研究论文|Research Article
数智技术协同创新|Digital Intelligent Technologies

Open Access

引用格式:郭蓉, 许东阳, 杨林燚, 等. 基于混合核最小二乘支持向量机的 S 型热电偶高精度补偿方法 [J]. 海南大学学报(自然科学版中英文), 2026, 44(2): 204−216.

Citation: GUO Rong, XU Dongyang, YANG Linyi, et al. A nonlinear compensation method of thermocouple based on least squares support vector machine with hybrid kernels[J]. Natural Science of Hainan University, 2026, 44(2): 204−216.

基于混合核最小二乘支持向量机的 S 型热电偶高精度补偿方法

郭　蓉, 许东阳, 杨林燚, 唐　浩, 徐　博✉

(海南大学 信息与通信工程学院, 海南 海口 570228)

摘　要: 为改善热电偶传感器本身的非线性特性, 尤其针对在−50 ~ 1 768 ℃ 的宽温度范围的航天发动机温度测试中 S 型热电偶表现出线性度较差的问题, 本文通过基于混合核最小二乘支持向量机构建非线性补偿模型对热电偶测试系统进行补偿。首先, 利用高斯径向基核和多项式核构造混合核函数, 解决单一核函数局部细节和全局映射无法平衡的问题, 保证了在数据处理过程中高维特征空间的线性可分性; 其次, 提出基于改进粒子群算法的核参数寻优算法, 引入概率突跳策略增强算法的局部跳出能力, 设计自适应惯性权重和学习因子更新策略调整搜索空间, 保证算法的求解精度及收敛速度。实验结果表明, 本文提出的方法相比于 BP 神经网络方法, 最大绝对误差减少了 0.260 ℃, 补偿后的最大拟合误差为 0.380 ℃, 准确率为 98.960%, 满足实际航天发动机的宽测温范围的高精度测试要求。

关键词: 非线性补偿; 混合核函数; 概率突跳策略; 高精度测试

中图分类号: G232　　**文献标志码:** A　　**文章编号:** 1004-1729(2026)02-0204-13

DOI: 10.65658/j.hndk.2025091802　　CSTR: 32403.14.hndk.2025091802

A nonlinear compensation method of thermocouple based on least squares support vector machine with hybrid kernels

GUO Rong, XU Dongyang, YANG Linyi, TANG Hao, XU Bo✉

(School of Information and Communication Engineering, Hainan University, Haikou 570228, China)

Abstract: To address the pronounced nonlinear characteristics of thermocouple sensors, particularly for the poor linearity exhibited by Type S thermocouples over a wide temperature range of −50~1 768 ℃ in aerospace engine temperature testing, this paper develops a nonlinear compensation model based on hybrid kernel least squares support vector machines to compensate the thermocouple measurement system. Firstly, a hybrid kernel function is constructed by combining radial basis function and polynomial kernels to overcome the inability of single kernel functions to balance local details and global mapping, thereby ensuring linear separability in high-dimensional feature spaces during data processing. Secondly, an improved particle swarm optimization algorithm is proposed for kernel parameter optimization. This enhanced particle swarm optimization incorporates a probability mutation strategy to strengthen its ability to escape local optima, along with adaptive

Received: 2025−09−18; **Revised:** 2025−10−29; **Accepted:** 2025−10−29.
✉ **Corresponding author(s):** XU Bo, 996458@hainanu.edu.cn.

inertia weight and learning factor update strategies designed to adjust the search space dynamically, ensuring both solution accuracy and convergence speed. Experimental results demonstrate that compared with the backpropagation neural network method, the proposed approach reduces the maximum absolute error by 0.260 ℃, achieving a post-compensation maximum fitting error of 0.380 ℃ and an accuracy rate of 98.960%, meeting the stringent requirements for high-precision temperature measurements across broad ranges in practical aerospace engines.

Keywords: nonlinear compensation; hybrid kernel function; probability mutation strategy; high-precision measurement

0 引 言

作为飞行器的“心脏”,航天发动机需要在极端环境下稳定工作,承受高温、高压和高转速等多重考验。其中,发动机热端部件工作环境极为严酷,涡轮前温度可达 1 700 ℃ 以上。根据航天工业行业标准,航天发动机要求的测温范围是−50 ~ 1 768 ℃,且在该温度范围下精度要求为±1 ℃。因此,亟需一种宽温度范围的高精度温度测试技术。S 型热电偶具有较宽的温度范围,且坚固耐用,适合用于温度要求较高的测温环境[1]。但其输入输出呈非线性特性,且在较低的测温范围误差较大,非线性误差在 1% 左右,难以满足航天发动机高精度测温的要求,需要通过建立补偿模型减小其非线性误差[2]。

热电偶非线性补偿模型按实现方式可分为硬件补偿法和软件补偿法。硬件补偿法通过硬件电路的方式构建补偿模型,消除可以修正的误差,在一定程度上可以改善实际测试中热电偶的误差,但额外的硬件补偿电路容易产生温度漂移,且使用的器件受到电子线路精度的限制,此类方案的非线性改善具有局限性且增加了额外的成本[3−4]。软件补偿法具备灵活性,可以根据实际的工况动态调整,提高补偿系统的适应性和准确性。软件补偿法有查表法、数学拟合法以及机器学习法等。其中,查表法作为最直接的非线性补偿方法,具有简单方便的特点,但由于表中数据有限,无法涵盖所有的电动势数据导致精度有限,该方法适用于对精度要求不高的场合。多项式拟合法[5−6] 比查表法更精细,仅适合非线性度简单的曲线拟合,且随着多项式阶数的增加容易导致过拟合。为了解决多项式过拟合的问题,近年来,机器学习被广泛用于高精度补偿领域,包括反向传播(back-propagation, BP)神经网络[7]、径向基函数(radial basis function, RBF)神经网络[8]、支持向量机(support vector machine, SVM)[9] 以及深度学习[1] 等方法,该类方法通过数据训练的方式获得无法通过表达式拟合的复杂补偿系统,补偿精度较高。但是基于 BP 神经网络的补偿方法过度依赖梯度下降,容易陷入局部最优;基于 RBF 神经网络的补偿方法在训练过程中随着数据样本的增多,隐藏层的中心和宽度选择困难;基于深度学习的补偿方法网络训练过程需要大量的数据样本支持,数据获取过程需要在高温等极端环境的反复测量,影响传感器使用寿命。基于最小二乘支持向量机(least squares support vector machine, LSSVM)的补偿方法在小样本条件下的复杂系统预测中得到了广泛的应用。魏明奎等[10] 将自组织特征映射神经网络与 LSSVM 相结合,充分结合了神经网络在特征聚类上的优势和支持向量机在回归预测上的高精度。但在宽测温范围且温度较高的极限环境中,该类补偿方法泛化能力差,无法满足高精度补偿需求。Liu 等[11] 提出将局部核与全局核混合,平衡算法的局部敏感性和全局适应性,解决泛化能力差的问题。文献 [12−14] 将 RBF 核与 Sigmoid 核混合,RBF 核与多项式(polynomial, Poly)核混合,从而在复杂数据分布下捕捉数据的细节特征及整体趋势,增强泛化能力。

