基于深度学习的振动能量收集器性能预测及优化研究

郑黎明[1,2]，张馨文[2]，张悦豪[2]，晏行伟[1,2]，杨岸然[1,2]，刘晨曦[1]
（1. 中国人民解放军国防科技大学长沙 410073；2. 天津先进技术研究院，天津 300392）

摘　要：随着物联网、移动互联网等技术的快速发展，从环境中获取能量为电子设备供电成为产业界和学术界的研究热点，其中压电振动能量收集技术因转化效率高、适应性强等优势成为最主流的环境能量获取方式。然而，现有压电能量收集器在低频适应性、多方向响应方面仍有诸多不足，且其设计过程依赖计算成本较高的有限元分析，难以高效探索高维设计空间。本文提出了一种融合结构设计与数据优化的系统方法，首先，设计了一种基于双层耦合结构的低频多方向压电振动能量收集器，结合机电耦合模型与有限元分析，有效降低谐振频率并增强多方向响应能力；随后，提出融合 Kolmogorov-Arnold Networks（KAN）与 Transformer 的预测模型（TabKANet），并结合 Optuna 超参数优化模块，以提升模型对复杂非线性关系的建模精度与泛化能力；最后，将代理模型嵌入多目标优化框架，采用改进交叉变异算子的非支配排序遗传算法（IC-NSGA-II）对振动能量收集器的输出性能进行协同优化，获得分布均匀、收敛良好的近似 Pareto 前沿。通过 COMSOL 有限元仿真数据与实物样机实测数据，验证了所提方法在低频、多方向压电振动能量收集器设计中的有效性与准确性。

关键词：振动能量收集器；低频适应性；多方向响应；KAN；多目标优化
中图分类号：TN915.08
文献标志码：A
doi：10.11959/j.issn.2096−3750.WLW26166

Performance Prediction and Optimization of Vibration Energy Harvesters Using Deep Learning

ZHENG Liming[1,2], ZHANG Xinwen[2], ZHANG Yuehao[2], YAN Xingwei[1,2], YANG Anran[1,2], LIU Chenxi[1]
1. National University of Defense Technology, Changsha 410073, China
2. Tianjin Advanced Technology Research Institute, Tianjin 300392, China

Abstract: With the rapid development of the Internet of Things (IoT) and mobile Internet, harvesting energy from the environment to power electronic devices has become a research hotspot in both industry and academia. Owing to its high conversion efficiency and strong adaptability, piezoelectric vibration energy harvesting has become the predominant approach for ambient energy acquisition. However, existing piezoelectric energy harvesters still exhibit deficiencies in low-frequency adaptability and multi-directional response, and their design relies on computationally intensive finite element analysis, which hinders efficient exploration of high-dimensional design spaces. This paper proposes a systematic approach that integrates structural design with data-driven optimization. First, a low-frequency, multi-directional piezoelectric vibration energy harvester based on a double-layer coupled structure is designed; by combining an electromechanical coupling model with finite element analysis, the resonant frequency is lowered and the multi-directional response is enhanced. Subsequently, a prediction model named TabKANet, which integrates Kolmogorov-Arnold Networks (KAN) with a Transformer, is proposed and combined with Optuna-based hyper-parameter optimization to improve the modeling accuracy and generalization for complex nonlinear relationships. Finally, the surrogate model is embedded into a multi-objective optimization framework, and an improved non-dominated sorting genetic algorithm with adaptive crossover and mutation operators (IC-NSGA-II) is employed to jointly optimize the output performance of the harvester, yielding a well-distributed approximate Pareto front.The proposed method is verified against COMSOL finite-element data and measure-

收稿日期：XXXX−XX−XX；修回日期：XXXX−XX−XX

ments on a fabricated prototype, demonstrating its effectiveness for the design of low-frequency, multi-directional piezoelectric vibration energy harvesters.

Key words: Vibration energy harvester, low-frequency adaptability, multi-directional response, KAN, multi-objective optimization

0 引言

随着物联网、移动互联网技术的快速发展，可穿戴设备、智能家居、智慧城市等新型应用场景不断落地，网络接入终端数量呈现指数增长趋势，万物互联时代正加速到来。低功耗传感器作为物联网感知层的核心单元，是系统数据采集与稳定运行的重要基础[1-3]。当前传感器普遍依赖电池供电，存在续航有限、运维成本高、偏远及特殊场景维护难度大等问题，且废旧电池易引发生态污染，无法满足物联网规模化与绿色可持续的发展要求[4]。

环境能量采集技术可将环境可再生能源转化为电能，是解决物联网终端电池供电瓶颈的有效手段。其中，振动能分布广、稳定性高，应用优势显著。现有振动俘能技术主要分为压电式、电磁式与摩擦电式，压电式凭借高能量密度成为主流研究方向[5-9]。振动能量采集技术的发展历程始于21世纪初，Lu等人[10]首次设计并研制出振动能量采集器，该器件的谐振频率为3 kHz，在对应激励条件下实现了15μW的输出功率。振动俘能技术持续发展，但实际环境中的振动多集中于30 Hz以下的低频段[11-12]，且激励方向随机，因此低频匹配与多方向响应成为振动能量收集器设计亟待解决的核心问题。在各类结构形式中，悬臂梁式压电能量收集器结构简洁、制备工艺简便、适用范围广，是该领域研究最广泛的典型结构[13-15]，当环境振动频率与器件固有频率匹配时可稳定输出微瓦至毫瓦级电能，满足部分低功耗设备的供电需求[16]。但传统线性悬臂梁结构固有频率偏高且仅对特定方向敏感，难以匹配上述低频多向振动，输出性能受限，制约了其在无线传感网络与物联网等领域的应用[17-20]。为此，引入机械非线性机制被认为是提升低频振动响应能力与降低谐振频率的有效途径，具体方法包括构建多稳态结构、设计多自由度耦合系统以及优化压电换能器几何形状等[21-22]。

然而，上述经典方法仍存在难以回避的局限：其一，多稳态、多自由度等非线性机制的引入虽能降低谐振频率、提高输出性能，但显著增加了设计变量数目与参数间的耦合复杂度，依赖有限元验证的迭代范式计算成本高昂，难以在高维设计空间中实现高效寻优；其二，已有设计多面向单向激励与单一工况，缺乏面向低频多方向振动环境的系统化设计方法。

近年来，代理模型与智能优化算法的协同可有效降低仿真成本、优化器件关键参数，为提升低频压电振动能量采集效率、突破传统器件性能局限提供了重要技术思路。随着计算能力的提升，以代理模型为核心的智能优化方法逐渐被引入压电能量收集器（PEH）的结构优化。Ali等人[23]率先将人工神经网络与遗传算法相结合用于PEH的优化设计，开辟了数据驱动优化设计的研究方向；此后，CNN-LSTM[24]、DNN[25]等深度代理模型相继被用于替代耗时的瞬态充电仿真与有限元-电路耦合计算，作为适应度函数加速几何与机电参数寻优；在此基础上，Kriging元模型[26]、BP神经网络[27-28]、并行分离多输入神经网络[29]与RBF神经网络[30]等代理模型分别与遗传算法、NSGA-II及差分进化等元启发式算法相结合，将优化问题拓展至能量收集与传感精度的权衡[26]、单位质量与单位体积功率密度[27]、谐振频率匹配[28]以及多风速工况输出性能[30]等多目标设计场景，在大幅降低计算成本的同时有效提升了器件性能。

但是，现有智能优化方法在实际应用中仍面临以下挑战：首先，所构建的代理模型多为BP神经网络、RBF网络等浅层模型，特征提取与非线性表达能力有限，难以在高维强耦合参数空间中兼顾预测精度与泛化能力；其次，优化目标多聚焦于单一性能指标或特定激励形式，面向低频、多方向振动俘能的多目标协同优化研究仍不充分。因此，如何构建兼顾预测精度与泛化能力的深度代理模型，并将其与高效多目标优化算法有机耦合，形成经实验验证的、面向低频多方向压电振动能量收集器的系统化设计方法，仍是该领域亟待解决的关键问题。

