

文章编号:0253-4339(XXXX)XX-0001-08

doi: 10.12465/issn.0253-4339.20260601001

应用于电机散热的热管性能特性及预测模型对比

李雪强¹ 张植青¹ 张一凡¹ 林心悦¹ 刘圣春¹ 张成明²

(1 天津商业大学 天津市制冷技术重点实验室,天津 300134; 2 哈尔滨工业大学电气工程及自动化学院,哈尔滨 150006)

摘要 电机高功率密度化使其热管理问题日趋严峻,准确预测热管等效导热系数对电机散热设计至关重要。针对电机散热系统中热管性能及性能预测问题,本文以等效导热系数为评价指标,实验研究了热源功率、冷凝段与蒸发段的相对位置、弯折角度等关键参数对热管传热性能的影响机制。在此基础上建立并对比了遗传算法优化的反向传播神经网络(GA-BPNN)、卷积神经网络(CNN)、最小二乘支持向量机(LSSVM)、随机森林(RF)与极端梯度提升(XGBoost)5种机器学习模型的性能。结果表明:重力与弯折角度对热管的导热性能影响最大,上方侧90°弯折的热管导热性能最好,其导热性能是下方侧的30倍;XGBoost模型的平均绝对百分比误差为3.72%,决定系数为0.95,均方根误差仅次于GA-BPNN模型,在所选的5种模型中的精度最高,且训练时间小于2 s;XGBoost模型的预测表明不同安装位置及弯折角度的热管性能不尽相同,为了提高电机各绕组的均温性,推荐弯折角度为0°的热管用于电机散热中。

关键词 电机;热管;等效导热系数;机器学习

中图分类号: TK172.4; TM301.4; TP181

文献标识码: A

Heat Pipe Performance Characteristics and Prediction Models for Motor Heat Dissipation

Li Xueqing¹ Zhang Zhiqing¹ Zhang Yifan¹ Lin Xinyue¹ Liu Shengchun¹ Zhang Chengming²

(1. Tianjin Key Laboratory of Refrigeration Technology of Tianjin, Tianjin University of Commerce, Tianjin 300134, China; 2. Department of Electrical Engineering and Automation, Harbin Institute of Technology, Harbin 150006, China)

Abstract Electric motors are developing towards high power density and miniaturization, making thermal management increasingly critical. This study investigated the influence mechanisms of key parameters, such as the heat source power, position between evaporator and condenser side, and bending angle, on the heat transfer performance of heat pipe. Moreover, comparative analyses were performed on the prediction performance of five machine learning models: genetic algorithm optimized back propagation neural network (GA-BPNN), convolutional neural network (CNN), least squares support vector machine (LSSVM), random forest (RF), and extreme gradient boosting (XGBoost). The results indicate that: the coupled detrimental effects of gravity and bending angle on the capillary wick structure govern the heat transfer performance; under a 90° bending angle at 60-W heat source power, the side arrangement of the condenser above evaporator achieves the best equivalent thermal conductivity, which is 30 times that of the condenser under evaporator. The mean absolute percentage error of XGBoost is 3.72%, coefficient of determination is 0.95, root mean square error only higher than that of the GA-BPNN model, and training time is less than 2 s, demonstrating the best performance among five models. The prediction results of XGBoost model illustrate that different positions and bending angles lead to different dissipation performances. To improve the temperature uniformity in the winding of motor, a heat pipe with 0° bending angle is recommended for the heat dissipation of motor.

Keywords motor; heat pipe; equivalent thermal conductivity; machine learning

随着电气化交通产业的快速发展,电机作为新能源汽车、电动飞机等高新技术产业的核心部件,其

重要性日益凸显^[1]。现阶段电机正朝着高功率密度以及小型化的方向发展,随之带来发热量陡增,散热

收稿日期:2026-06-01;修回日期:2026-06-22;录用日期:2026-06-25

责任编辑:

基金项目:国家自然科学基金资助项目(52077044)。(The project was supported by the National Natural Science Foundation of China (No. 52077044).)



