T_o)、第一隐含层10个节点、第二隐含层6个节点、输出层1个节点(COP)。多层前馈网络具有逼近连续非线性映射的能力[19]。两个隐含层均采用双曲正切S形函数(tansig)作为激活函数:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = 2\sigma(2x) - 1 \tag{3}$$

输出层采用线性激活函数purelin。为减小不同输入变量量纲对训练过程的影响,输入和输出均进行线性归一化。网络包含103个权重和偏置参数,参数数与样本数之比约为1.23,因此有必要通过验证集监控、早停和重复数据划分评价过拟合风险,而不能仅依据训练集拟合优度判断模型性能。

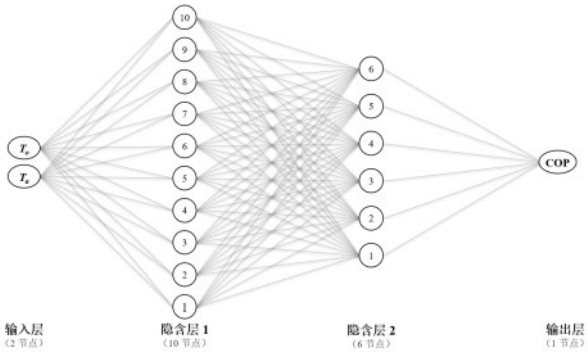


图3　BP神经网络拓扑结构示意图

Fig. 3　Topology of the BP neural network

2.1.2　Levenberg-Marquardt训练算法　本文采用Levenberg-Marquardt(LM)算法[19]训练网络。LM算法将梯度下降法与Gauss-Newton法相结合,通过引入阻尼系数μ自适应调节优化方向,其权值更新形式为:

$$\Delta \boldsymbol{w} = -\left(\boldsymbol{J}^T\boldsymbol{J} + \mu \boldsymbol{I}\right)^{-1}\boldsymbol{J}^T\boldsymbol{e} \tag{4}$$

式中,$\boldsymbol{\Delta w}$为权值更新量,$\boldsymbol{J}$为误差对网络权值的雅可比矩阵,$\boldsymbol{e}$为误差向量,μ为阻尼系数,$\boldsymbol{I}$为单位矩阵。当μ较小时,LM算法趋近于Gauss-Newton法,具有较快的局部收敛速度;当μ较大时,趋近于梯度下降法,从而增强全局搜索能力。LM算法对小中型网络的二阶收敛特性使其在84个训练样本

的情景下具有显著优势，通常可在百次迭代内收敛至目标精度[20]。

84组数据按70%:15%:15%的比例随机划分为训练集、验证集和测试集。训练集用于更新网络权重与偏置，验证集用于早停监控和最优迭代轮次选择，测试集不参与参数更新和早停决策，仅用于训练完成后的性能评价。为降低单次划分的偶然性，采用30个固定随机种子重复上述过程，并报告测试指标的均值和标准差。

2.1.3 评价指标 为全面评估模型预测性能，本文选取决定系数(R^2)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)及最大相对误差(MaxErr)四项指标进行综合评价，其定义如下：

(1)决定系数R^2：

$$R^2 = 1 - \frac{\sum(\hat{y}_i - y_i)^2}{\sum(\hat{y}_i - \bar{y}_i)^2} \tag{5}$$

(2)均方根误差RMSE：

$$RMSE = \sqrt{\frac{1}{N}\sum(\hat{y}_i - y_i)^2} \tag{6}$$

(3)平均绝对百分比误差MAPE：

$$MAPE = \frac{1}{N}\sum\left|\frac{\hat{y}_i - y_i}{y_i}\right| \times 100\% \tag{7}$$