围绕上述问题，本文首先提出双层耦合悬臂能

量收集器结构，使三个近似正交的压电分枝在同一条振子链上分别响应三向振动，并以极化反向串联实现输出叠加，从而避免多自由度结构横向尺寸随子振子数目线性增长；随后根据该收集器结构构建仿真数据集，提出融合KAN与Transformer的Tab-KANet代理模型，由KAN承担逐变量映射、自注意力建模参数间的耦合，使网络结构由物理机理驱动而非经验堆叠；最后构建了以输出功率最大化和结构体积最小化为目标的多目标优化模型，采用改进的多目标优化算法，引入Laplace交叉与黄金比收缩步长完成参数寻优，并通过仿真与实物实验验证所提方法的有效性。

1　耦合式振动能量收集器设计

1.1　收集器结构

本文提出了一种基于双层耦合结构的低频振动能量收集器，旨在实现对多方向低频环境振动的有效响应与高效能量转换。该能量收集器采用双层耦合的级联拓扑结构，其中下层结构由四分之一圆弧形柔性悬臂梁构成，其表面粘贴长度为弧长2/3的压电薄膜层，用于捕获梁体弯曲变形所产生的应变能；悬臂梁采用一端作为固定端、另一端为自由端，自由端配置质量块以实现系统固有频率的调谐匹配，使其与目标低频振动源产生共振，该质量块同时作为上下层结构的耦合节点，实现了结构的一体化集成。

上层结构采用T型悬臂梁配置，由多个矩形单元拼接而成，在三个关键区域分别设置压电材料以响应不同方向的弯曲振动模态，并在T型梁的中心区域及自由端附加配重质量块，进一步降低系统谐振频率。悬臂梁的固定端与下层圆弧梁的质量块连接，自由端配置质量块，形成复合振动系统。

本文通过实验和COMSOL有限元仿真对收集器性能进行研究，保证结果的准确性。双层压电能量采集器的仿真过程涉及到机械和电场的耦合,建立的有限元模型如图1所示。为了节省计算资源和保证计算精度，将梁和PZT片作为密集网格进行网格划分，而将其他部分进行较为粗略的网格划分。

从解析模型可以看出，收集器的谐振频率和输出电压是宽度的函数。因此，所提出的收集器的谐振频率和输出可以通过沿其长度改变宽度来调制。仿真中使用的结构参数和材料参数如表1,表2所示。

表1　圆弧形及T型能量收集器的结构参数

圆弧形			
	悬臂梁	压电材料	质量块
外径(mm)	30	30	
内径	20	20	
厚度	0.5	0.5	
长、宽度		18	10*10
T型			
长度	39.6		
宽度	10	13	10
厚度	0.5	0.5	0.5

表2　圆弧形及T型能量收集器的材料参数

特征	梁基体、质量块	压电材料
	铜	PZT-5H
密度	8960	7500
杨氏模量	120	76
泊松比	0.34	0.35
相对介电常数		1433
压电常数		-6.6

如图1(a)、(b)所示，基于结构稳定性考虑，柔性梁基座及质量块采用紫铜材料制备，铜基底层兼具承受惯性激励和便于电极引线焊接的双重功能，压电层与金属基底的厚度均设定为0.5mm，质量块厚度为10mm。在工作过程中，当环境中存在外部振动源时，基座产生位移响应，并驱动结构与其连接的柔性梁产生相应形变。此时，与柔性结构相接触的一个或多个悬臂梁触点发生相对位移或挤压，从而将激励有效传递至对应位置处的压电材料。压电材料在机械应力作用下产生电荷，完成机械能到电能的转换，实现对不同方向环境振动能量的高效采集。

将导线焊接至悬臂梁上表面，压电材料同时作为收集器的负（–）与正（+）电极。考虑到圆弧形压电层的布置不对称，整体输出中忽略上下压电层间电压降的影响。双层耦合结构中，上下两层悬臂梁在弯曲振动时分别处于拉伸与压缩状态；当两层串联连接时，将其极化方向设置为相反，两层的输出电势因应变反号而相互补偿，合成电场方向一致，从而获得更高的输出；若两层极化方向相同，则一层产生正电压、另一层产生负电压，输出相互抵消。

已有多自由度结构通常通过串联若干个独立的

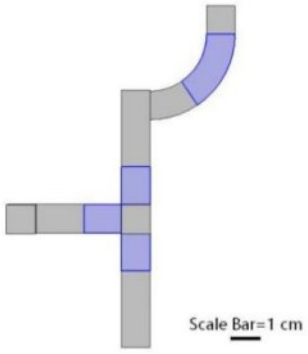

(a)　悬臂梁俯视示意图

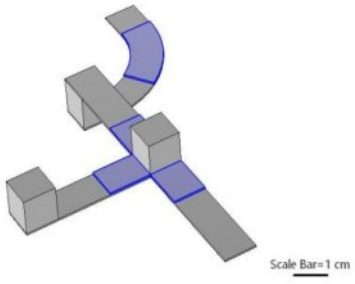

(b)　悬臂梁整体示意图

图1　振动能量收集器悬臂梁示意图

悬臂子振子，各振子需分别调谐至不同的中心频率，器件横向尺寸随子振子数目近似线性增长，且子振子之间仅通过基座发生弱机械耦合，输出需分别整流后再合成。多模态结构则依赖单一梁的高阶模态，但高阶模态的机电耦合系数衰减很快，实际可利用的模态数目有限。本文提出的双层耦合结构低频振动能量收集器与上述方案的差异，可进一步从结构拓扑、力学与电路三个层面说明。

结构拓扑上，本文的方向数由三个近似正交压电分枝的空间朝向决定，与子振子数量、模态阶数均无关；增加方向只需增加分枝及其引线，振子链与输出端口的数量不变，多模态单梁的方向数则受可用模态数限制。本文仅用2层梁、3 个压电分枝和 1 个输出端口完成三向响应，将四者的拓扑组织共同构成一条从基座到压电分枝再到输出端口的连续载荷路径，而非若干部件的拼接。

力学层面上，多自由度结构则各子振子刚度近似对角、仅经基座弱耦合，模态之间没有能量交换，只能靠频率错开覆盖带宽，且需为每个子振子分别调谐；多模态结构虽由单一梁承载多个模态，但高阶模态的应变曲率与压电层覆盖区失配，有效机电耦合系数随阶数迅速下降。

本文结构共用质量块使上下两层振子构成两自由度强耦合系统，两层梁的刚度与质量同时进入系统矩阵，矩阵含非对角耦合项。由式(11)可知，一阶频率由等效刚度与等效质量的比值决定；两层梁串联后的等效刚度低于同尺寸单层悬臂，等效质量又包含共用质量块与上层梁端部质量，故一阶频率相对单层悬臂下移，两阶模态的频率间隔与振型比例可通过质量块尺寸H3及圆弧梁半径R1、R2连续调节，两层梁因而能在同一低频窗口内共同响应。

电路上，两层压电片极化反向串联，当一层受拉、另一层受压时应变反号，两路电势因应变反号而相互补偿、合成电场同向，在相同应变水平下提高输出幅值；整机只需一个输出端口，不增加整流级数，也不引入额外的阻抗匹配网络。多自由度结构各子振子相互独立、相位不一致，需分别整流后汇流，存在二极管压降与阻抗失配损失。

1.2　收集器建模分析

构建振动能量收集器模型，通过控制方程描述，可以等效于弹簧—质量—阻尼器模型，如图2所示。当系统基座受到谐波激励时，该压电能量采集器产生周期性振动，其相对位移分别表示为x_1和x_2。