移动阅读

困难等一系列问题。若电机产生的热量不能及时排出,将导致电机内部温度的升高,进而加速器件损耗、老化和永磁体退磁,不仅缩短电机使用寿命,还会诱发各类安全故障^[2]。

当前,电机散热的方式主要为风冷和液冷^[3]。风冷采用自然对流或者强迫对流的形式进行散热,其优点是结构简单、成本低、维护便捷,但散热能力有限,难以匹配高热负荷电机的冷却需求^[4]。现有风冷优化研究多聚焦于采用多通道气流路径增强散热,例如在电机的轴向和径向同时布置通风道以形成立体冷却风道^[5],相比于仅在内部使用单通道风扇的电机,可使总体温度降低5%。液冷则通过水冷套或油冷回路的方式进行高效换热,液冷冷却方式最大的优势在于冷却效果好,例如,水冷及油冷的相对冷却能力分别是强迫式风冷的20倍、50倍以上^[6];喷嘴式能在低流量下提升可观的散热性能^[7]。但液冷系统结构复杂、制造成本偏高,制约了其在低成本、小型化电机中的推广应用^[8]。热管作为一种高效的导热器件,近年来在国内外引起了广泛关注。研究表明,将热管布置于电机的关键发热部位(如绕组、转子或定子槽底部)可以显著降低电机的温度。例如,通过改善线圈末端传热的设计^[9],可以使电机温升降低13.7%~19.6%;而采用冷却转子的特定冷却结构^[10],可以使转子、定子铁芯和绕组的温升分别降低70.39%、69.4%和46.18%。此外,在电机定子槽底部布置热管^[11],冷却效果尤为显著,可使电机绕组温升降低19 K,并延长电机过载运行时间12.7%。

受热管工作机制限制,将热管应用于电机散热时,需重点考虑热管在复杂工况下的等效导热系数,例如热源功率、热管的弯折角度以及冷凝段和蒸发段的相对位置等。当前获取热管传热性能的手段主要分为实验测试、数值模拟与机器学习预测3类。采用实验测试的方法可以获得精准的热管性能,并指导电机散热系统的设计。田金颖等^[12]采用实验测试方法,表明不同热源分布形式会影响热管传热性能评价。但实验测试存在周期长、设备投入成本高的缺陷。而赵萧涵等^[13]使用数值模拟的方法,采用VOF模型将饱和温度和工质物性变化引入模型中,对U型重力热管启动过程进行建模,其模拟结果与实验值平均误差仅为5 K。然而在面对多参数耦合工况时,物理模型模型构建复杂,计算成本较高。而机器学习模型能在保证结果精度的前提下,对热管的性能进行快速预测^[14]。I. J. Jin等^[15]使用卷积神经网络模型,将倾斜角、填充率等输入特征纳入到输入特征值中,其预测结果的误差可降至7%以下。H.

Maddah等^[16]使用反向传播神经网络模型,将普朗特数和充液率作为输入特征,可将预测值与真实值的拟合程度提升至0.99。Huang Guanghan等^[17]利用随机森林模型将热负荷和充液率作为输入特征来预测等效导热系数,体现了机器学习方法在复杂工况下热管性能预测中的应用潜力。

综上所述,现有研究主要针对单一机器学习模型进行热管性能预测,而不同机器学习模型在预测精度、预测稳定性和计算效率的研究尚缺乏系统对比。为此,本文首先通过实验研究了热源功率、蒸发段与冷凝段相对位置、热管弯折角度对热管传热性能的影响;在此基础上对比分析了5种机器学习模型,分别为遗传算法优化的反向传播神经网络(genetic algorithm-back propagation neural network, GA-BPNN)、卷积神经网络(convolutional neural network, CNN)、最小二乘支持向量机(least squares support vector machine, LSSVM)、随机森林(random forest, RF)和极端梯度提升(extreme gradient boosting, XGBoost)。选取平均绝对百分比误差(mean absolute percentage error, MAPE)、决定系数(coefficient of determination, R^2)、均方根误差(root mean square error, RMSE)和运行时间作为评价指标。本文的研究工作为电机散热的热管性能预测模型的选择提供参考。