(4)最大相对误差MaxErr：

$$MaxErr = max\left|\frac{\hat{y}_i - y_i}{y_i}\right| \times 100\% \tag{8}$$

其中，y_i、$\hat{y}_i$和$\bar{y}$分别表示第i个样本的实测值、预测值和实测值均值，N为样本数量。上述指标中，R^2用于表征模型整体拟合优度，RMSE反映误差的绝对量级，MAPE与MaxErr则分别从平均水平与极端偏差角度刻画相对误差特征。多指标联合评价可从不同维度综合反映模型预测精度与稳定性，R^2越接近1，RMSE、MAPE、MaxErr越小，说明模型精度越高。

2.2 基于神经网络代理模型的工况空间稠密采样

直接利用有限实验点拟合多项式时，模型阶次和系数可能对样本分布较敏感。代理模型可将复杂响应关系转化为便于后续近似和工程分析的连续数值响应面[17, 18, 20]。通过引入BP神经网络，获得连续、平滑的代理响应面，再将该响应面压缩为便于工程部署的显式多项式。因此，稠密查询点应理解为代理模型的数值响应，而不能等同于新增实验样本。

在每次数据划分中，仅利用训练集和验证集确定BP神经网络。在目标工况域内，将T_a和T_o分别离散为50和35个节点，形成1750个查询点，并由训练后的网络计算相应COP。该步骤将神经网络所表示的连续非线性关系离散化，为不同阶次多项式对同一代理响应面的投影提供统一数值基础。外层测试数据不参与网络训练、稠密查询模型确定、多项式选阶或系数估计。

2.3 误差约束下的自适应多项式回归

2.3.1 候选多项式模型集 本文基于阶次递进原则，构建了覆盖线性至三次多项式的5种COP候选模型，其具体模型结构如表3所示。

表3 候选COP多项式关联式

Table 3 Candidate polynomial correlations for COP

模型名称	项数	多项式关联式
线性模型	3	$c_o + c_1T_a + c_2T_o$
双线性模型	4	$c_o + c_1T_a + c_2T_o + c_3T_aT_o$
二次多项式	6	$c_o + c_1T_a + c_2T_o + c_3T_a^2 + c_4T_aT_o + c_5T_o^2$
二次扩展	8	$c_o + c_1T_a + c_2T_o + c_3T_a^2 + c_4T_aT_o + c_5T_o^2 + c_6T_a^2T_o + c_7T_aT_o^2$
三次多项式	10	$c_o + c_1T_a + c_2T_o + c_3T_a^2 + c_4T_aT_o + c_5T_o^2 + c_6T_a^3 + c_7T_aT_o^2 + c_8T_aT_o^2 + c_9T_o^3$

2.3.2 系数估计 对于每种候选模型，构造设计矩阵Φ(1750×M)，采用最小二乘法估计系数向量c进行估计：

$$MaxErr = max\left|\frac{\hat{y}_i - y_i}{y_i}\right| \times 100\% \tag{9}$$

$$c = (\Phi^T\Phi)^{-1}\Phi^T y_{dense} \tag{10}$$

其中，y_{dense}为BP神经网络在1750个工况查询点处的COP响应向量。稠密网格有助于约束多项式对整个代理响应面的逼近，但不会增加独立实验信息。多项式模型的预测能力仍需使用未参与本轮建模的测试数据评价。

2.3.3 自适应阶次选择准则 候选模型按照由低阶到高阶的顺序进行评价。每次重复划分中，训练数据用于BP网络建模，验证数据用于确定满足MaxErr≤5%条件的最低多项式阶次，测试数据仅在模型结构和参数冻结后评价一次。为比较代理响

应面拟合与直接实验数据拟合的差异，在确定二次模型为工程部署候选后，进一步设置固定6项二次多项式的直接拟合基线。

2.3.4　固定6项二次多项式的公平比较　为排除多项式项数差异对比较结果的影响，代理-二次多项式与直接二次多项式均固定为包含常数项、T_a、T_o、T_a^2、T_aT_o和T_o^2的6项形式。前者以训练后的BP网络在1750个稠密查询点生成的COP响应为拟合对象；后者仅以同次训练集中的实验COP为拟合对象。两类模型在相同的独立测试集上计算R^2、RMSE、MAPE和MaxErr，从而定量表征BP代理响应面对于低阶显式关联式精度的影响。