虽然通过核混合可以提高模型的精度,但核混合后模型参数较多。通过传统的网格搜索或随机搜索算法容易造成维度灾难,且混合核参数间存在非线性耦合,传统梯度下降法会因局部最优而失效。智能优化算法被广泛用于自动搜索最优超参数组合,如模拟退火(simulated annealing, SA)[15]、粒子群算法(particle swarm optimization, PSO)[16−17]、遗传算法(genetic algorithm, GA)[18]、量子行为粒子群[19] 和云粒子群[20] 等,智能优化算法同时搜索不同区域避免逐点遍历,自动学习参数间的隐含关系。基于此,王子豪等[21] 提出基于免疫算法的 LSSVM 参数优化方法,通过迭代优化惩罚因子以及核函数参数,补偿传感器零位温

度系数与灵敏度温度系数,显著提高了传感器的温度稳定性。韩剑等[9]通过改进粒子群优化算法对惩罚参数和核函数参数进行高效的寻优,并应用于氨氮传感器的数据补偿。但该方法在寻优中求取的参数量较少,在面对混合核多参数的寻优中仍有陷入局部最优的风险。

针对单一核函数补偿精度有限且混合核函数参数选取困难的问题,本文提出一种基于混合核最小二乘支持向量机的S型热电偶高精度补偿方法。该方法构建融合全局核函数与局部核函数特性的最小二乘支持向量机模型,学习热电偶传感器温度与电动势之间复杂的非线性映射关系,并通过改进的粒子群算法快速、准确地寻求模型的最优参数组合,实现高精度的热电偶非线性补偿。

1 热电偶非线性补偿

1.1 热电偶静态特性 热电偶静态特性是指在热平衡条件下,其输出热电动势与测量端温度之间形成的确定性稳态映射关系,是热电偶实现温度传感功能的物理本质,也是评估热电偶的测量精度、长期稳定性及线性度等核心性能指标的基础依据。热电偶的热电转换过程基于塞贝克效应,对电极材料的电子能带结构、晶格振动模式及组分均匀性具有极强的依赖性,导致其输出热电动势与温度之间通常呈现显著的非线性特性。此非线性特性直接限制了热电偶的原始测量精度,尤其在宽温度范围内,若不加以补偿,将造成较大的测试误差。

1.2 非线性补偿原理 原始温度信号经过热电偶传感器后,由于热电偶传感器本身的非线性特性,转换过程中会引入一定的误差,需要构建非线性补偿模型。热电偶非线性补偿的原理框图如图1所示。误差通过补偿模型对热电偶系统模型的跟踪得以修正。

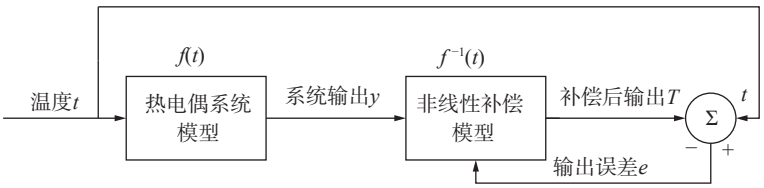


图1 热电偶补偿原理框图

图1中 t 为被测物体的温度,$f(t)$为含热电偶的测温系统模型,y为热电偶输出电动势,$f^{-1}(t)$为待求取的非线性补偿模型,T是补偿模型输出的温度,e是补偿模型的输出误差:$e=t-T$。逆建模方法通过目标函数 e 的反馈调整补偿模型参数,e 越小表明补偿结果越好,理想状态下为零,即实现补偿模型的输出温度 T 与被测物体真实温度相等。

2 所提方法

2.1 混合核最小二乘支持向量机 由于实际难以获得理想补偿模型的函数表达式[22],LSSVM的优势是使用少量样本就可以拟合出近似理想的系统模型。因此,补偿模型通过LSSVM对数据进行训练,拟合热电偶的温度−电压非线性曲线。同时,基于LSSVM的各类核函数不同的映射能力,选择合适的核函数组合,有利于进一步提高补偿模型精度。

2.1.1 *最小二乘支持向量机原理* LSSVM模型被广泛运用于解决多分类或者函数拟合问题,具有结构简单、学习能力强且所需训练样本少等优势。该模型的思想是通过核函数将低维输入空间的非线性关系映射至高维特征空间,转化为线性拟合问题,旨在求解以下问题以拟合超平面[23]。

求解一个对于训练数据$\{(\boldsymbol{x}_i,y_i),i=1,2,3,\cdots,n\}$距离最小的超平面:

$$\min_{\boldsymbol{w},\lambda,e}\left(\frac{1}{2}\|\boldsymbol{w}\|^2+\frac{\lambda}{2}\sum_{i=1}^{m}e_i^2\right) \tag{1}$$

其中,$\boldsymbol{x}_i$为输入向量,y_i为输出值,n为样本总数,$\boldsymbol{w}$为权重向量,λ 为用于确定模型复杂度和精度之间权衡的正则化参数,e_i 为输出的实际值和预测值之间的回归误差。

约束条件为

$$y_i = \boldsymbol{\omega}^{\mathrm{T}} \boldsymbol{\Phi}(\boldsymbol{x}_i) + b + e_i \tag{2}$$

其中, $\boldsymbol{\omega}^{\mathrm{T}}$为权重向量的转置; $\boldsymbol{\Phi}(\boldsymbol{x}_i)$是将输入数据$\boldsymbol{x}_i$映射到高维特征空间的映射函数, 可通过核函数间接实现; b是偏置项。为了求解上述二次规划问题, 采用拉格朗日乘数法求解, 可得回归模型的表达式为

$$y(x) = \sum_{i=1}^{m} \alpha_i K(\boldsymbol{x}, \boldsymbol{x}_i) + b \tag{3}$$

其中, α_i为拉格朗日乘子, $K(\boldsymbol{x}, \boldsymbol{x}_i)$表示核函数。核函数的作用为将数据从低维空间映射到高维空间, 避免“灾难维度”, 从而实现对复杂的函数进行拟合。根据 Mercer 定理, 核函数需满足半正定性[24−25]。

2.1.2 混合核函数 映射方式取决于核函数的选取, 不同核函数的特性不一样, 大致可分为局部核函数和全局核函数 2 类。局部核函数的整体特点是只对样本分布比较集中的局部数据学习能力强, 但推广泛化能力弱, 典型的局部核函数为 RBF 核。全局核函数的特点对分布较为分散的数据有较好的效果, 能获得更多的全局信息, 推广能力强, 但缺乏局部的学习能力, 典型的全局核函数包括 Poly 核、Line 核和 Sigmod 核等。具体核函数的关系式如下:

RBF 核函数:

$$K_{\mathrm{RBF}}(\boldsymbol{x}, \boldsymbol{x}_i) = \exp\left(\frac{-\|\boldsymbol{x} - \boldsymbol{x}_i\|^2}{2\sigma^2}\right),\ \sigma > 0 \tag{4}$$