1 热管工作原理及实验系统

1.1 热管结构及工作原理

热管的结构及工作原理如图1(a)所示。电机运行过程中产生的热量从绕组传递至热管的蒸发段,管内工质吸热发生相变,从液体变成气体并流向冷凝段。蒸气在冷凝段放热冷凝为液体,通过重力与毛细抽力的协同作用返回至蒸发段完成相变传热循环。基于电机的装配需求,热管需要进行一定角度的弯折,但弯折将影响热管内部毛细结构的完整性,从而削弱热管的整体换热性能。热管应用于电机绕组散热的装配结构如图1(b)所示。将热管蒸发段嵌入定子绕组间隙,利用热管内部的相变换热实现电机绕组的高效散热。热管在弯折后,其冷凝段与蒸发段形成3种不同的相对位置:冷凝段在蒸发段上方(上方侧)、冷凝段在蒸发段侧方(侧方侧)以及冷凝段在蒸发段下方(下方侧)。不同相对位置下重力对工质回流的作用不同,从而导致热管导热性能的不同。

1.2 热管特征参数及输入特征值的选取

为系统探究不同因素对热管的性能影响,并为




图1 热管的结构及在电机上的排布方式

Fig. 1 Heat pipe structure and arrangement on motors

机器学习模型构建多维特征空间,本文将对热管等效长度、热管弯折角度、相对位置等在内的13种参数(输入特征)进行综合分析,其物理意义如表1所示。

表1 热管特征参数

Tab.1 Heat pipe characteristic parameters

参数	物理意义
热管等效长度 L_{eff}	热管的等效传热距离
热管总长度与热管直径比 F	热管的长径比相关参数
热管总长度与热管横截面积比 I	热管的长径比特征
蒸发段与热管总长度比 e	热管蒸发段相对总长度的占比
冷凝段与热管总长度比 c	热管冷凝段相对总长度的占比
热源功率 Q	蒸发段表面总加热功率
工质充液率 β	工作流体容积占比
工质普朗特数 Pr	工质边界层与流动边界层的相对厚度关系
工质品质因数 M	工质相变换热性能
冷凝段外努赛尔数 Nu	冷凝段外部对流换热的强度
环境温度 T_i	冷凝段外侧环境温度
弯折角度 θ	热管弯折的几何角度,间接反映吸液芯结构被破坏的程度
相对位置 P	冷凝段与蒸发段的相对位置

1.3 热管性能评价指标

本文采用等效导热系数(K_{eff})作为热管的性能评价指标。该参数为热管在稳态工作状态下表现出的整体导热能力,其数值越大代表导热的性能越好。等效导热系数 K_{eff} ($\text{kW}/(\text{m}\cdot\text{K})$) 计算如下:

$$K_{\text{eff}} = \frac{L_{\text{eff}}}{R_{\text{total}} A} = \frac{L_{\text{total}} - \frac{1}{2}(L_e + L_c)}{\left[\frac{\Delta T}{(q \pi d L_e)} \right] \left[\frac{1}{4}(\pi d^2) \right]} \quad (1)$$

$$q = 2\pi L_e \lambda_{\text{cu}} \frac{(T_o - T_e)}{(\pi d L_e) \ln\left(\frac{D}{d}\right)} \quad (2)$$

式中: L_{eff} 为热管等效长度, mm; R_{total} 为总热阻, K/W ; A 为热管横截面积, mm^2 ; ΔT 为蒸发段与冷凝段中心点温度差, $^{\circ}\text{C}$; λ_{cu} 为铜的导热系数, $\text{kW}/(\text{m}\cdot\text{K})$; L_e 为蒸发段长度, mm; d 为热管直径, mm; D 为导热层外径, mm; q 为热管蒸发段表面的热流密度, W/m^2 ; T_o 为运行温度, $^{\circ}\text{C}$; T_e 为蒸发段壁面温度, $^{\circ}\text{C}$ 。