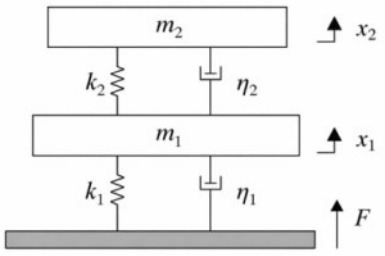

图2　能量采集器的弹簧—质量—阻尼器模型

当基座激振力为F时，该系统的动力学模型为：

$$M\begin{pmatrix}\ddot{x}_1\\ \ddot{x}_2\end{pmatrix}+\eta\begin{pmatrix}\dot{x}_1\\ \dot{x}_2\end{pmatrix}+K\begin{pmatrix}x_1\\ x_2\end{pmatrix}=\begin{pmatrix}F\\ 0\end{pmatrix} \tag{1}$$

$$M=\begin{pmatrix}m_1 & 0\\ 0 & m_2\end{pmatrix} \tag{2}$$

$$\eta=\begin{pmatrix}\eta_1+\eta_2 & -\eta_2\\ -\eta_2 & \eta_2\end{pmatrix} \tag{3}$$

$$K=\begin{pmatrix} k_1+k_2 & -k_2 \\ -k_2 & k_2 \end{pmatrix} \tag{4}$$

其中，参数m_1,m_2分别表示上下两个分段梁的总质量值；弹簧刚度值k_1,k_2分别表示两个分段梁的等效刚度；另外，两段梁的力学阻尼分别用η_1,η_2表示。以第一段梁为代表，推导出弹簧的集总质量m_1和等效刚度k_1的表达式如下：

$$m_1=m_a+\beta_M\left(m_b+m_p\right) \tag{5}$$

$$k_1=cYI \tag{6}$$

式中，质量块、基板铜片和压电层的质量分别记为m_a、m_b和m_p；β_M为瑞利常数；YI表示压电梁的弯曲刚度；c的值与具体结构有关。

$$m_a=\rho_{Cu}\mathrm{h}_3^3 \tag{7}$$

扇形和矩形压电片体积分别为V_1和V_2，由质量公式$m=\rho V$可得基板铜片m_b和压电层的质量m_p分别为：

$$m_b=\rho_{Cu}\left(\mathrm{h}_3\left(3L_1\mathrm{h}_1+\mathrm{h}_1\mathrm{h}_3\right)+\frac{\theta}{360}\pi\left(R_2^2-R_1^2\right)\mathrm{h}_2\right) \tag{8}$$

$$m_p=\rho_{PZT}\left(3L_2\mathrm{h}_2\mathrm{h}_3+\frac{\theta}{360}\pi\left(R_2^2-R_1^2\right)\mathrm{h}_2\right) \tag{9}$$

令$F=F_0e^{jwt}$，则对应的相对位移$x(t)$为：

$$x(t)=\frac{m\omega^2}{k-m\omega^2+j\omega\eta}F_0e^{jwt} \tag{10}$$

可以忽略阻尼情况下，谐振频率ω为：

$$\omega^2=\frac{1}{2m_1m_2}\left\{\begin{matrix}\left[\left(k_1+k_2\right)m_2+k_2m_1\right]- \\ \sqrt{\left[\left(k_1+k_2\right)m_2+k_2m_1\right]^2-4m_1m_2k_1k_2}\end{matrix}\right\} \tag{11}$$

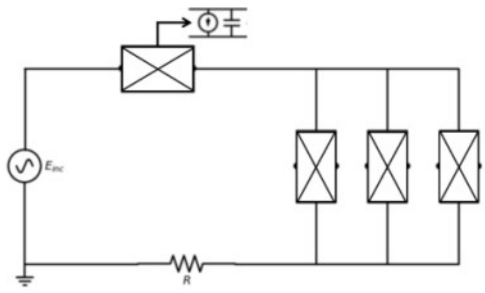

图3　并联连接的等效电路图

考虑到每个压电层都可以等效为电流源和内部电容器的并联连接，这三个压电层并联连接如图3所示，电路的输出端与负载电阻R_L相连。把压电片1单独作为A组，压电片2、3、4先并联作为B组，串联后微分方程为：

$$\frac{dV}{dt}+\frac{V}{R_LC_{eq}}=\frac{I_1(t)}{C_{p1}}+\frac{I_B(t)}{C_B} \tag{12}$$

其中，$I_B(t)$为B组压电片等效电流；V为负载电阻电压,V'为压电层上的电压变化率；C_p为等效电容，C_B为B组电容；$\theta_n(n=1,2,3,4)$为分段梁的机电耦合系数。

$$I_1(t)=\theta_1\dot{x}_1 \tag{13}$$

$$I_B(t)=\sum_{n=2}^{4}\theta_n\dot{x}_n \tag{14}$$

$$C_B=\sum_{n=2}^{4}C_{pn} \tag{15}$$

串联等效电容为：

$$C_{eq}=\frac{C_{p1}C_B}{C_{p1}+C_B} \tag{16}$$

其中，$C_{pn}(n=1,2,3,4)$为其等效内部电容；电容的表达式为$C_{pn}=\varepsilon S/d$；其中ε为介电常数；S和d分别为压电层的面积和厚度。在源正弦波激励$F(t)$下，相对位移$x_n(t)$和等效电流$I^*(t)$的波形可描述为：

$$x_n(t)=x_nsin\left(\omega t+\tau_n+\varphi_n\right) \tag{17}$$

$$I^*(t)=I^*cos\left(\omega t-\varphi\right) \tag{18}$$

φ_n为相对位移$x_n(t)$与激励力$F(t)$之间的相位差；x_n为相对位移的振幅；ω为角频率；τ_n为位移波形的初始相位角；φ为等效电流；$I^*(t)$的相位差；t为时间变量。

$$I_B=\sum_{n=2}^{4}x_n\theta_n\omega e^{j\left(\varphi+\varphi_n+\tau_n\right)} \tag{19}$$

可得负载电阻电压V与收获的平均输出功率P的表达式为:

$$V=\frac{\left(I_1C_B+I_BC_{p1}\right)R_L}{j\omega C_{p1}C_BR_L+\left(C_{p1}+C_B\right)} \tag{20}$$

$$P=\frac{V^2}{2R_L} \tag{21}$$

对振动能量收集器进行有限元应力分析，在X、Y、Z三向施加0.1g激励加速度，得到应力分布如图4所示：各方向应力均集中于固定端并沿悬臂梁向自由端逐渐衰减，其中X向应力局限于横向梁与竖直梁连接区域及弯折结构处，能量转换能力较弱；Y向应力分布范围扩大、弯曲过渡区亦出现应力集中，但幅值仍低于Z向；Z向应力响应最显著，俘能性能最优。需要说明的是，本文以Z向作为参数寻优的基准工况，仅为保证后续优化中各方案具有统一的比较基准。

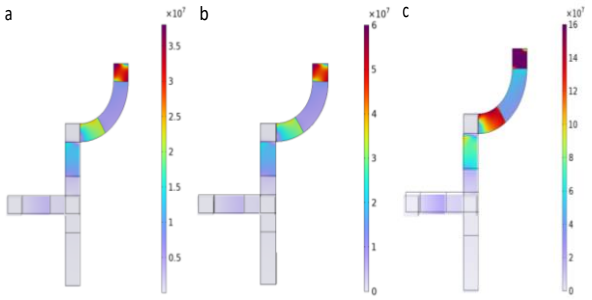

(a)　X轴(b)Y轴(c)Z轴

图4　振动能量收集器多向激励下的应力分布

2　基于深度学习的振动能量收集器优化

2.1　数据集

为了训练和测试深度学习模型，需要先获取数据集，文中使用COMSOL Multiphysics模拟生成训练数据集，下层金属悬臂梁和PZT-5H压电片取内环半径*R1*（20-25mm），外环半径*R2*（30-35mm），PZT-5H扇形压电片的角度*D*（30-90°）；上层T型金属悬臂梁长度*L1*（35-40mm），PZT-5H方形压电片长度*L2*（10-15mm），金属层高度*H1*（0.5-1mm），压电片高度*H2*（0.5-1mm）和正方体质量块长度*H3*（10-12mm）。将该结构参数化，生成包含8个结构尺寸参数与3项性能输出（谐振频率、最佳开路电压与最佳输出功率）的数据集，共8000组样本。数据集中的所有输入参数都是在预定义的间隔内从均匀分布中随机选择的，谐波激励幅值恒定为0.1g（约0.98m/s²）。本文将全部样本按70%、10%、20%的比例划分为训练集、验证集与测试集，并对随机划分过程设定固定随机种子以保证结果可复现。

由于质量块边长、金属梁与压电层的高度及长度之间数值差异较大，为消除不同参数量纲差异对模型训练的影响，对原始数据进行归一化处理，将其映射到[0,1]区间，归一化表达式如下：

$$x_{norm}=\frac{x-x_{min}}{x_{max}-x_{min}} \tag{22}$$

式(22)中，x是原始参数值，x_{min}和x_{max}分别是该参数的最小值和最大值。归一化处理后，所有结构化参数的值均在0到1之间，这有助于减少不同参数之间的差异，提高模型的收敛速度。