其中, σ为 RBF 核函数宽度。

Line 核函数:

$$K_{\mathrm{Line}}(\boldsymbol{x}, \boldsymbol{x}_i) = \boldsymbol{x} \cdot \boldsymbol{x}_i + \mathrm{c} \tag{5}$$

其中, c为常数。

Poly 核函数:

$$K_{\mathrm{Poly}}(\boldsymbol{x}, \boldsymbol{x}_i) = (\boldsymbol{x} \cdot \boldsymbol{x}_i + \mathrm{c})^d,\ d \in \mathbf{N} \tag{6}$$

其中, d为 Poly 核函数次数。

Sigmoid 核函数:

$$K_{\mathrm{Sigmoid}}(\boldsymbol{x}, \boldsymbol{x}_i) = \tan h(k(\boldsymbol{x} \cdot \boldsymbol{x}_i) + v),\ k > 0,\ v > 0 \tag{7}$$

其中, $\tan h$为 Sigmoid 核函数的激活函数, k为尺度参数, v为偏移量。

综上所述, 局部核函数和全局核函数均无法兼顾学习能力和泛化能力。因此, 考虑将 2 种核函数组合, 组合形式为

$$f(\boldsymbol{x}, \boldsymbol{z}) = \rho K_{\mathrm{loc}} + (1 - \rho) K_{\mathrm{glo}},\ 0 < \rho < 1 \tag{8}$$

其中, ρ 是权重, 表示各个核所占的比重; K_{loc} 是局部核函数, K_{glo} 是全局核函数, 两者加权为 1, 保证f是一个凸函数, 可根据需求选取合适的局部核函数和全局核函数类型。

根据 Mercer 定理, 对于有限点集 $\{x_1, x_2, \cdots, x_n\}$, 考虑任何实数 $\alpha_1, \alpha_2, \cdots, \alpha_n$, 都有:

$$\sum_{i=1}^{n} \sum_{j=1}^{n} a_i a_j K(\boldsymbol{x}_i, \boldsymbol{x}_j) \geqslant 0 \tag{9}$$

其中, 当 $\alpha=\alpha_2=\cdots=\alpha_n$ 时等号成立。由于 K_{loc} 和 K_{glo} 均为满足 Mercer 定理的核函数, 则$\sum_{i=1}^{n} \sum_{j=1}^{n} a_i a_j K_{\mathrm{loc}}(\boldsymbol{x}_i, \boldsymbol{x}_j) \geqslant 0$, $\sum_{i=1}^{n} \sum_{j=1}^{n} a_i a_j K_{\mathrm{glo}}(\boldsymbol{x}_i, \boldsymbol{x}_j) \geqslant 0$, 那么对于混合核函数$f(\boldsymbol{x}, \boldsymbol{z})$有:

$$\sum_{i=1}^{n} \sum_{j=1}^{n} a_i a_j f(\boldsymbol{x}, \boldsymbol{z}) = \sum_{i=1}^{n} \sum_{j=1}^{n} a_i a_j [\rho K_{\mathrm{loc}} + (1 - \rho) K_{\mathrm{glo}}] = \rho \sum_{i=1}^{n} \sum_{j=1}^{n} a_i a_j K_{\mathrm{loc}} + (1 - \rho) \sum_{i=1}^{n} \sum_{j=1}^{n} a_i a_j K_{\mathrm{glo}} \geqslant 0 \tag{10}$$

因此,混合核函数$f(\boldsymbol{x},\boldsymbol{z})$是半正定的,可以作为核函数。

混合核最小二乘支持向量机(hybrid kernel least squares support vector machine, HKLSSVM)模型可表示为

$$y(x)=\sum_{i=1}^{m}\alpha_i[\rho K_{\mathrm{loc}}+(1-\rho)K_{\mathrm{glo}}]+b \tag{11}$$

混合核函数利用2类核函数的优点[26],并可以通过调整权重ρ调整混合核函数的效果。当ρ趋近于0时,能够提高模型泛化推广能力;当ρ趋近于1时,能提升局部学习能力。选取合适的ρ值能够得到平衡了学习能力和推广能力的最佳效果的模型。

2.2 群体智能算法 基于HKLSSVM模型包含多个参数,其中,正则化系数λ、Poly核参数d、RBF核参数σ以及核权重ρ的值的选取影响着模型的求解效果。为了寻找最佳的参数组合,引入了PSO。在参数寻优算法的选取上,PSO虽然结构简单,搜索速度快,但粒子运动方向受当前最优解影响,粒子运动过程容易陷入局部最优,导致算法的求解精度受限。引入基于概率突跳策略在搜索区间随机游走,可以跳出局部最优[27],扩大可行解搜索范围,提高求解精度。但引入该策略会导致PSO收敛速度慢的问题。因此,提出改进惯性权重和学习因子可以自适应调整搜索步长,平衡算法求解精度及收敛速度。

2.2.1 粒子群算法 PSO是一种基于群体智能的分布式协同与信息共享的动态平衡机制,通过个体最优与局部最优交互,实现全局空间搜索与局部解细化的自适应调整[28]。速度和位置更新方式使用无梯度依赖的迭代策略对高维的复杂问题具有极强的鲁棒性。因此,本文使用PSO进行高维参数优化。

速度更新:

$$\boldsymbol{v}_{id}(t+1)=\omega(t)\boldsymbol{v}_{id}(t)+c_1\boldsymbol{r}_1(\boldsymbol{P}best_{id}(t)-\boldsymbol{x}_{id}(t))+c_2\boldsymbol{r}_2(\boldsymbol{P}gest_{id}(t)-\boldsymbol{x}_{id}(t)) \tag{12}$$

其中,$\boldsymbol{v}_{id}(t+1)$表示第$t+1$代的第d维中的第i个粒子的速度。$\omega(t)$是当前一代的惯性权重。c_1和c_2是学习因子,通常取1.5~2之间的固定值,$\boldsymbol{r}_1$和$\boldsymbol{r}_2$是服从(0, 1)均匀分布的随机数。$\boldsymbol{P}best_{id}(t)$表示个体极值。$\boldsymbol{P}gest_{id}(t)$表示全局最优解。$\boldsymbol{x}_{id}(t)$表示位移。

位移更新:

$$\boldsymbol{x}_{id}(t+1)=\boldsymbol{x}_{id}(t)+\boldsymbol{v}_{id}(t+1) \tag{13}$$

更新的快慢由惯性权重决定,惯性权重的表达式:

$$\omega(t)=\omega_{\max}-\frac{\omega_{\max}-\omega_{\min}}{T_{\max}}t \tag{14}$$