3　结果与分析

3.1　BP神经网络训练结果

BP神经网络在30次重复独立划分中的测试集R^2为0.9977±0.0025，RMSE为0.0145±0.0085，MAPE为0.596%±0.367%，MaxErr为1.664%±0.922%。不同划分下R^2范围为0.9905～0.9998，其中“0.9977±0.0025”等数值为30次重复划分下各指标的“平均值±标准差”，用于刻画模型性能的集中趋势与离散程度；而“0.9905～0.9998”为30次划分中R^2的最小值与最大值（即极差范围）。二者分别从集中趋势与取值范围两个角度评价模型稳定性，互为补充而非矛盾：标准差反映不同随机划分的波动，极差范围则给出最不利单次划分的边界。不同划分下R^2范围为0.9905～0.9998，MaxErr范围为0.623%～3.493%，表明网络总体具有较高的域内预测精度，且不同数据划分仍会影响最差点误差。因此，本文后续结论以重复验证的均值和离散程度为主要依据，而不采用某一次运行的最佳结果。

图5展示了BP神经网络预测值与实验值的对应关系。总体上，预测值沿理想对角线分布，残差集中于零附近，表明BP神经网络能够较好地表征给定工况范围内COP的非线性变化规律。结合30次重复独立划分结果可知，模型在不同数据划分下均保持较高的域内预测精度。

3.2　代理模型稠密采样分析

图6的三维散点图直观展示了稠密采样（1750点）与原始实验数据（84点）的空间分布对比。稠密样本在全工况空间均匀铺满，不存在任何方向上的盲区；而原始实验点仅覆盖有限网格节点，在任意

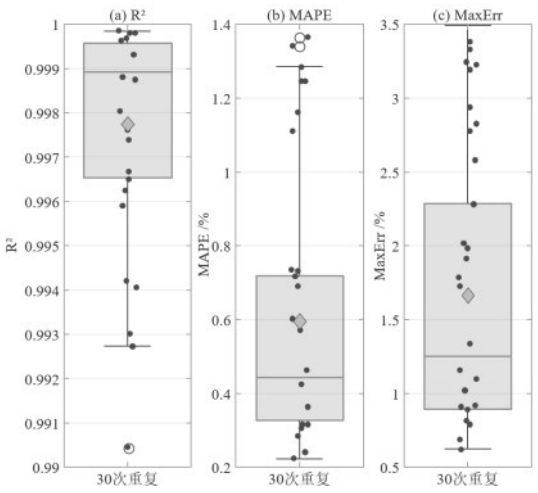


图4　BP神经网络30次重复独立划分的测试集性能分布

Fig. 4　Distribution of BP neural-network test performance over 30 repeated independent data partitions

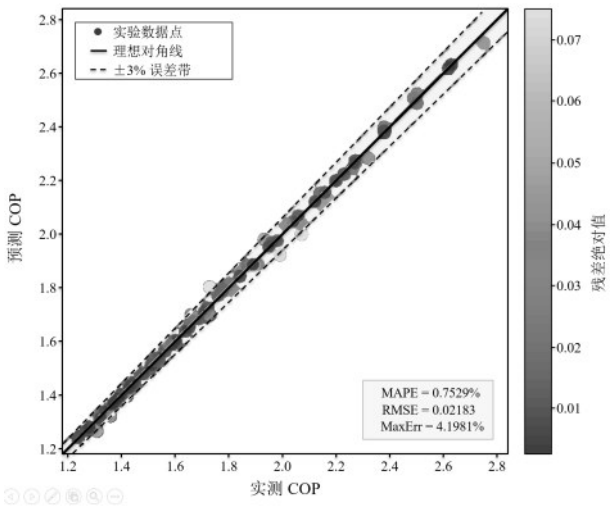


图5　神经网络预测精度验证

Fig. 5　Validation of neural-network prediction accuracy

两条相邻等温线之间均无中间支撑。灰度连续分布表明代理模型生成的虚拟样本与物理实验数据在COP数值规律上高度一致，无异常跳变或非物理极值点，使多项式系数的鲁棒性明显改善。