2 机器学习模型

2.1 机器学习模型参数设置

基于当前主流的机器学习算法,本文选取了神经网络、支持向量机以及集成模型3类代表性算法。为了全面对比不同模型的预测精度、预测稳定性和计算效率,本文针对热管性能预测选取了5种机器学习模型,模型设置如表2所示。

2.2 机器学习模型评测指标

本文所使用的机器学习模型评测指标为决定系数 R^2 、平均绝对百分比误差(mean absolute percentage error, MAPE)、均方根误差(root mean square error, RMSE)以及训练时间。 R^2 表征模型对目标变量方差的拟合程度; MAPE 为预测值相对于真实值的平均绝对偏差百分比,用于评估预测值误差的相对水平; RMSE 为衡量预测值与真实值的误差,可用于评估模型预测的稳定性。训练时间为模型从开始训练到完成训练的完整过程所需时间,用于评估模型的训练开销以及工程适用性。 R^2 、MAPE 以及 RMSE 的计算如下:

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_{\text{pre}, i} - Y_{\text{exp}, i})^2}{\sum_{i=1}^N (Y_{\text{pre}, i} - \bar{Y}_{\text{exp}, i})^2} \quad (3)$$

$$E_{\text{MAP}} = \frac{1}{N} \sum_{i=1}^N \left(\frac{|Y_{\text{pre}, i} - Y_{\text{exp}, i}|}{Y_{\text{exp}, i}} \times 100\% \right) \quad (4)$$

表 2 不同机器学习模型参数设置
Tab.2 Parameter setting of different machine learning models

模型名称	超参数	值
GA-BPNN	隐藏层节点数	15
	种群规模	75
	遗传代数	150
	交叉率	0.8
	变异率	0.05
CNN	学习率	0.001
	卷积层数	3
	卷积核数量	32
	卷积核尺寸	2
	全连接层节点数	64
RF	学习率	0.003
	决策树数量	373
	最大树深度	8
	最小分裂样本数	3
	最小叶节点样本数	3
XGBoost	最大树深度	6
	弱学习器数量	180
	行采样率	0.75
	列采样率	0.83
	学习率	0.005
LSSVM	核函数类型	RBF
	正则化参数	125
	核宽度参数	2

$$E_{\text{RMS}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{\text{pre},i} - Y_{\text{exp},i})^2} \quad (5)$$

式中： E_{MAE} 为平均绝对百分比误差； E_{RMS} 为均方根误差； N 为数据集样本量； $Y_{\text{pre},i}$ 为预测值，kW/(m·K)； $Y_{\text{exp},i}$ 为实验值，kW/(m·K)； $\overline{Y_{\text{exp},i}}$ 为实验算数平均值，kW/(m·K)。

3 实验系统描述

图 2 所示为热管性能测试实验系统。该系统由热管、加热系统、冷却系统和数据采集系统组成。热管材质为铜，工质采用去离子水。利用电热丝模拟热源，配合带有风管的轴流风机对热管进行散热，实验时保持风管与热管冷凝段同轴。利用热电偶采集热管各测点温度，热线风速仪采集轴流风机的流场风速。为测试不同位置下的热管换热性能，对热管

进行不同角度的弯折(图 2 右侧)，实验系统参数如表 3 所示。




图 2 热管性能测试实验系统
Fig.2 Heat pipe testing experimental system

表 3 实验系统参数定义
Tab. 3 Parameters of experimental system

类型	项目	参数	数值
热管	尺寸	直径/mm	4
		总长度/mm	180
		弯折角度	0°~180°
加热系统	材料	铜	—
	吸液芯	充液率/%	0.2
	工作流体	去离子水	—
	漆皮电热丝	电功率/W	10~60
冷却系统	导热层	导热层直径×热管直径× 导热层长度/mm	40×4×50
	风管	风管直径×风管长度/m	0.2×2
		空气温度/℃	20
		风速/(m/s)	4
数据采集系统	轴流风机	输入电压/V	220
	热电偶	精度/℃	±0.1
		工作范围/℃	0~200