其中,$\omega_{\max}$和$\omega_{\min}$表示惯性权重的最大值和最小值,t是当前迭代次数,$T_{\max}$是最大迭代次数。

循环迭代,计算移动后粒子的适应度函数值,并不断更新个体极值和全局极值,直到迭代结束。

2.2.2 模拟退火法 PSO通过更新个体极值和全局极值进行寻优,虽收敛速度快,但这种仅接受更优解的策略易引发早熟收敛,使种群陷入局部最优。为解决此问题,本文在个体最优与全局最优的更新中,引入SA算法的"优解直接接受+差解概率接受"策略,利用SA的Metropolis准则允许PSO以一定概率接受差解,从而保持种群多样性,提高算法的全局搜索能力。

算法过程[29]:

步骤1 设置初始温度T_0,温降系数α。将T设置得较高,以确保算法的搜索空间足够大。α控制着退火的速度,一般取值在0.90~0.99之间,如果小于0.90,则收敛速度太快,容易错失最优值。

步骤2 初始解$\boldsymbol{f}_x$随机给出。

步骤3 进入循环,根据适应度函数计算新的解$\boldsymbol{f}'_x$,并根据PSO的局部最优和全局最优值确定新的解,比较新的适应度函数值是否优于初始解。

步骤4 如果优于初始解,保留新的解为当前最优解。否则,根据Metropolis抽样定理,差解以一定概率P_x被接受为当前解:

$$P_x = \begin{cases} 1, & f'_x < f_x \\ \exp\left(-\dfrac{f_x - f'_x}{T_x}\right), & f_x < f'_x \end{cases} \tag{15}$$

步骤 5 采用冷却策略:

$$T(t+1) = aT(t) \tag{16}$$

其中, $T(t)$和$T(t+1)$分别表示第t代和第$t+1$代的温度, a 是温降系数。

步骤 6 是否达到最大迭代次数, 如果达到, 则结束优化搜索; 如果未达到, 则从步骤 2 开始循环。

2.3 改进惯性权重和学习因子

2.3.1 改进惯性权重 PSO 的参数设置固定, 但当惯性权重参数设置过大时, 早期算法搜索能力过强, 后期算法收敛速度慢; 当惯性权重设置过小时, 算法容易陷入局部最优。此外, 引入 SA 的目的是以一定概率跳出局部最优的策略引导 PSO 找到全局最优, 进一步导致收敛速度慢。因此, 本文提出采用自适应惯性权重策略。随着迭代次数的增加呈线性递减的趋势。在迭代初期, 自适应惯性权重具有搜索范围广、搜索速度快的特点。在迭代后期, 保证算法收敛速度的同时避免陷入局部最优。

改进的惯性权重:

$$w(m) = w_{\max} - \max(w_{\max}, \min(w_{\max}, t/T_{\max})) \tag{17}$$

其中, $w_{\max}$是惯性权重的最大值, $w(m)$是当前一代惯性权重, t是当前迭代次数, $T_{\max}$是最大迭代次数。

2.3.2 改进学习因子 学习因子 c_1 和 c_2 分别代表 PSO 中个体和全局的认知能力。通常 c_1 和 c_2 采用固定值, 无法适配群体学习及个体学习的优化需求。改进之后的学习因子随着迭代次数的增加自适应调整策略, 能够有效地提升算法性能。学习因子 c_1 和 c_2 变化公式为

$$c_1 = 2\exp\left[-20\left(-\frac{t}{T_{\max}}\right)^6\right] \tag{18}$$

$$c_2 = 2 - c_1 \tag{19}$$

在整个迭代过程中, c_1的值呈逐渐下降趋势, c_2的值呈逐渐上升趋势。这是因为迭代初期, PSO 的各个粒子需要进行全局搜索, 增大c_1可以确定可行解的范围; 随着迭代次数增加, 需要提升局部搜索的性能时, 增大 c_2 可以加强种群间粒子的合作, 提升算法寻优精度。

综上所述, 本文提出的改进的粒子群算法优化混合核最小二乘支持向量机模型, 如图 2 所示。本文设计基于 HKLSSVM 作为求取补偿模型的基础方法, 通过 PSO 对混合核参数进行寻优; 为避免 PSO 过早陷入局部最优, 提出结合 SA 算法对粒子更新过程进行优化; 通过多次迭代, 获得满足算法停止条件的可行解。通过验证数据集确定满足评价指标时输出最优参数组合, 并在测试阶段利用求得的 HKLSSVM 模型实现 S 型热电偶非线性补偿。

3 实验分析

3.1 补偿结果 实验的测温范围是−50 ~ 1 768 ℃。根据国际标准的 S 型热电偶分度表, 对 S 型热电偶补偿。由于在−50 ~ 200 ℃ 温度下 S 型热电偶本身的非线性度较差。因此, 根据 S 型热电偶的非线性程度差异, 将数据集分为低于 200 ℃ 非线性强和高于 200 ℃ 非线性弱 2 个部分, 采用非均匀分段抽样构建数据集, 用于交叉验证实验。训练集分别在−50 ~ 199 ℃ 之间每隔 3 ℃ 选取训练样本, 在 200 ~ 1 768 ℃ 每隔 4 ℃ 选取训练样本。训练集用于训练选取合适的混合核模型以及寻找核参数。测试集选取测温范围中的剩下数据作为测试集, 用于客观评估模型的泛化性能和整体精度。

选取最大绝对误差作为适应度函数, 而不是传统的均方误差。这是因为热电偶在不同阶段的非线性程度不一样。在低温的状态下, 绝对误差比较大, 如果取均值函数作为适应度函数, 无法保证低温区域的准确度。同时, 将平均准确率也作为最终评价指标。