2.2　TabKANet预测模型

为刻画表格数据输入结构参数与多维性能指标之间复杂的非线性映射关系，本文采用TabKANet作为回归模型。KAN基于Kolmogorov-Arnold表示定理[31]，该表示定理从数学本质来看，阐明了多元连续函数的分解规律，可概括为任意一个n元函数都可以表示为若干个一元函数的加法和函数复合的混合运算。核心表达式如下：

$$f(x)=f(x_1,...,x_n)=\sum_{q=1}^{2n+1}\Phi_q\left(\sum_{p=1}^{P}\phi_{q,p}(x_P)\right) \tag{23}$$

式（23）中，f是任意一个n元函数，自变量为$f(x)=f(x_1,...,x_n)$，其可以表示为Φ_q和$\phi_{q,p}$共$(2n+1)(n+1)$个一元函数的相加和复合。内函数和外函数是网络架构的核心，内函数$\phi_{q,p}$是对输入变量x_P进行操作的单变量函数；外函数Φ_q是对内函数的输出进行操作的函数。通过在网络中引入可学习的一维函数B-spline，对特征间的非线性关系进行显式建模，从而弥补传统神经网络在表格数据回归任务中存在的表达能力不足与特征建模不充分的问题。

与传统神经网络模型相比，KAN网络以可学习的一元函数（B样条）替代节点上的固定激活函数，参数量更少且计算过程更具可解析性，可在一定程度上缓解机器学习模型长期存在的黑箱问题。TabKANet在此基础上进一步融合Transformer机制，KAN模块负责输入特征的非线性映射与输出回归，Transformer模块借助多头自注意力建模特征间的交互作用与全局依赖，使模型同时具备局部非线性表征能力与全局关系建模能力，为高精度预测提供支撑。

进一步从物理机理上看，KAN的结构形式与第1.2节所建立的机电耦合解析模型具有天然的同构性。由式（19）至式（21）可知，负载输出功率取决于激励频率、上下梁等效质量与等效刚度、机电耦合系数以及串并联等效电容等物理量，其解析结构表现为若干结构参数的乘除嵌套复合，而非各参数的线性加权叠加。KAN以连接边上的可学习B样条一元函数显式承担这两个层次，因此比依靠固定标量激活函数逐层做仿射变换再非线性压缩的全连接类网络更贴近该类机电解的逼近需求，也更易于在较少参数下达到给定精度。上述同构性可进一步由1.2节的关键式(5)—(11)、(19)—(21)逐层对应。

其一，等效刚度与集总质量均表现为结构参数的单项式，如 $M_{eq} = m_a + \beta M(m_b + m_p)$，对应于KAN连接边上的单变量幂函数，B样条对$h^3$、$L^{-3}$一类幂律具有精确逼近能力；其二，谐振频率由式(11)的刚度矩阵与质量矩阵行列式方程确定，单分支条件下退化为$\omega = (K_{eq}/M_{eq})^{1/2}$，其数学实质仍为刚度项与质量项的相除及开方，对应于KAN层间的复合运算。

2.3　深度学习框架建立

为建立输入特征与输出性能参数之间的复杂映射关系，模型主体采用基于KAN与Transformer融合的TabKANet深层架构。首先由KAN嵌入层对连续数值特征进行高阶非线性映射与特征重构，其中KAN以定义在连接边上的可学习一元函数（如B样条基函数）取代传统网络节点的固定激活函数，承担特征重构与输出回归的核心任务；随后Transformer部分通过多头自注意力机制建模输入特征间的全局依赖，可自动学习不同物理量与结构特征之间的交互权重，从而捕获高维输入中隐含的复杂耦合关联。

在此基础上需要说明的是选择Transformer模块的物理动机。此处引入自注意力并非用于时序预测，而是将经KAN映射后的每个结构参数视为集合中的一个令牌，借由多头注意力显式建模参数之间的二阶交叉效应。逐变量的一元函数族在原理上难以表达此类跨变量的条件依赖，而自注意力对每个参数对赋予数据驱动的交互权重，恰好与该耦合形式相对应。因此，本文网络结构的分工可以概括为：由KAN承担与机电耦合解析式同构的逐变量一元映射，由Transformer承担参数间的耦合交互，二者各司其职，而非已有模块的简单堆叠。

本文TabKANet模型与已有相关KAN和Transformer融合模型的区别，现用网络前向计算显式形式说明。设输入为d维结构参数$X = (X_1,\cdots,X_d)$，在上述两类的基础上，若按KAN在网络中的位置进一步细分，已有融合方式大致有三类：一是KAN-FFN型，token仍由线性投影WxWxWx)生成，只把Transformer块内的前馈网络换成KAN；二是串联型，先用KAN做特征提取，再把KAN输出送入标准Transformer；三是并行型，KAN分支与Transformer分支各自输出后加权融合。三者的共同点是，单参数的非线性映射与参数间的交互耦合被混在同一高维映射中，网络需要用同一组参数同时拟合一元响应与多元耦合。

TabKANet模型把这两类作用拆开，KAN嵌入层先把每个标量参数x_i映射为G维向量$\varphi_i(x_i)$，即token本身由一元样条函数生成，而不是由线性投影生成；注意力层只在这组token之间计算交互权重α_{ij}，输出为$\sum_j a_{ij}W_V\varphi_j(x_j)$，再经输出头得到预测值。于是模型可写成$f(x) = \psi(\sum_j a_{ij}(x)W_V\varphi_j(x_j))$，其中$\varphi_j$只依赖单个变量，$\alpha_{ij}$只依赖变量对。这一形式与1.2节机电耦合解的一元幂函数，乘除复合结构相对应：一元非线性由φ承担，跨变量耦合由α承担，二者在参数上解耦。已有三类融合方式把φ与α纠缠在同一组权重中，拟合同样的物理关系需要更多参数与样本。

这一分解带来两点可检验的性质。其一，参数效率：KAN嵌入的参数量为$O(d\cdot G\cdot k)$（d=8，G为网格数，k为样条阶数），线性投影为$O(d^2)$；在本文8000组样本的条件下，前者的归纳偏置更强，而注意力层的$O(d^2)$参数专门用于建模8个参数之间的二阶交互，容量分配与物理关系的低阶交互特征一致。其二，可解释性：训练完成后可逐条绘制$\varphi_i(x_i)$，直接读出某一结构参数对谐振频率或输出电压的偏效应，并与式(5)—(11)的单调性、幂律趋势对照；已有融合模型的单参数响应淹没在高维仿射变换中，难以单独提取。

模型采用Adam优化算法进行参数更新，并引入梯度裁剪策略以保证训练稳定，最大训练轮数设置为300，同时结合Early Stopping机制防止过拟合。在此基础上，引入Optuna超参数优化模块，对网络层数、注意力头数、嵌入维度及正则化参数等关键超参数进行自适应搜索，以获得预测精度与泛化能力更优的候选模型，其取值范围与优化结果如表3所示，此时TabKANet的预测效果最佳。

表3　超参数取值范围和优化结果

超参数名称	取值范围	优化值
网络dropout率	[0.1,0.3]	0.2
学习率	$[1\times10^{-4},3\times10^{-3}]$	0.001
批训练样本数	[32,256]	128
KAN层数	[2,5]	2
B样条基函数阶数	[2,8]	3
Transformer层数	[1,6]	2

由表3可知，TabKANet由KAN嵌入层（KAN层数2、B样条基函数阶数3）、Transformer编码器（层数2，多头自注意力）与3维输出头串联而成。

2.4 评价指标

训练完成后，计算R^2、RMSE和MAE等指标，对模型预测性能进行综合评价。为更直观地表征模型训练结果与预测结果的有效性，模型评价指标均通过测试集数据计算得到，并在各输出变量上分别给出，不跨输出变量取平均。

（1） 决定系数

决定系数（R^2）用于衡量模型对样本数据的拟合程度，取值越接近1，说明预测值与真实值偏差越小，模型拟合效果越好。

$$R^2 = 1 - \frac{\sum_{i=1}^{n}\left(y_i - \widehat{y}_i\right)^2}{\sum_{i=1}^{n}\left(y_i - \bar{y}\right)^2} \tag{24}$$