4 结果分析

4.1 热管性能实验结果

图 3 所示为热管冷凝段与蒸发段不同相对位置及不同弯折角度对热管传热性能的影响。由图 3 可知，随着热源功率的增大，热管的等效导热系数呈现下降趋势。这是由于热管内部的相变循环到达了换热极限(例如蒸发段干涸、内部压降激增、吸液芯压差驱动不足等)。以弯折角度 0° 举例，当热源功率从

10 W 增大至 30 W 时,热管处于高效换热状态,此时热管的等效导热系数从 $76.6 \text{ kW}/(\text{m}\cdot\text{K})$ 下降至 $73.9 \text{ kW}/(\text{m}\cdot\text{K})$,导热性能仅降低 3.5%。当功率进一步由 30 W 增大至 50 W 时,热管达到换热极限,等效导热系数降低 73%。继续增大热源功率,热管传热机制逐步由工质导热转变为管壁导热主导,该阶段的等效导热系数降低 40%。




图3 不同方位下的等效导热系数随热源功率的变化

Fig.3 Variation trend of equivalent thermal conductivity of heat source power at different positions


由于吸液芯结构的改变,不同的弯折角度也会较大程度的影响热管性能。以侧方侧为例,在 10 W 时,随着弯折角度从 0° 至 180° 发展,热管的等效导热系数从 $76.6 \text{ kW}/(\text{m}\cdot\text{K})$ 下降至 $26.9 \text{ kW}/(\text{m}\cdot\text{K})$,导热性能降低 65%。值得注意的是,在该相对位置下,当


热源功率为 60 W 时,不同弯折角度的热管等效导热系数差距较小,这是由于此时热管的等效导热系数逐渐趋于管壁材料导热性能,因此弯折对热管内部吸液芯的影响不再趋于主导地位。

此外,在重力的作用下,热管蒸发段与冷凝段不同的相对位置也会导致热管性能的差距。例如,在热源功率为 60 W、弯折角度为 90° 时,上方侧的等效导热系数是侧方侧的 4.4 倍;是下方侧的 30 倍。这表明重力和毛细力的耦合作用共同决定了热管性能。


4.2 机器学习模型预测性能对比

图4所示为5种机器学习模型在相同条件下的性能预测对比。由图4可知,XGBoost模型的MAPE值为3.7%,预测精度在5类模型中最优;其次是GA-BPNN、CNN、RF。LSSVM模型的精度为5种模型中最差的,MAPE值为8.7%。而对于预测值与真实值的拟合度而言,XGBoost最好, R^2 为0.95;拟合度最差的仍是LSSVM模型, R^2 为0.83。对于预测稳定性方面,GA-BPNN的预测稳定性最高,其RMSE值为 $1.33 \text{ kW}/(\text{m}\cdot\text{K})$,其次是XGBoost、CNN、RF,LSSVM。综合上述3项评价指标对比结果可知,XGBoost模型的综合性能最好。






(c) CNN



(d) RF



(e) LSSVM

图4 不同机器学习模型性能预测结果对比

Fig.4 Performance comparison among different tuned machine learning models

图5所示为不同机器学习模型的训练时间的对比。由图5可知,RF、XGBoost、LSSVM这3种模型的训练时间均不足2s,而GA-BPNN、CNN模型训练时间分别为286、58s。RF、XGBoost、LSSVM模型体现了训练时间短的优势,这是因为RF、XGBoost模型由于树模型的贪心算法递归结构不需要大量构建迭代优化,而LSSVM模型则是其独特的线性方程组可直接获得解析解,从而大幅削减训练时间。