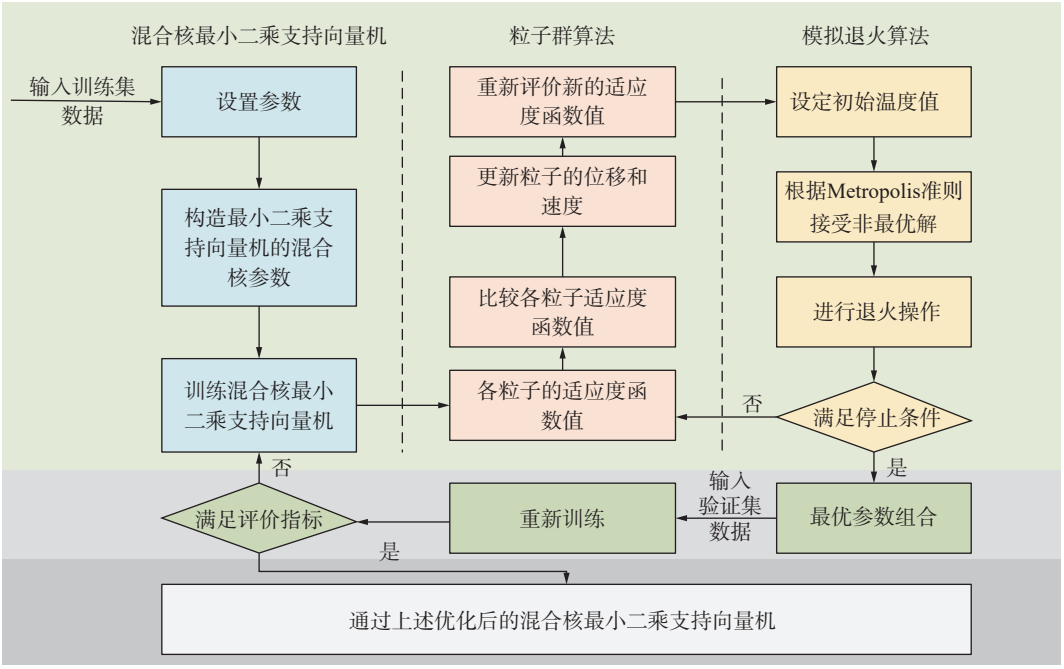


图 2　改进的粒子群算法优化混合核最小二乘支持向量机模型

适应度函数值 *fitness* 表示为

$$fitiness = \max(|y(i) - \hat{y}(i)|) \tag{20}$$

其中，$y(i)$ 表示第 i 个样本的标准输出值，$\hat{y}(i)$ 表示第 i 个样本经过补偿系统的实际输出值。

平均准确率 *Accuracy* 表示为

$$Accuracy = \left(1 - \sqrt{\frac{1}{M}\sum_{i=1}^{M}[(y_i - \hat{y}_i)/y_i]^2}\right) \times 100\% \tag{21}$$

其中，M 为样本总数。

为了选取最优的 HKLSSVM 模型，分别使用改进的 PSO 训练 LSSVM 的 RBF 核、Sigmoid 核、Poly 核和 Line 核进行性能测试，不同单核适应度函数迭代曲线如图 3 所示。改进的 PSO 定义种群的个数为 50，最大迭代次数为 1 000 次，惯性权重的范围为 [0.01,0.95]，退温系数为 0.9。

从图 3 可以看出，RBF 核初始适应度值较小，表明对非线性补偿任务的适配性强，最终在 484 次迭代收敛至适应度值 0.129，且为 4 种核函数中最小的适应度函数值。相较于其他 3 种核，具有最快的收敛速度。Sigmoid 核最终在 642 次迭代找到最优适应度函数值，适应度函数值为 0.134，收敛精度显著提升，但是收敛速度较慢。Poly 核在迭代初期搜索能力有限，且在 SA 概率突跳策略引导下，适应度值会出现较大波动；但随着迭代次数增加，改进 PSO 算法逐渐探索到相对合理的参数，最终收敛至 3 左右。单独使用 Line 核无法成功学习，故没有很好的收敛，其适应度值一直保持在 100 以上，无法有效地拟合热电偶非线性补偿任务的连续映射关系。

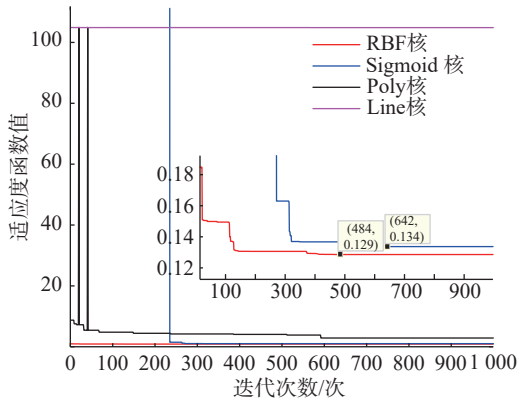


图 3　不同单核适应度函数迭代曲线

不同单核函数的测试结果如表 1 所示。从表 1 可以看出，RBF 核、Poly 核和 Sigmoid 核分别对应的训练集、验证集与测试集的绝对误差比较接近，平均准确率的结果也相近，未出现严重过拟合和欠拟合的

问题，说明数据集划分较为合理。相比之下，RBF 核函数的绝对误差最小且平均准确率最高，具有较强的学习能力。且测试集具有较高的补偿精度，说明改进后的 PSO 成功进行了参数寻优，提高了热电偶非线性补偿的性能。Line 核的绝对误差以及平均准确率的误差较大，因为 Line 核是线性核，无法捕捉热电偶非线性补偿任务中复杂的“电压−温度”非线性关系，导致预测值完全偏离真实温度，因此该核函数完全不适合本任务。

表 1　不同单核函数的测试结果

核函数	训练集		验证集		测试集	
	最大绝对误差/℃	平均准确率/%	最大绝对误差/℃	平均准确率/%	最大绝对误差/℃	平均准确率/%
RBF	0.115	99.994	0.129	99.247	0.129	96.523
Sigmoid	0.134	99.960	0.134	99.367	0.134	96.171
Poly	1.343	99.331	2.843	83.158	2.593	66.336
Line	104.900	−72.830	102.500	−505.800	104.200	−2 155.000

本文分别测试了 3 种混合核：改进的 PSO 分别训练了 RBF 和 Poly 的混合核、RBF 和 Sigmoid 的混合核以及 RBF 和 Line 的混合核。不同核函数的测试集结果对比图如图 4 所示。3 个混合核的最大误差和平均准确率均优于单核的结果，表明本文引入混合核可以提高模型的精度。其中，使用 RBF 和 Poly 的混合核拟合数据的结果最佳，与 RBF 和 Sigmoid 的混合核相比，最大绝对误差减少了 0.014，经计算平均准确率提高了 0.883%；与 RBF 和 Line 混合核相比，最大绝对误差减少了 0.011，经计算平均准确率提高了 1.199%。因此，本文选取 RBF 核和 Poly 核为最优混合核函数，解决本文的热电偶非线性补偿问题。

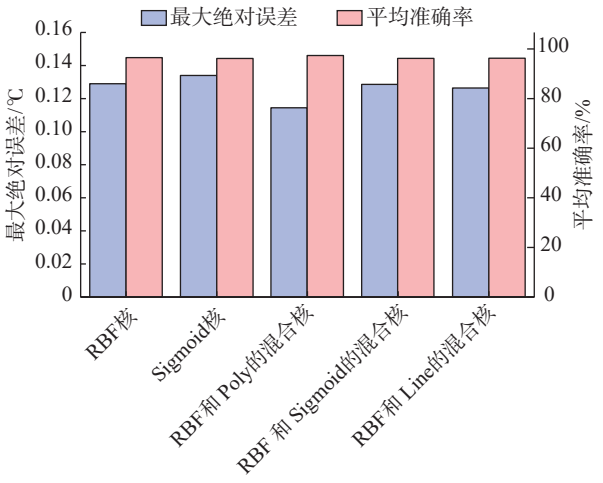


图 4　不同核函数的测试集结果对比图

为进一步验证所提方法的性能，本文分别选取经典的 BP、RBF 以及深层前馈神经网络（deep feedforward neural network, DFNN）和高阶多项式拟合（polynomial fitting）的方法用于 S 型热电偶非线性补偿。其中，RBF 神经网络通过 GA 进行网络参数寻优；DFNN 使用非线性最小二乘优化算法（levenberg-marquardt, LM）优化参数。通过 20 次蒙特卡洛实验，不同机器学习方法的比较结果如表 2 所示。从表 2 可以看出，相较于其他 4 种方法，本文方法在整体性能上表现优越，最大绝对误差是 0.115 ℃，平均准确率为 97.406%，可以满足航天测试领域中的高精度测试需求。