3.3　自适应多项式回归结果

为比较不同复杂度多项式模型的泛化表现，图7给出了5类候选模型在30次重复独立划分中验证集最大相对误差（MaxErr）的分布。线性模型与双线性模型的MaxErr整体较高，且多数重复结果超过5%；二次多项式及更高阶模型的MaxErr总体低于5%，表明适度引入二次项能够显著改善对BP代理模型输出的逼近效果。考虑模型精度与表达简洁性，后续以满足验证误差要求的低阶模型作为显式

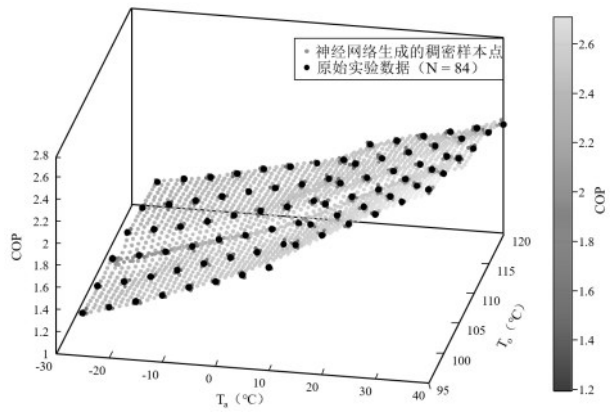


图6 代理模型稠密采样示意图

Fig. 6 Dense sampling using the surrogate model

关联式候选。

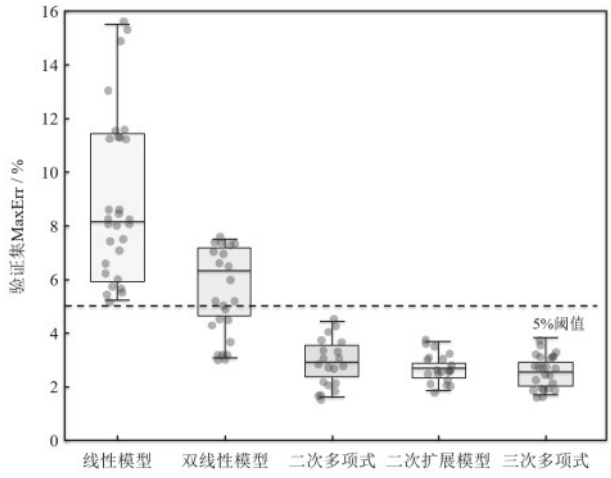


图7 候选多项式模型最大相对误差分布

Fig. 7 Distribution of the maximum relative error of the candidate polynomial model

3.4 最终关联式

综合模型精度、表达形式和计算复杂度，选用包含常数项、T_a、T_o、T_a^2、T_aT_o和T_o^2的二次多项式作为最终关联式：代理-二次多项式。基于BP代理模型在1750个稠密工况点生成的COP响应，拟合得到代理-二次多项式；其系数依次为3.34140905、0.05373857、-0.01958261、0.00008671、-0.00034960和0.00003447。该代理-二次多项式适用范围限定为$T_a\in[-25,40]$℃、$T_o\in[95,120]$℃。

$$COP = 3.34140905 + 0.05373857 \times T_a - 0.01958261 \times T_o + 0.00008671 \times T_a^2 - 0.00034960 \times T_a \times T_o + 0.00003447 \times T_o^2 \quad (11)$$