图5 不同机器学习模型的训练时间对比

Fig.5 Training time comparison for different machine learning models

综合模型精度、拟合度、预测稳定性及训练时间多项指标对比结果,XGBoost模型的表现最优,因此,本文选取该模型作为预测热管性能的机器学习模型。

4.3 基于XGBoost模型的性能预测

本节采用XGBoost模型对热管的换热性能进行预测,预测结果如图6所示。由图6可知,当热管蒸发段和冷凝段的相对位置不同时,热管传热性能存在明显差异。例如当冷凝段在蒸发段上方时,等效导热系数随着弯折角度的增大而呈现先升高后下降的趋势;在弯折角度 90° 时到达最大等效导热系数,为 $43.5 \text{ kW}/(\text{m} \cdot \text{K})$ 。结合电机的实际运行情况,应减小各绕组温差,保证不同安装位置下热管的等效导热系数相差较小。由图6还可知,弯折角度为 90° 时,该差异最为明显,上方侧与下方侧的导热系数相差近30倍。仅当热管弯折角度为 0° 时,不同布置位置




图6 不同相对位置下热管等效导热系数分布特性

Fig.6 Distribution characters of equivalent thermal conductivity at different position

下的等效导热系数保持一致,可保证电机的温度均匀性。因此在电机散热过程中,推荐使用 0° 弯折角度的热管。

5 总结

本文开展了不同弯折角度,不同冷凝段与蒸发段相对位置的实验研究,建立了5种不同的机器学习模型,并进行性能对比。基于实验和模型结果,得到如下结论:

1)在重力与热管弯折的共同作用下,不同相对位置的性能差距显著,弯折角度为 90° 时重力对热管的换热性能影响较大,此时上方侧的换热性能是下方侧的30倍。因此,在利用热管进行散热时需同时考虑弯折角度和相对位置对换热性能的影响。

2)在5种主流机器学习模型中,XGBoost预测速度快,训练耗时不足2 s。同时该模型的预测精度高,MAPE仅为3.72%, R^2 为0.95, RMSE仅次于GABPNN模型。因此该模型可作为预测热管性能的机器学习模型的首选。

3)XGBoost模型的预测结果表明,热管传热性能随安装位置与弯折角度发生明显变化。为改善电机各绕组的均温性,推荐弯折角度为 0° 的热管用于电机散热中。

本文受天津市自然科学基金资助项目资助(25JCYBJC0030)。(The project was supported by the Tianjin Natural Science Foundation of Tianjin (No. 25JCYBJC00030).)