表 2　不同机器学习方法的比较

机器学习方法	测试集平均准确率/%	测试集最大绝对误差/℃
BP[7]	96.316	0.230
RBF[8]	96.516	0.167
LM-DFNN[1]	97.272	0.151
多项式拟合[2]	96.738	0.161
本文方法	97.406	0.115

为验证改进算法对 HKLSSVM 核参数优化的有效性，本文对比了 PSO-LSSVM、SAPSO-HKLSSVM 及本文方法在−50 ~ 1 768 ℃ 全量程温度预测中的绝对温度误差，不同算法误差曲线图如图 5 所示。PSO-LSSVM 的误差曲线呈现两端高中间低的分布特征，较大误差主要出现在 1 768 ℃ 左右的高温范围和

−50 ℃左右的低温范围。PSO-LSSVM的最大误差为0.150 ℃,此结果源于PSO-LSSVM中PSO的贪心收敛特性,过早陷入局部最优,导致Poly核的权重为0,仅依赖RBF核无法兼顾全量程温度下的强非线性关系,导致高低温区间误差增大。SAPSO-HKLSSVM通过SA的Metropolis准则引入概率跳出局部最优机制,误差分布得到明显改善,最大误差降至0.122 ℃,经计算相较于PSO降低18.667%,高低温区的误差峰值得到改善,这表明SA的概率突跳策略有效缓解PSO局部最优问题,混合核核参数得到充分的求解,有效提高补偿精度。本文方法在SAPSO-HKLSSVM的基础上通过改进惯性权重和学习因子进一步优化搜索策略,误差最大为0.115 ℃,经计算较SAPSO降低5.738%,较PSO降低23.333%,全量程最大温度误差进一步得到改善,此结果验证本文改进策略的有效性,本文方法不仅保持SA的突跳策略跳出局部最优的能力,而且提升了收敛稳定性,实现了热电偶全量程的高精度非线性补偿目标。

由于惯性权重作为重要的搜索策略之一,是能否找到全局最优的关键。根据本文引入PSO和SA的混合算法会导致收敛速度差的缺点,需要通过改进惯性权重来改善这一缺点。改进惯性权重需要在前期加快算法的收敛速度,在中后期逐渐加强局部搜索能力,末期为更精细的局部搜索,但搜索时间不宜过久,避免陷入局部最优。为了验证本文改进惯性权重的优越性,将不同的惯性权重的适应度函数变化曲线做了对比,如图6所示。在迭代的200次内,相比于其他改进的惯性权重,本文改进的惯性权重的收敛速度较快;在迭代的500次中,除Tanh权重陷入局部最优外,其他惯性权重均具有一定的跳出局部最优的能力,而本文改进的惯性权重的适应度函数值结果优于其他改进的惯性权重。本文改进的惯性权重在一定程度上可加快收敛速度,并提高搜索精度。

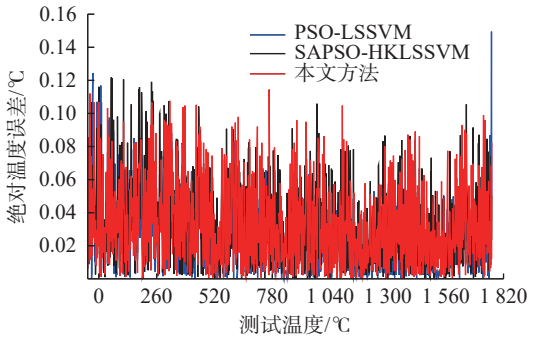


图5 不同算法误差曲线图

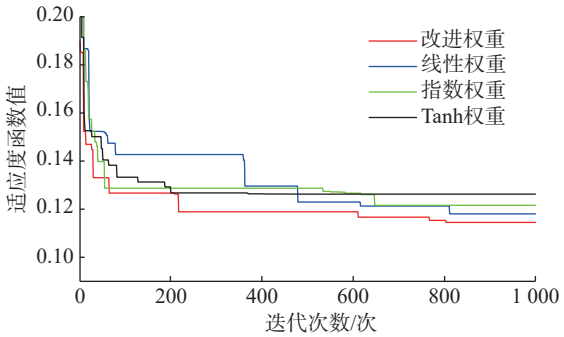


图6 不同惯性权重的适应度函数变化图

3.2 实测验证 为了验证本文提出方法的有效性,搭建测温装置的测试平台。搭建测试平台所需要的辅助仪器有福禄克电子仪器仪表公司(FLUKE)生产的5500A校准仪以及一台上位机PC端。其中,FLUKE5500A校准仪用来模拟电压信号以及不同类型的热电偶输出的温度信号,最大的温度信号范围可达−250 ~ 2 316 ℃;PC端用于完成电压−温度的非线性补偿运算以及观察分析数据。实验平台示意图如图7所示。

通过使用FLUKE5500A校准仪模拟输出温度范围为−50 ~ 1 768 ℃的S型热电偶,选取温度范围−50 ~ 1 768℃中的每隔1 ℃作为标准数据样本,测温装置每隔1 ℃实际的输出电压值作为被补偿数据样本。将实验数据样本划分为训练集、验证集和测试集。选取−50 ~ 199 ℃之间每隔3 ℃的数据和200 ~ 1 768 ℃每隔4 ℃的数据作为训练样本。选取测温范围−50 ~ 197 ℃中每隔9 ℃和203 ~ 1 763 ℃每隔12 ℃的数据作为验证集。测试集选取测温范围中的剩下数据作为测试集。以反映整体精度的平均准确率、反映极端工况稳健性的最大绝对误差和反映工程实时性的测试时间为评价指标,对BP神经网络、RBF神经网络、LM-DFNN、多项式拟合、高斯过程回归(Gaussian processes regression, GPR)[30]及本文方法6种方法进行了对比分析。不同机器学习方法的性能验证见表3。GPR的平均准确率最高,这是因为基于GPR方法中径向基函数核与白噪声核的组合,擅长捕捉噪声下的复杂非线性关系,所以能够较好地平均化误差。但缺点是对极端值敏感,导致绝对误差较大,最大误差为6.658 ℃,远超其他方法。本文方法的最大误差最小为0.380 ℃,可以在整个非线性量程中有效减少非线性误差,平均准确率虽略低于

GPR, 但优于其他对比方法, 且满足工程精度要求。不同机器学习方法在整个温度范围内的误差如图 8 所示。从图 8 中可以看出, 误差较大的区域集中在温度较低−50 ~ 200 ℃, 说明 S 型热电偶在低温区域中非线性度较差, 难以补偿。但本文方法可以有效地捕捉低温区域的局部细微特征, 改善了这一温度范围的补偿误差, 较 BP 神经网络方法, 误差减少了 0.260 ℃。因此, 本文方法可以有效地提高热电偶补偿精度。