3.5 预测结果对比

图8比较了典型出水温度下实验数据、代表性BP网络预测结果与代理-二次多项式的COP变化趋势。值得注意的是，实验数据在环境温度T_a=15℃附近出现COP的阶跃式增大（如T_o=95℃工况下，T_a由10℃升至15℃时COP由1.93增至2.15，增幅约0.22，明显高于其余相邻温度节点约0.07～0.13的增幅）。这一现象在原始实验数据中即已存在，并非BP网络或多项式拟合引入的伪迹。对于本文所研究的补气增焓复叠循环机组，该阶跃很可能与机组控制逻辑在T_a=15 ℃附近发生的运行模式切换有关，例如补气增焓回路的启停阈值、低温级压缩机运行频率或多台压缩机的分级启停策略、膨胀阀开度的分段控制逻辑等通常以环境温度作为切换判据，当环境温度跨越设定阈值时，机组会切换至更高效的运行模式，从而在COP-T_a曲线上表现为局部阶跃而非严格连续变化。由于该阶跃源于实际控制逻辑而非测量误差，BP神经网络凭借其对局部非线性特征的强拟合能力可以较好地复现这一现象（如图8中BP预测曲线所示），而基于全域数据拟合的二次多项式关联式在整体趋势上仍保持单调光滑，无法精确复现局部阶跃，这也是该温度区间附近多项式相对误差偏大的主要原因（见图9）。代理-二次多项式（虚线）与神经网络预测结果（实线）在整体趋势及数值分布上均与实验数据点高度一致，未出现系统性偏差或局部发散现象，表明该显式模型能够准确刻画COP随环境温度升高而单调增加、随出水温度升高而整体降低的非线性响应特征。从拟合精度角度分析，代理-二次多项式在全工况区间内保持良好的逼近能力，其预测结果与神经网络高精度黑箱模型基本重合，验证了其在低维输入条件下对复杂热力过程的有效降阶表达能力。

图9给出了代理-二次多项式在84组实验数据上的相对误差分布。相对误差介于-3.873%～3.678%之间，最大绝对相对误差出现在环境温度15℃、出水温度120℃工况，表明该代理-二次多项式能够较好描述给定实验工况范围内COP的总体变化规律。误差在不同温度组合下呈现一定的正负交替特征，说明二次多项式对局部非线性变化仍存在近似偏差。

表4比较了BP神经网络、代理-二次多项式和实验数据拟合多项式在30次重复独立划分下的测试性能。BP神经网络的预测精度最高。与直接二次多项式相比，代理-二次多项式的平均R^2由0.9915提高至0.9954，RMSE由0.0316降低至0.0298，MAPE由1.309%降低至1.263%，MaxErr由3.655%降低至3.303%。在30次成对比较中，代理-

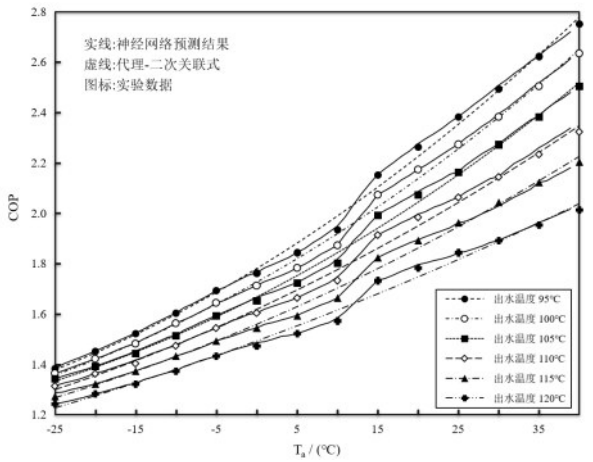


图8　典型出水温度下实验数据、代表性BP网络与代理-二次多项式的COP对比

Fig. 8　Comparison of COP among experimental data, a representative BP network and the surrogate-quadratic model at typical outlet-water temperatures