（2） 平均绝对误差

*MAE*通过计算预测值与真实值误差绝对值的平均来度量预测误差水平，可避免正负误差相互抵消。*MAE*越小，模型预测性能越好。

$$MAE = \frac{1}{n}\sum_{i=1}^{n}\left|y_i - \widehat{y}_i\right| \tag{25}$$

（3） 均方根误差

*RMSE*对预测误差平方后取平均再开方，能够反映预测值与真实值之间的整体差异程度。*RMSE*越小，模型预测精度越高：

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(y_i - \widehat{y}_i\right)^2} \tag{26}$$

3 改进多目标遗传算法

上一节通过TabKANet算法实现了由结构参数到输出性能的快速高精度映射，但代理模型仅能给出给定参数下的性能评估，如何据此在参数空间中确定最优结构仍有待解决。

3.1 振动能量收集器多目标优化模型建立

考虑到压电能量收集器设计中既需要提升输出功率性能，又希望尽可能减小装置体积，两者之间通常存在一定冲突关系，因此本文将优化问题构建为双目标优化模型。其中，第一个目标为最大化输出功率，第二个目标为最小化结构体积，为便于采用统一的最小化框架进行求解，将最大化功率目标转换为最小化其相反数，得到最终的多目标优化模型为：

$$Min\,F(x) = \left(-P(x), V(x)\right)^T \tag{27}$$

在本研究中，将第2节训练好的深度学习模型用于多目标函数适应度函数中，以优化该器件的输出功率和体积。优化问题可表述如下:

$$\begin{cases} 20 \leqslant x_1 \leqslant 25 \\ 35 \leqslant x_2 \leqslant 40 \\ 10 \leqslant x_3 \leqslant 15 \\ 0.5 \leqslant x_4 \leqslant 1 \\ 0.5 \leqslant x_5 \leqslant 1 \\ 10 \leqslant x_6 \leqslant 12 \\ 30 \leqslant x_7 \leqslant 35 \\ 30 \leqslant x_8 \leqslant 90 \end{cases} \tag{28}$$

$$X = \left\{x_1, x_2, ..., x_p\right\} \tag{29}$$

$$x_1, x_2, ..., x_p \in O_p \quad p = 1,2,...,8 \tag{30}$$

其中，根据优化规则定义这些可优化变量的上界和下界。X是整个优化问题中的变量集合，O_p表示第p个变量x_p的定义域或可行范围。

需要指出，式(27)—(30)仅把Z向输出功率与结构体积作为目标，尚未显式包含低频与多方向要求。为使优化解可直接对应低频、多方向工况，本文在式(28)—(30)的变量边界之外增加两类性能约束：其一是谐振频率约束，按环境振动主频带取f_L = 8Hz、f_U = 14Hz，谐振频率约束为

$$f_L \leqslant f_r(x) \leqslant f_U \tag{31}$$

其二是多方向响应约束，取R_0 = 5%，即两个非主方向的开路电压不低于主方向的5%。

$$R_{md}(x) = min\left\{V_X(x), V_Y(x)\right\} / V_Z(x) \geqslant R_0 \tag{32}$$

这里采用开路电压而非功率定义响应比，是因为三向最佳负载不同，电压比更能直接反映压电分枝的应变传递能力。

谐振频率$f_r(x)$由TabKANet的频率输出直接给出，可在每一代适应度评估中计算；V_X、V_Y未包含在现有代理模型的输出中，R_0 = 5%是按d31弯曲模态的方向选择性设定的工程阈值：Z向为压电层的主应变方向，X/Y向经T型梁分枝的横向弯曲与扭转传递，有效应变分量小一个量级。

3.2 NSGA-II算法

NSGA(Non-dominated Sorting Genetic Algorithm)作为早期多目标优化算法之一，在实际应用中存在计算复杂度较高及高维问题适应性不足等问题，同时缺乏有效的精英保留机制，易导致优良个体丢失。针对上述缺陷，Deb等人[32]提出了NSGA-II算法，通过引入快速非支配排序与拥挤距离比较

机制，有效提升了算法的计算效率与解集质量。

（1） 拥挤度距离

拥挤距离（Crowding Distance）是NSGA-II中用于描述个体在目标空间分布特性的关键指标，其主要作用在于衡量同一非支配层内个体之间的稀疏程度。一般而言，个体的拥挤距离值越大，表明其邻域范围内个体分布较为稀疏；反之，则说明该区域解的分布较为密集。通过引入该指标，可在保证非支配排序优先性的基础上，进一步维持Pareto前沿解集的分布均匀性，从而避免解集过度集中于局部区域。

（2） 精英策略

精英策略的核心是在种群迭代中保留优良个体，避免其被选择、交叉或变异随机淘汰。优良个体通常具有较高非支配等级和良好分布特性，在多目标优化中可加速算法向Pareto前沿收敛，并兼顾解集多样性[33]。

实现时，先按非支配排序选取高等级个体，再以拥挤距离筛选，优先保留拥挤距离较大者；若非支配层个体不足，则补充高拥挤距离个体。随后将精英个体与子代合并为扩展种群，再次按非支配等级和拥挤距离排序筛选，最终保留与原种群规模一致的新一代个体。该机制实现优良个体跨代保留，从而提高算法收敛性能与优化精度。

3.3 改进交叉变异算子

交叉与变异算子是遗传算法种群更新的核心，前者决定全局搜索范围，后者影响局部开发能力，其参数设置直接决定寻优效果。参数过低会导致进化缓慢、易陷局部最优；过高则随机性增强、优良个体难以保留，收敛性能下降。因此，需根据优化问题特点合理设定参数。

针对上述问题，本文引入自适应交叉与变异策略（IC-NSGA-II），按种群进化状态动态调整交叉与变异概率：进化初期取较高概率，以增强全局勘探能力；由于进化因子由初值单调增至1，而式(34)分母在进化因子为0.75处取得极大值1.25，因此两个概率实际呈先降后微升的单谷曲线：进化前中期，搜索由全局勘探平滑过渡到局部开发；进化末期，两个概率小幅回升，以补充种群多样性、抑制早熟收敛，同时由精英保留机制保证已获得的优良个体不被破坏。

$$P_{gen} = \frac{gen_{current}}{Gen_{max}} \tag{33}$$

$$\begin{cases} P_{cavg} = \dfrac{P_{cini}}{P_{gen} + \sqrt{1 - P_{gen}}} \\ P_{mavg} = \dfrac{P_{mini}}{P_{gen} + \sqrt{1 - P_{gen}}} \end{cases} \tag{34}$$

其中，P_{gen}表示自适应进化因子，$gen_{current}$为当前进化代数，Gen_{max}表示最大进化代数；P_{cavg}表示自适应交叉概率，P_{cini}为初始交叉概率，设置为0.9；P_{mavg}表示自适应变异概率，P_{mini}为初始变异概率，设置为0.1。

本文进一步对交叉与变异算子本身作两处改进。标准SBX交叉以多项式分布生成分布因子($\eta_c = 15$)，子代集中于父代邻域；本文改由Laplace分布生成扰动，取$\beta = 1 + L$后按SBX形式生成子代，并将子代截断至设计域。其中L由逆变换法

$$L = -b \cdot sgn(u - 0.5) \cdot ln(1 - 2|u - 0.5|)\,(u \sim U(0,1)) \tag{35}$$

此时$\beta > 1$使子代外推至父代区间之外，$\beta < 0$使子代越过中点继续收缩；由于不对β作截断，重尾部分得以保留，因而多数子代位于父代邻域、少数子代产生较大跳跃。标准多项式变异的步长在进化过程中基本恒定；本文将变异步长改为按黄金比几何收缩，即

$$\delta(g) = \delta_0 \varphi^{\frac{4g}{G^{max}}} \tag{36}$$

由初期递减至末期约0.03倍，前期覆盖设计域、后期仅作精细扰动。其中，β为交叉分布因子，b为Laplace尺度参数，由0.5线性衰减至0.1；$\delta_0 = 0.2$为初始变异步长，$\varphi = 0.618$为步长收缩比率；u为(0,1)上的均匀随机数。

上述改动的优势体现在两方面：其一，重尾扰动使大跳步以可预期的概率出现，而多数子代仍位于父代邻域，因而无需增加额外控制参数即可兼顾全局勘探与局部开发；其二，黄金比步长随代数单调收缩，后期扰动足够小，不会破坏已收敛的解集。两组改动均不触及选择、精英与拥挤度机制，可直接嵌入任意基于SBX与多项式变异的NSGA-II实现。