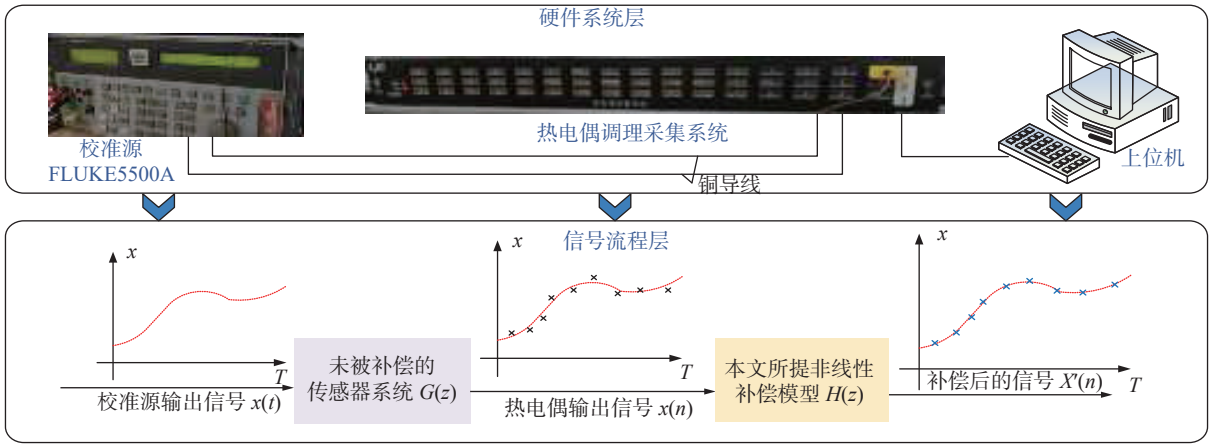


图 7　实验平台示意图

表 3　不同机器学习方法的性能验证

机器学习方法	测试数据集平均准确率/%	测试数据集最大绝对误差/℃
BP(1-6-1)[7]	98.225	0.640
RBF(1-241-1)[8]	98.256	0.568
LM-DFNN(1-5-5-1)[1]	98.530	0.474
多项式拟合(32)[2]	98.652	0.447
GPR[30]	99.947	6.658
本文方法	98.960	0.380

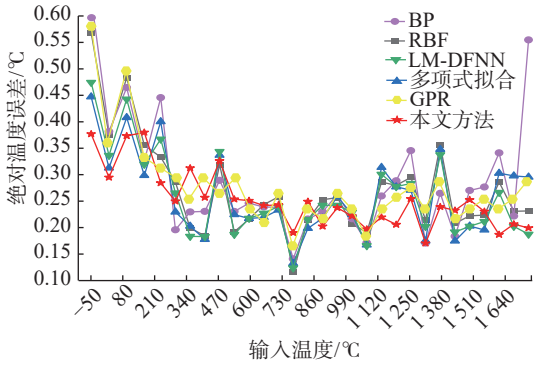


图 8　不同机器学习方法在整个温度范围内的误差

4　结　论

本文提出了基于混合核 LSSVM 的 S 型热电偶高精度补偿方法。通过构造多核函数, 平衡 LSSVM 模型对数据局部细节和全局特征的学习能力, 提高模型的泛化性能, 并结合概率突跳策略及自适应更新策略改进群体智能算法对混合核参数进行寻优, 进一步提升方法的求解精度。在实际测试中, 本文提出的补偿方法在宽温度范围内实现了较高的补偿精度, 降低了热电偶的非线性误差。其中, 补偿后最大误差为 0.380 ℃, 准确率为 98.960%, 远高于航天发动机±1 ℃ 的测温精度要求。为低成本的航天发动机高精度温度测试提供了解决方案。

参考文献:

[1] ANANDANATARAJAN R, MANGALANATHAN U, GANDHI U. Deep neural network-based linearization and cold junction compensation of thermocouple[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 2500609.

[2] SRINIVASAN K, SARAWADE P D. An included angle-based multilinear model technique for thermocouple linearization[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(7): 4412−4424.

[3] BERA S C, MANDAL N, SARKAR R. Study of an improved temperature indicating circuit using thermocouple[J]. IET Science, Measurement & Technology, 2010, 4(3): 169−176.

[4] ALY A A, EL-LAIL A S A. A novel circuit for thermocouple signals linearization using AD converter[J]. International Journal of Information Technology and Computer Science, 2013, 5(3): 56−60.

[5] ŽIVANOVIĆ D, SIMIĆ M. Two-stage segment linearization as part of the thermocouple measurement chain[J]. Measurement and Control, 2021, 54(1/2): 141−151.

[6] SARMA U, BORUAH P K. Design and development of a high precision thermocouple based smart industrial thermometer with on line linearisation and data logging feature[J]. Measurement, 2010, 43(10): 1589−1594.

[7] TANG J W, ZHANG Y, TANG X J, et al. Nonlinearity correction of the thermocouple based on neural network[C]//2009 WRI global congress on intelligent systems. Xiamen: IEEE, 2009: 28−32.

[8] GUO L H, WANG W, JIAO X B. Thermocouple signal conditioning with genetic optimizing RBF neural networks[C]//2011 IEEE 3rd international conference on communication software and networks. Xi'an: IEEE, 2011: 290−292.

[9] 韩剑, 莫德清, 汪楠. 基于 MPSO-SVM 非线性氨氮传感器的数据补偿 [J]. 桂林理工大学学报, 2021, 41(1): 225−229.
HAN J, MO D Q, WANG N. Data compensation based on MPSO-SVM non-linear ammonia nitrogen sensor[J]. Journal of Guilin University of Technology, 2021, 41(1): 225−229.

[10] 魏明奎, 叶葳, 沈靖, 等. 基于自组织特征神经网络和最小二乘支持向量机的短期电力负荷预测方法 [J]. 现代电力, 2021, 38(1): 17−23.
WEI M K, YE W, SHEN J, et al. Short-term load forecasting method based on self-organizing feature mapping neural network and GA-least square SVC model[J]. Modern Electric Power, 2021, 38(1): 17−23.

[11] LIU J H, SU H G, MA Y J, et al. Chaos characteristics and least squares support vector machines based online pipeline small leakages detection[J]. Chaos, Solitons & Fractals, 2016, 91: 656−669.

[12] MA W L, LIU H. Least squares support vector machine regression based on sparse samples and mixture kernel learning[J]. Information Technology and Control, 2021, 50(2): 319−331.

[13] SUN S Z, FU J Q, LI A, et al. A new compound wind speed forecasting structure combining multi-kernel LSSVM with two-stage decomposition technique[J]. Soft Computing, 2021, 25(2): 1479−1500.

[14] TIAN Z D, LI S J, WANG Y H, et al. Mixed-kernel least square support vector machine predictive control based on improved free search algorithm for nonlinear systems[J]. Transactions of the Institute of Measurement and Control, 2018, 40(16): 4382−4396.

[15] SARTAKHTI J S, AFRABANDPEY H, SARAEE M. Simulated annealing least squares twin support vector machine (SA-LSTSVM) for pattern classification[J]. Soft Computing, 2017, 21(15): 4361−4373.