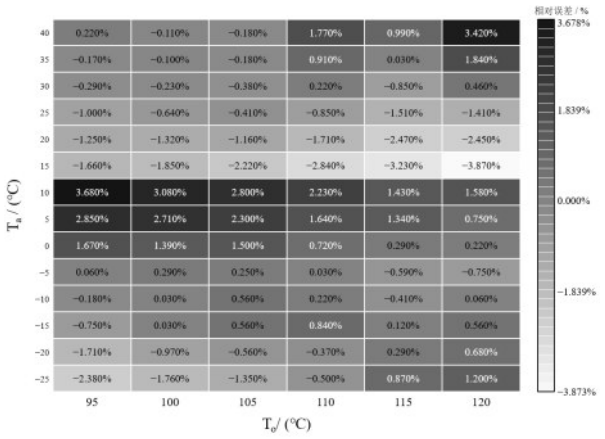


图9　代理-二次多项式在84组实验数据上的相对误差分布

Fig. 9　Relative-error distribution of the surrogate-quadratic model over the 84 experimental data points

二次多项式在R^2、RMSE和MaxErr指标上分别有24次优于直接二次多项式，在MAPE指标上有21次更优。结果表明，BP网络生成的稠密响应面能够在一定程度上保留原始COP数据的非线性变化特征，并提升低阶显式关联式的测试精度。

表4　三类模型在30次重复独立划分下的测试性能比较

Table 4　Repeated-test performance comparison among the three models

模型	R^2	RMSE	MAPE/ %	MaxErr / %
BP神经网络	0.9977±0.0025	0.0145±0.0085	0.596±0.367	1.664±0.922
代理-二次多项式	0.9954±0.0043	0.0298±0.0068	1.263±0.288	3.303±0.895
实验数据拟合多项式	0.9915±0.0045	0.0316±0.0067	1.309±0.276	3.655±0.860

综上，BP神经网络适用于精度优先且具备网络推理条件的预测任务；代理-二次多项式在保持显式二次关联式形式的同时，测试精度优于直接实验数据拟合的二次模型，更适合嵌入可编程控制器（PLC）、控制逻辑或工程计算表，实现给定机组和温度范围内的COP快速估算，可作为本文精度与工程部署便利性之间的优选折中方案。

为进一步说明本文预测模型的精度水平，将其与国内外相关研究进行对比。已有文献采用人工神经网络预测热泵COP时通常可获得较高精度：Mohanraj等人[15]、Mathioulakis等人[16]及Yu等人[17]报道的神经网络模型R^2普遍处于0.95以上；Zhou等人[18]针对地源热泵的前馈网络模型同样具有较高预测精度。本文BP神经网络在30次重复独立划分下的平均测试R^2=0.9977，与上述文献报道的高精度水平总体相当，表明本文所采用的LM训练算法和2-10-6-1网络结构在给定工况域内是有效的。与既有工作相比，本文的主要区别在于：现有热泵COP神经网络预测研究[15-18]大多止步于黑箱模型本身的精度报告，未进一步讨论如何将训练好的网络转化为便于工程离线部署的显式表达式；本文则在保持较高预测精度的BP代理模型基础上，进一步提出误差约束下的自适应多项式压缩方法，所得代理-二次关联式测试集R^2=0.9954，同时具备显式解析形式和仅6项系数的紧凑结构，可在不具备神经网络推理条件的PLC或简化仿真环境中直接调用，这是本文相对于已有文献的主要改进和贡献所在。

4　结 论

针对高温热泵COP预测精度与工程部署便利性的权衡问题，本文基于84组实验数据研究了BP神经网络代理模型及误差约束自适应多项式回归方法。主要结论如下：

（1）在30次重复独立划分中，BP神经网络测试集R^2、MAPE和MaxErr的平均值分别为0.9977、0.596%和1.664%，表明其在本文实验工况域内具有较高的COP预测精度。

（2）在固定6项二次多项式结构下，代理-二次多项式的测试集R^2、MAPE和MaxErr平均值分别为0.9954、1.263%和3.303%，优于直接实验数据拟合二次多项式的0.9915、1.309%和3.655%。说明以BP稠密响应面为拟合对象可提升低阶显式关联式的测试精度。