参考文献

- [1] Wang Jinghui, Rakha H A. Electric train energy consumption modeling[J]. Applied Energy, 2017, 193: 346–355.
- [2] 江从喜, 赵兰萍, 杜旭之, 等. 基于整车工况的电动汽车轮毂电机散热分析[J]. 中国机械工程, 2016, 27(13): 1839–1845. (Jiang Congxi, Zhao Lanping, Du Xuzhi, et al. Thermal analysis on in-wheel motor under whole electric vehicle driving conditions [J]. China Mechanical Engineering, 2016, 27(13): 1839–1845.)
- [3] 毛正松, 陆永卷, 欧阳石坤, 等. 增程器风冷电机散热方案仿真分析及测试验证[J]. 内燃机与配件, 2023(5): 27–29. (Mao Zhengsong, Lu Yongjuan, Ouyang Shikun, et al. Simulation analysis and test verification of an air cooled E-motor heat dissipation design for range extender [J]. Internal Combustion Engine & Parts, 2023(5): 27–29.)
- [4] 陈前, 周亚南, 徐高红, 等. 混合转子永磁电机双风道冷却系统设计[J]. 电气工程学报, 2024, 19(2): 1–8. (Chen Qian, Zhou Yanan, Xu Gaohong, et al. Design of dual air duct cooling system for hybrid rotor permanent magnet motor [J]. Journal of Electrical Engineering, 2024, 19(2): 1–8.)
- [5] 张良, 陈克, 张得胜, 等. 纯电动巴士电机驱动器冷却系统的设计和分析[C]//2014中国汽车工程学会年会论文集. 2014: 93–95. (Zhang Liang, Chen Ke, Zhang Desheng, et al. Design and analysis of cooling system for motor drive of pure electric bus [C]//Proceedings of 2014 SAE China Annual Conference. 2014: 93–95.)
- [6] Li Chenxi, Li Ji. Passive cooling solutions for high power server CPUs with pulsating heat pipe technology: review [J]. Frontiers in Energy Research, 2021, 9: 755019.
- [7] Liu Chuan, Xu Zeyuan, Gerada D, et al. Experimental investigation on oil spray cooling with hairpin windings[J]. IEEE Transactions on Industrial Electronics, 2020, 67(9): 7343–7353.
- [8] Li Ye, Li Qi, Fan Tao, et al. Heat dissipation design of end winding of permanent magnet synchronous motor for electric vehicle[J]. Energy Reports, 2023, 9: 282–288.
- [9] Wang Huimin, Zhang Chujie, Guo Liyan, et al. Novel revolving heat pipe cooling structure of permanent magnet synchronous motor for electric vehicle [J]. Applied Thermal Engineering, 2024, 236: 121641.
- [10] Chen Zutao, Yu Zhongjun, Fu Jia, et al. Analysis and design of air-heat pipe composite cooling of high power density motor [J]. Applied Thermal Engineering, 2024, 236: 121495.
- [11] Alamar A A, Al-Dadah R K, Mahmoud S M. Numerical investigation of effect of fill ratio and inclination angle on a thermosiphon heat pipe thermal performance [J]. Applied Thermal Engineering, 2016, 108: 1055–1065.
- [12] 田金颖, 诸凯, 刘建林, 等. 冷却电子芯片的平板热管散热器传热性能研究[J]. 制冷学报, 2007, 28(6): 18–22. (Tian Jinying, Zhu Kai, Liu Jianlin, et al. Experiments investigation on thermal conductivity of flat heat pipes used to cool electric die [J]. Journal of Refrigeration, 2007, 28(6): 18–22.)
- [13] 赵萧涵, 刘圣春, 李雪强, 等. U型重力热管启动过程中压力和温度的演变规律[J]. 制冷学报, 2024, 45(6): 106–113. (Zhao Xiaohan, Liu Shengchun, Li Xueqiang, et al. Evolution of pressure and temperature during start-up process in U-shaped gravity heat pipe [J]. Journal of Refrigeration, 2024, 45(6): 106–113.)
- [14] Wansasueb K, Promthaisong P, Bubphachot B, et al. Applied machine learning: Performance prediction of heat pipe with mesh wick [J]. Case Studies in Thermal Engineering, 2024, 63: 105307.
- [15] Jin I J, Park Y Y, Bang I C. Heat transfer performance prediction for heat pipe using deep learning based on wick

- type[J]. International Journal of Thermal Sciences, 2024, 197: 108806.
- [16] Maddah H, Ghazvini M, Ahmadi M H. Predicting the efficiency of CuO/water nanofluid in heat pipe heat exchanger using neural network [J]. International Communications in Heat and Mass Transfer, 2019, 104: 33–40.
- [17] Huang Guanghan, Li Wenming, Zhong Guisheng, et al. Optimizing L-shaped heat pipes with partially-hybrid mesh-groove wicking structures [J]. International Journal of Heat and Mass Transfer, 2021, 170: 120926.

通信作者简介

刘圣春,男,教授,天津商业大学机械工程学院,13920682426, E-mail:liushch@tjcu.edu.cn。研究方向:CO₂制冷热泵,制冷系统优化及节能技术,冷冻冷藏技术,相变储能及新能源利用。

About the corresponding author

Liu Shengchun, male, professor, School of Mechanical Engineering, Tianjin University of Commerce, 86-13920682426, E-mail: liushch@tjcu.edu.cn. Research fields: trans critical CO₂ heat pump systems, system optimization and energy efficiency enhancement, refrigeration and freezing technologies, phase change materials for thermal energy storage and renewable energy utilization.