3.4 评价指标

为了进一步评估改进NSGA-II算法在多目标优化中的性能表现，本文选取反世代距离（Inverted

Generational Distance,IGD）与超体积（Hyper volume,HV）作为评价指标，从收敛性与解集分布特性两个方面进行综合评估。

IGD 通过对 PF true 中所有参考点到 PF known 的最小欧氏距离求平均值来进行计算，其数值大小与算法性能呈负相关关系，*IGD* 值越小，说明算法得到的解集越接近真实 Pareto 前沿，且分布更加均匀，算法整体性能较优，其计算公式如下所示：

$$IGD(P,Q)=\frac{\sum_{v\in P}d(v,Q)}{|P|} \tag{35}$$

其中，$d(v,Q)$表示个体 v 到种群 Q 的最小欧几里得距离；P 表示真实 Pareto 前沿上的点的个数。

HV 值反映了解集在目标空间中的覆盖程度，其数值越大，说明解的分布越分散且覆盖范围越充分，从而表明其更接近真实的 Pareto 最优前沿。在评价解集性能时，通常选取参考点 *Ref* 并以该参考点与解集 S 构成的支配区域来计算 *HV* 指标。

$$Hyper\ volume = Lebesgue\left(\bigcup_{x\in S}[f(x),Ref]\right) \tag{36}$$

式中，Lebesgue 为勒贝格测度，$[f(x),Ref]$ 用于描述由解集 S 所支配，但不包含参考点 *Ref* 支配区域的体积大小。

4　实验结果及分析

4.1　TabKANet 预测模型实验结果

在 TabKANet 预测模型消融实验中，逐次引入 Transformer 特征交互模块与 Optuna 超参数优化策略，以验证各改进环节对基础 KAN 模型的有效性。需指出，模型虽同时输出谐振频率，但考虑到开路电压与输出功率直接决定能量采集器的实际供能能力，且频率预测在各变体中差异较小，故主要对比电压与功率两项关键指标的提升幅度。

表 4　消融实验预测精度对比

模型	开路电压			输出功率		
	RMSE	MAE	R^2	RMSE	MAE	R^2
KAN	6.779	5.638	0.900	0.119	0.096	0.902
TabKANet	4.935	3.597	0.947	0.079	0.075	0.957
TabKANet(OP)	3.712	2.791	0.970	0.070	0.056	0.966

表中各模型均在同一测试集上评估；指标按单一输出变量分别计算。为保证对比的公平性，各基线模型与所提模型采用相同的输入输出维度、相同的数据划分与相同的训练轮数上限。

实验表明：基础 KAN 模型已具备合理预测能力，但精度有限；引入 Transformer 交互的 TabKANet 模型显著改善了特征间高阶耦合关系的拟合效果；进一步联合 Optuna 调优后，模型结构更趋合理，三项指标均达最优。消融结果充分证明，各改进策略均对性能提升产生正向贡献，验证了所提模块组合的必要性。为衡量所提方法的相对优势，在相同数据集和实验条件下，选取 CNN、XGBoost 和 Transformer 作为基准模型，进行横向对比，将对比实验中的四种模型结果汇总于表 5 中。结果显示，TabKANet(OP)在三项指标上均优于全部对比方法。

表 5　对比实验预测精度对比

模型	开路电压			输出功率		
	RMSE	MAE	R^2	RMSE	MAE	R^2
Transformer	9.797	7.912	0.791	0.235	0.214	0.622
CNN	9.245	7.128	0.814	0.183	0.154	0.771
XGBoost	8.437	6.418	0.845	0.160	0.102	0.825
TabKANet(OP)	3.712	2.791	0.970	0.070	0.056	0.966

4.2　多目标优化算法实验结果

以振动能量收集器为优化对象，本节通过消融与对比两组实验验证 IC-NSGA-II 的有效性。消融实验将标准 NSGA-II 与 IC-NSGA-II 在相同设置下比较，种群规模设定为 100，最大进化代数为 100，交叉概率为 0.9，结果见表 6。

为了进一步评价该算法在多目标优化中的性能表现，本文选取 MOGOA 算法和 MOPSO 算法作为经典对比算法，三种算法均取种群规模 150、迭代 150 次；两种对比算法采用拥挤距离维护外部档案，并以截断更新机制控制档案规模。评价指标取 IGD 与 HV，从收敛性、解集分布性以及覆盖范围等方面对各算法进行综合分析。

从表中可以看出，IC-NSGA-II 在三个性能指标上均表现最优。其中，其 IGD 值为 0.0054，明显小于 NSGA-II 算法，MOGOA 算法和 MOPSO 算法，说明其收敛性更好；HV 值达到 0.780，高于另外三种算法，表明其帕累托解集具有更好的覆盖范围，解集分布更加均匀。综合来看，INSGA-II 在收敛性、多样性以及解集分布均匀性方面均优于 NSGA-II 算法，MOGOA 算法和 MOPSO 算法，能够获得更高质量的帕累托最优解集。综合来看，引

入改进交叉变异算子后，算法在保持种群多样性的同时，有效提升了全局搜索能力与局部寻优能力，使IC-NSGA-II能够获得质量更高、分布更均匀的非支配解集，验证了所提改进策略的合理性与有效性。

表6　对比实验性能指标计算结果

算法	IGD	HV
NSGA-II	0.0510	0.6994
MOGOA	0.0983	0.6221
MOPSO	0.0676	0.6680
IC-NSGA-II	0.0054	0.7804

本节采用改进NSGA-II算法对优化问题进行求解后，经过多次迭代演化后，获得稳定的非支配解集，保留f_r在8~14 Hz频率约束后求解并绘制的近似Pareto前沿如图5所示。如图左上区域的解集偏向最大化功率，右下区域的解集偏向最小化体积。

整体趋势表明，随着输出功率的增加，结构体积也随之增大，这主要是因为结构参数调整在提升输出功率的同时，会导致器件整体占用空间增加，二者存在典型的多目标冲突特性。因此，需要对两个目标进行权衡处理，在Pareto解集中选取了三组具有代表性的解，分别对应最大功率解、最小体积

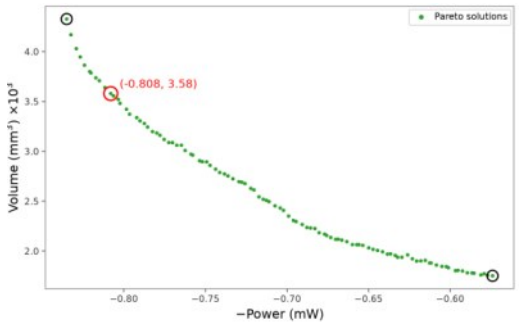

图5　Pareto前沿近似解集

解以及折中解，其中红色圈出的折中解坐标为(−0.808，3.580)，该解代表在功率与体积之间取得了较好的平衡，为验证所选解的有效性及参数合理性，优化后参数及对应结果如表7所示。再对候选解做X/Y/Z三向校核，只有满足$\boldsymbol{R}_{md}(x)\geqslant 5\%$的解才进入最终方案集。

由表7可知，不同代表性解在输出功率与结构体积之间呈现出不同程度的权衡关系。其中，第3组方案在保证较高输出功率的同时，兼顾了结构紧凑性，因此被选定为后续结构修正与实物设计的参考方案。三组解均已满足式(31)的频率约束；进一步对选定解按式(32)开展X/Y/Z三向校核，其三向电压响应比不低于5%，校核结果与5.2节的三向实测扫频一并给出。

表7　优化参数与结果

优化方案	R_1/mm	R_2/mm	H_1/mm	H_2/mm	H_3/mm	L_1/mm	L_2/mm	D/°	V/cm^3	P/mW
1	24.992	35.009	0.503	0.599	11.946	10.151	30.134	30.079	4.398	0.830
2	20.029	31.830	0.730	0.993	11.974	12.971	32.953	82.345	1.663	0.661
3	20.021	31.350	0.658	0.968	11.647	13.714	30.910	70.924	3.580	0.808