（3）最终代理-二次关联式仅包含6项，在84组现有实验数据上的描述性拟合R^2为0.9948、MAPE为1.129%、MaxErr为3.873%，可用于本文机组在T_a=-25～40℃、T_o=95～120℃范围内的COP快速估算。

（4）模型选择应根据应用场景进行权衡：BP神经网络适用于精度优先的预测任务；代理-二次关联式适用于需要快速查算或嵌入控制程序的场景。本文数据来自单台机组的规则工况测试，因此结论仅适用于给定机组和温度范围内的插值预测；后续可通过补充非网格工况、重复测量和不同机组数据，进一步评价其跨工况与跨设备适用性。并在此基础上，进一步结合换热器温度端差、压缩机效率与转速、节流装置压差等设备运行状态数据，将这些内部测点纳入建模，开展面向变工况控制策略和系统运行优化的研究，提升模型的物理可解释性与工程指导价值。

符号说明：

COP——制热性能系数
C_p——水的定压比热容，kJ/(kg·K)
M——设计矩阵列数
MAPE——平均绝对百分比误差
MaxErr——最大相对误差
N——样本数量
Q——制热量，kW
R^2——决定系数
RMSE——均方根误差
T_a——环境温度，℃
T_o——出水温度，℃
V_w——水的体积流量，m^3/s
W_e——压缩机输入电功率，kW
c——多项式系数向量
e——误差向量
$f(x)$——隐含层激活函数
x——神经网络输入变量
y_{dense}——代理模型在稠密查询点的COP响应向量
y_i——第i个样本的实测值
$\hat{y}_i$——第i个样本的预测值
——实测值均值
Δ_w——权值更新量
μ——阻尼系数
ρ_w——水的密度，kg/m^3
σ——S形（sigmoid）函数
$\boldsymbol{\Phi}$——多项式回归设计矩阵

参考文献

[1] 吴迪, 胡斌, 姜佳彤. R1233zd(E)高温热泵实验研究与应用分析[J]. 化工学报, 2025, **76**(S1): 377-383.
Wu D, Hu B, Jiang J T. Experimental study and application analysis of R1233zd(E)high temperature heat pump[J]. CIESC Journal, 2025, **76**(S1): 377-383.

[2] 胡斌, 姜佳彤, 吴迪, 等. 工业高温热泵发展现状与展望[J]. 制冷学报, 2023, **44**(6): 1-12.
Hu B, Jiang J T, Wu D, et al. Development status and prospects of industrial high-temperature heat pumps[J]. Journal of Refrigeration, 2023, **44**(6): 1-12.

[3] Arpagaus C, Bless F, Uhlmann M, et al. High temperature heat pumps: Market overview, state of the art, research status, refrigerants, and application potentials[J]. Energy, 2018, **152**: 985-1010.

[4] Bamigbetan O, Eikevik T M, Nekså P, et al. Review of vapour compression heat pumps for high temperature heating using natural working fluids[J]. International Journal of Refrigeration, 2017, **80**: 197-211.

[5] Dong B, Zhao Y, Wei W, et al. Performance analysis of a high-temperature heat pump using R744/R134a mixture[J]. Applied Thermal Engineering, 2021, **192**: 116942.

[6] Hwang Y J, Park N. Virtual design on the heat pump refrigeration cycle: challenges and approaches[J]. International Journal of Air-Conditioning and Refrigeration, 2024, **32**(1): 8.

[7] Mohanraj M, Jayaraj S, Muraleedharan C. Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems: a review[J]. Renewable and Sustainable Energy Reviews, 2012, **16**(2): 1340-1358.

[8] Suresh V, Kishore P S. Optimization of heat pump system using artificial neural networks for performance enhancement[J]. Journal of Energy Resources Technology, 2018, **140**(5): 052001.