[16] 张龙, 张宝国, 张继军, 等. 基于 PSO-LSSVM 的热电偶非线性校正方法研究 [J]. 中国测试, 2021, 47(3): 110−115.
ZHANG L, ZHANG B G, ZHANG J J, et al. Research on nonlinear correction method of thermocouple based on PSO-LSSVM[J]. China Measurement & Test, 2021, 47(3): 110−115.

[17] LI B, TIAN X T. An effective PSO-LSSVM-based approach for surface roughness prediction in high-speed precision milling[J]. IEEE Access, 2021, 9: 80006−80014.

[18] WANG S X, ZHANG N, WU L, et al. Wind speed forecasting based on the hybrid ensemble empirical mode decomposition and GA-BP neural network method[J]. Renewable Energy, 2016, 94: 629−636.

[19] NUVVULA R S S, DEVARAJ E, MADURAI ELAVARASAN R, et al. Multi-objective mutation-enabled adaptive local

attractor quantum behaved particle swarm optimisation based optimal sizing of hybrid renewable energy system for smart cities in India[J]. Sustainable Energy Technologies and Assessments, 2022, 49: 101689.

[20] 张朝龙, 江巨浪, 李彦梅, 等. 基于云粒子群−最小二乘支持向量机的传感器温度补偿 [J]. 传感技术学报, 2012, 25(4): 472−477.

ZHANG C L, JIANG J L, LI Y M, et al. Temperature compensation of sensor based on CMPSO-LSSVM[J]. Chinese Journal of Sensors and Actuators, 2012, 25(4): 472−477.

[21] 王子豪, 卢文科, 左锋. 基于 IA-LSSVM 的一维位置敏感位移传感器(PSD)温度补偿 [J]. 传感技术学报, 2022, 35(2): 202−206.

WANG Z H, LU W K, ZUO F. Temperature compensation of one-dimensional PSD sensor based on IA-LSSVM[J]. Chinese Journal of Sensors and Actuators, 2022, 35(2): 202−206.

[22] ISLAM T, MUKHOPADHYAY S C. Linearization of the sensors characteristics: a review[J]. International Journal on Smart Sensing and Intelligent Systems, 2019, 12(1): 1−21.

[23] ZENG B, GUO J, ZHU W Q, et al. A transformer fault diagnosis model based on hybrid grey wolf optimizer and LS-SVM[J]. Energies, 2019, 12(21): 4170.

[24] DIOŞAN L, ROGOZAN A, PECUCHET J P. Improving classification performance of support vector machine by genetically optimising kernel shape and hyper-parameters[J]. Applied Intelligence, 2012, 36(2): 280−294.

[25] SUYKENS J A K, VANDEWALLE J, DE MOOR B. Optimal control by least squares support vector machines[J]. Neural Networks, 2001, 14(1): 23−35.

[26] LI J, HU G Q, ZHOU Y H, et al. A temperature compensation method for piezo-resistive pressure sensor utilizing chaotic ions motion algorithm optimized hybrid kernel LSSVM[J]. Sensors, 2016, 16(10): 1707.

[27] FENG X L, QIU B Y, WANG Y X. Optimizing parallel pumping station operations in an open-channel water transfer system using an efficient hybrid algorithm[J]. Energies, 2020, 13(18): 4626.

[28] SHAMI T M, EL-SALEH A A, ALSWAITTI M, et al. Particle swarm optimization: a comprehensive survey[J]. IEEE Access, 2022, 10: 10031−10061.

[29] DJURIŠIĆ A B, ELAZAR J M, RAKIĆ A D. Simulated-annealing-based genetic algorithm for modeling the optical constants of solids[J]. Applied Optics, 1997, 36(28): 7097−7103.

[30] PHAN A T, VU T T H, NGUYEN D Q, et al. Data compensation with gaussian processes regression: application in smart building's sensor network[J]. Energies, 2022, 15(23): 9190.

作者贡献声明

本声明旨在明确各作者对本论文的具体贡献, 确保学术成果署名的规范性与公平性。各作者贡献如下: 郭蓉负责实验和仿真实施、数据采集与系统整理, 主导数据统计分析、结果可视化及结论解读, 撰写论文初稿, 并完成内容的修订与语言润色。许东阳负责补充返修后的对比实验方案及理论框架, 参与数据统计分析及结果可视化工作。杨林燚协助解读分析结论, 对论文初稿内容提出关键修改意见, 参与逻辑结构调整及细节完善。唐浩负责研究过程的学术指导与方向把握, 对研究设计及结论推导提出指导性建议。徐博提供实验所需核心设备及部分经费支持, 协调关键数据资源; 参与论文最终修订, 给出系统性修改方案。

利益冲突声明

作者声明, 其不存在已知的可能影响本论文所报告工作的竞争性经济利益或个人关系。

AI 使用声明

本文未使用人工智能(AI)协助撰写。

伦理声明

不适用:本文不涉及人类或动物研究。

电子补充材料

补充材料可在本文的在线版本中获取 https://doi.org/10.65658/j.hndk.2025091802。

数据可用性

支持论文结论所需的所有数据均已包含在稿件和/或电子补充材料中。如需获取与本文相关的其他数据,可向通信作者提出申请。

致谢/Acknowledgements

本文得到以下基金项目支持:国家自然科学基金项目(62563007)和国家自然科学基金项目(62563008)。

This work was supported by the following funding projects:National Natural Science Foundation of China (62563007); National Natural Science Foundation of China (62563008).

作者简介

郭 蓉(1996—),女,内蒙古乌兰察布人,海南大学2024级信息与通信工程专业博士研究生。E-mail:guor@hainanu.edu.cn。

许东阳(2000—),男,安徽池州人,海南大学2024级人工智能专业硕士研究生。E-mail:24220854100026@hainanu.edu.cn。

杨林燚(1999—),男,重庆人,海南大学2025级电子信息技术硕士研究生。E-mail:25220854010018@hainanu.edu.cn。

唐 浩(1992—),男,海南东方人,博士,海南大学副教授,博士生导师。近年在IEEE TFS、RCIM等国际高水平期刊发表学术论文50余篇,其中中国科学院Top期刊论文20篇,ESI高被引论文5篇、ESI热点论文2篇;主持国家级课题3项,省部级课题6项;申请国家发明专利20余项、PCT专利1项;出版专著/教材4部;制定标准3项;获省部级奖3项、国际会议论文奖3项。E-mail:melineth@hainanu.edu.cn。

徐 博(1994—),女,吉林长春人,博士,海南大学讲师,第二批海南省南海新星教育人才。近年来主持国家级课题1项,获权专利7项,发表SCI论文10余篇。E-mail:996458@hainanu.edu.cn。

(责任编辑:高 喆,英文校对:吴 慰)

This is an open access article under the terms of the Creative Commons Attribution 4.0 International License (CC BY 4.0, https://creativecommons.org/licenses/by/4.0/).

© The Author(s) 2026. Published by Journal Editorial Department of Hainan University.