4.3　计算成本分析

为定量说明代理模型是否真正降低了设计成本，本节在同一计算平台、同一有限元模型（1.2节）下，以获得一条可用的Pareto前沿为设计任务单位，对本文代理辅助优化的全生命周期计算成本进行核算。核算仅统计计算时间，不计人工建模与调试成本，所有仿真均在相同网格与求解设置下完成。定义：t_1为单次参数化有限元仿真耗时（含频域扫频与负载扫描后处理），t_2为单次代理模型预测耗时，N_s为训练样本数，N_c为COMSOL内置优化器单次寻优所需仿真次数，m为逼近一条Pareto前沿所需的权重扫描次数，p为批量采样时的并行进程数，N_G为遗传算法单次寻优的适应度评估次数，T_t为模型训练与超参数搜索耗时。则两条路线的总成本可写为

$$C_{FE}(N)=N\cdot m\cdot Nc\cdot t_1 \tag{37}$$

$$C_S(N)=Ns\cdot t_1/p+Tt+N\cdot NG\cdot t_2 \tag{38}$$

$$N_0=(Ns\cdot t_1/p+T_t)/(m\cdot Nc\cdot t_1-NG\cdot t_2) \tag{39}$$

式(37)中的m体现了单目标优化器与多目标任务的差别：COMSOL优化模块一次只能给出一个加权解，要得到与本文方法规模相当的前沿，需按权重扫描m次；式(38)中数据生成采用p进程并行批量提交，而COMSOL优化器的迭代过程本质串行、无法并行摊薄。取$N=1$，即得盈亏平衡点$N_0\approx 0.19<1$，说明本文方法在首个任务上即已占优。

表 8　计算成本构成对比

成本项	COMSOL 模块	本文方法
单次仿真耗时 t1	228.3s	228.3s
一次任务仿真次数	5500	8000
仿真/数据生成耗时	348.8h	63.4h
训练与超参搜索 Tt	—	2.0h
寻优阶段评估耗时	—	20s
单任务总成本	348.8h	65.4h
相对本文方法的成本比	5.33×	1.00×

由表 8 可知，成本差异不在单次仿真，而在所需次数：为得到一条 Pareto 前沿，COMSOL 优化模块需 5500 次仿真，本文仅需一次性 8000 次，加训练 2.0h 共 65.4h，分别降低 81% 与 90%。随 N 增大，直接优化成本线性累加，而本文方法的一次性投入固定，这说明本文方法的价值不在于单次仿真更快，而在于一次建模、多次复用。

4.4　模型优化结果

为进一步比较优化前后器件的输出性能差异，本章基于修正后的结构参数在仿真软件中开展了频域与电阻扫描分析。相关结果如图 6 所示，显示了在恒定的 0.1g 激励加速度下，振动能量收集器连接到各种负载电阻时的峰值输出功率。从电压响应来看，优化前收集器的最大输出电压约为 38V，优化后结构的峰值电压提升至约 47V，增幅约为 23.7%，表明其在共振状态下的机电耦合能力得到显著增强。从功率输出角度分析，优化前的收集器在最优负载电阻为 398 kΩ 时，最大输出功率为 0.725mW，优化后最优电阻为 501 kΩ，最大输出功率为 0.808mW，增幅约为 11.4%。仿真结果表明，经过优化后的结构在输出性能方面得到显著提升。

从上图可以看出，优化后结构在谐振附近表现出更优的输出响应，说明所得到的参数组合能够有效改善器件的能量转换性能。为了对优化前后的性能提升进行更加直观的定量说明，本章进一步对关键优化指标进行了汇总，结果如表 9 所示。

由上表可以看出，优化结果可以兼具两个优化目标。同时，通过多目标优化，振动能量收集器输出功率增加，提升幅度达到 12%，优化输出结果和仿真结果误差值为 0.98%；收集器结构体积得到有效降低，降低幅度为 13.81%。结果表明，该优化方法在提升能量转换效率的同时，实现了结构尺寸与输出性能之间的协调优化，验证了其在实际工程

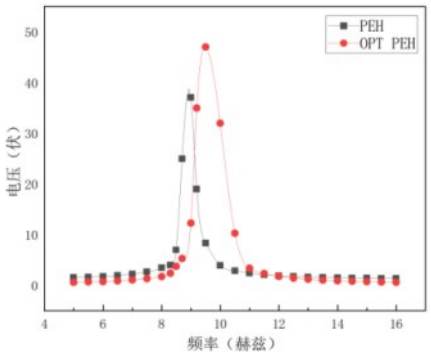

(a)　输出电压对比图

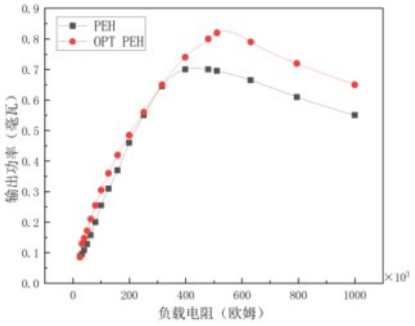

(b)　输出功率对比图

图 6　振动能量收集器最优解对应的优化设计对比

表 9　优化前后结果对比

优化目标	优化前	优化后	仿真结果
P(mW)	0.725	0.808	0.820
V(cm^3)	4.200	3.580	3.702

应用中的有效性。需要强调，上述提升是就 Z 向主工作方向而言的，所选折中解还须满足 3.1 节的频率与多方向约束。因此本文的“最优”是约束可行域内、以 Z 向功率与体积为目标的 Pareto 折中最优解。

5　实物制作与实验验证

5.1　制备及平台搭建

本文研制了一种低频多向压电振动能量采集器，其结构包括位于下层的圆弧梁收集器与位于上层的 T 型梁收集器。采用激光切割工艺分别制备各层的紫铜基底与质量块，再将质量块焊接至各自的自由端；上层 T 型梁的固定端与下层圆弧梁的质量块焊接，从而形成以共用质量块为唯一耦合节点的双层结构。压电层采用固相烧结法制备的 PZT-5H 压电片粘贴于基底表面。振动能量采集器实物如图 7 所示。

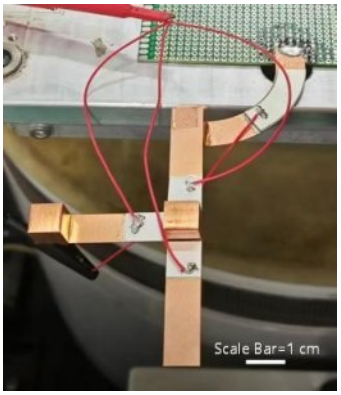

图7　振动能量收集器实物图

能量采集器通过测试平台进行测量，测试平台主要包括信号发生器、功率放大器SDA-10、信号调节器、振动台ES-10-240和示波器RTM2052五个部分。如图8所示，信号发生器可以直接与振动台相连产生振动，并通过它来产生测试所需频率的正弦信号。但用于固定的PCB板及收集器具有一定重量，因此在信号发生器与振动台之间需要加入功率放大器，通过调节功率放大器的增益，产生足够大小的加速度激励。加速度传感器固定在振动台上，与信号调节器、示波器及信号发生器相连，共同监控施加在能量收集器上激励加速度的大小和频率。电压由示波器高阻输入直接跨接于负载两端读取稳态峰峰值；由于示波器输入阻抗（MΩ量级）远大于负载（百Ω量级），其分流对功率计算的影响小于0.1%，可忽略。

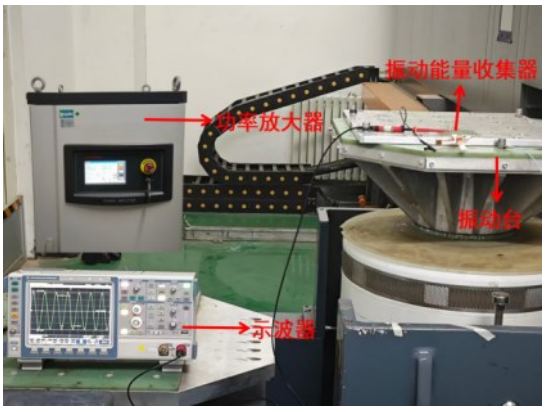

图8　测试平台搭建图

5.2　电压测量

记录每台收集器在不同频率下的开路电压，然后将实测电压与仿真电压进行对比，如图9所示。对该压电振动能量收集器进行测试，将压电振动能量收集器结构固定在振动台上面，施加大小为0.1g加速度的正弦激励。根据仿真软件COMSOL的计算结果得到每种收集器结构的谐振频率范围，随后在信号发生器上调节测试频率使其慢慢靠近谐振频率。同时观察振动台上收集器的振动幅度以及示波器上所显示的示数，以此确保谐振频率的准确性。通过示波器观察并记录不同频率下的开路电压，并将实际测试所得的电压值与仿真求得的电压值进行比较。