[9] 颜建国, 郑书闽, 郭鹏程, 等. 基于GA-BP神经网络的超临界CO_2传热特性预测研究[J]. 化工学报, 2021, **72**(9): 4649-4657.
Yan J G, Zheng S M, Guo P C, et al. Prediction of heat transfer characteristics for supercritical CO_2 based on GA-BP neural network[J]. CIESC Journal, 2021, **72**(9): 4649-4657.

[10] 刘根, 孙仲顺, 张博, 等. 机器学习驱动的生物质热解模型建立及挥发分化学链重整制氢工艺优化[J]. 化工学报, 2024, **75**(11): 4333-4347.
Liu G, Sun Z S, Zhang B, et al. Establishment of machine learning-driven biomass pyrolysis model and optimization of volatiles chemical looping reforming hydrogen production process [J]. CIESC Journal, 2024, **75**(11): 4333-4347.

[11] 陈治宏, 吴佳伟, 楼小玲, 等. 化学品生物制造过程机器学习的研究进展[J]. 化工学报, 2025, **76**(8): 3789-3804.
Chen Z H, Wu J W, Lou X L, et al. Recent advances in machine learning for biomanufacturing of chemicals[J]. CIESC Journal, 2025, **76**(8): 3789-3804.

[12] 欧阳洪生, 张董鑫, 岑淑婷, 等. 新型环保工质HP-1物性和高温热泵应用特性研究[J]. 制冷学报, 2025, **46**(1): 16-23.
Ouyang H S, Zhang D X, Cen S T, et al. Physical properties and high-temperature heat pump application characteristics of the new environmentally friendly refrigerant HP-1[J]. Journal of Refrigeration, 2025, **46**(1): 16-23.

[13] 常德鹏, 王日颖, 孙岩雷, 等. 用于120 ~ 150℃蒸汽生产的超高温空气源自由活塞斯特林热泵性能研究[J]. 工程热物理学报, 2023, **44**(11): 2967-2973.
Chang D P, Wang R Y, Sun Y L, et al. Study on performance of ultra-high temperature air source free piston stirling heat pump for producing 120-150℃ steam[J]. Journal of Engineering Thermophysics, 2023, **44**(11): 2967-2973.

[14] 何宇佳, 成家豪, 常萌萌, 等. 一种用于供暖的改进式机械过冷跨临界CO_2热泵[J]. 工程热物理学报, 2021, **42**(11): 2771-2774.
He Y J, Cheng J H, Chang M M, et al. A modified transcritical CO_2 heat pump with mechanical subcooling for heating[J]. Journal of Engineering Thermophysics, 2021, **42**(11): 2771-2774.

[15] Mohanraj M, Jayaraj S, Muraleedharan C. Performance prediction of a direct expansion solar assisted heat pump using artificial neural networks[J]. Applied Energy, 2009, **86**(9): 1442-1449.

[16] Mathioulakis E, Panaras G, Belessiotis V. Artificial neural networks for the performance prediction of heat pump hot water heaters[J]. International Journal of Sustainable Energy, 2018, **37**(2): 173-192.

[17] Yu X H, Zhang Y F, Zhang Y, et al. Intelligent prediction on performance of high-temperature heat pump systems using different refrigerants[J]. Journal of Central South University, 2018, **25**(11): 2754-2765.

[18] Yu Z, Narsilio G, Makasis N, et al. Artificial neural networks for predicting the performance of heat pumps with horizontal ground heat exchangers[J]. Frontiers in Energy Research, 2024, **12**: 1423695.

[19] Marquardt D W. An algorithm for least-squares estimation of nonlinear parameters[J]. Journal of the Society for Industrial and Applied Mathematics, 1963, **11**(2): 431-441.

[20] Hagan M T, Menhaj M B. Training feedforward networks with the Marquardt algorithm[J]. IEEE Transactions on Neural Networks, 1994, **5**(6): 989-993.