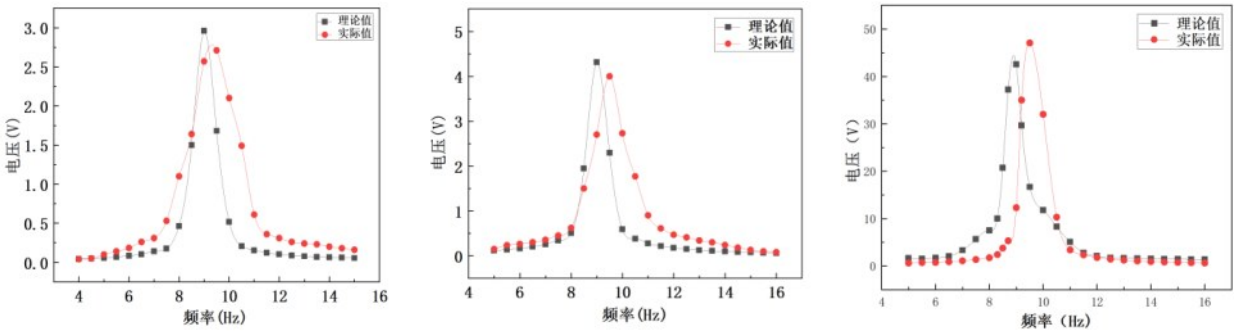

(a)　X方向　　(b)　Y方向　　(c)　Z方向

图9　X、Y、Z向输出电压的理论与实测结果对比

5.3　功率测量

将压电振动能量收集器安装在振动台上，并将其输出端与外接负载电阻串联，然后将示波器连接到负载电阻的两端。在谐振条件下，改变负载电阻的阻值，记录不同负载下的输出电压，并分析输出功率随负载变化的规律。

结果表明，在一定范围内，随着负载电阻的增加，输出功率逐渐增大；当负载阻值与收集器内阻相匹配时，此时为最佳电阻，输出功率达到最大；随后，随着负载电阻进一步增大，输出功率呈下降

趋势。如图10所示，仿真结果表明，最佳负载阻抗为501kΩ，理论输出功率为0.812mW；实验测试结果显示，最佳负载阻抗为480kΩ，实测输出功率为0.794mW，相对误差为2.22%。理论结果与实测结果较为吻合，验证了所建立分析模型的准确性。

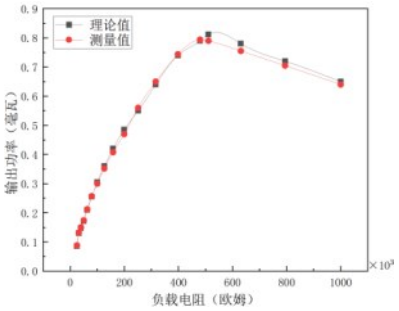

图10　不同负载电阻下的输出功率对比

6　结束语

本文研究了低频双层耦合压电振动能量收集器的结构设计与参数优化问题，可为物联网场景下低功耗传感器自供电系统的优化设计提供参考。针对传统压电悬臂梁收集器在低频多向环境振动中固有频率偏高、方向适应性不足，以及结构参数与输出性能间呈强非线性映射、高维参数空间寻优成本高昂等设计难题，提出了TabKANet代理模型与一种改进交叉变异算子的NSGA-II算法。实验结果表明：所建代理模型在预测精度上优于全部对比模型，改进算法所得近似Pareto前沿在收敛性与分布均匀性上亦优于标准NSGA-II，实物测试结果与有限元仿真结果吻合良好，验证了所提方法在低频、多方向压电振动能量收集器设计中的有效性。能量收集接口电路与能量管理策略同样是影响系统实际供能能力的重要因素，下一步工作将研究面向该低频多向收集器的最大功率点跟踪与高效接口电路设计。



张悦豪（1997– ），男，硕士，天津先进技术研究院工程师，主要研究方向为能量收集、超材料/超表面、AI 算法。



张馨文（2000– ），女，硕士，天津先进技术研究院工程师，主要研究方向为压电能量收集器、AI 算法。





晏行伟（1985– ），男，博士，国防科技大学电子科学学院、天津先进技术研究院副教授，主要研究方向为多源信息融合、无源定位、智能反无人机。



杨岸然（1988– ），男，博士，国防科技大学、天津先进技术研究院副研究员。主要研究方向为地理人工智能（GeoAI）、众源地理信息、三维重建。



刘晨曦（1990– ），男，博士，国防科技大学电子科学学院副教授，硕士生导师，主要研究方向为电磁兼容与防护、电磁辐射与散射。

参考文献：

[1] Bockelmann C, Pratas N, Nikopour H, et al. Massive machine-type communications in 5G: physical and MAC-layer solutions[J]. IEEE Communications Magazine, 2016, 54(9): 59-65.

[2] Mohammadi N, Shahgholi G, Khayyambashi M, et al. Energy-aware and spectrum-efficient massive random access mechanism for ultra-reliable low latency communications[J]. Physical Communication, 2024, 66: 102478.

[3] El-Barbary Z, Safarova L, Atamurotov F, et al. Artificial intelligence driven internet of things framework for wind energy monitoring and performance enhancement in smart cities[J]. International Journal of Energy Research, 2025, 1: 7215655.

[4] Ahmed S, Islam B, Yildirim K, et al. The Internet of Batteryless Things[J]. Communications of the ACM, 2024, 67(3): 64-73.

[5] 于家豪,陶凯. 振动俘能技术在可穿戴领域的应用[J]. 机械工程学报, 2022, 58(20): 46-71.

[6] Farhan M, Muthalif A, Mohamed A. Innovative approaches to optimize vibration energy harvesting (VEH): a comprehensive review[J]. Energy Reports, 2024, 12: 5194-5219.

[7] 吕品雷, 王子乔, 杨爱军, 等. 基于电磁感应和压电效应复合的变压器振动能量收集研究[J]. 高压电器, 2023, 59(12): 145-151.

[8] Qi L, Pan H, Pan Y, et al. A review of vibration energy harvesting in rail transportation field[J]. iScience, 2022, 25(3): 103849.

[9] 张坤, 张博, 刘斐. 基于抗磁悬浮的摩擦电式振动能量收集器[J]. 微纳电子技术, 2023, 60(6): 896-901.

[10] Lu F, Lee H P, Lim S P. Modeling and analysis of micro piezoelectric power generators for micro-electromechanical-systems applications[J]. Smart Materials and Structures, 2004, 13(1): 57–63.

[11] Zhang G, Gao S, Liu H, et al. A low frequency piezoelectric energy harvester with trapezoidal cantilever beam: theory and experiment[J]. Microsystem Technologies, 2017, 23(8): 3457-3466.

[12] Guo J, Lv, et al. Preparation and optimization of a low-frequency wave energy harvester based on piezoelectric materials[J]. Functional Materials Letters,2025, 18(5): 2551041.

[13] Yu C, Wang J, Zhao P, et al. Low-frequency vibration energy harvesting using electret-piezoelectric complementary coupling with optimized bandwidth and power density[J]. Journal of Cleaner Production, 2025, 532: 146953.

[14] 胡捷,李红,杨卫平,等. 压电式变截面悬臂梁低频振动能量收集器的设计与优化[J]. 传感技术学报,2023, 36(6): 868-873.

[15] Bendine K, Pereira J, Gomes G, et al. Energy harvesting enhancement of nonuniform functionally graded piezoelectric beam using artificial neural networks and Lichtenberg algorithm[J]. Structures, 2023, 57: 105271.

[16] Tabak A, Safaei B, Memarzadeh A, et al. An Extensive Review of Piezoelectric Energy-Harvesting Structures Utilizing Auxetic Materials[J]. Journal of Vibration Engineering & Technologies,2024, 12(3): 3155-3192.

[17] Sun W, Wang Y, Liu Y, et al. Navigating the future of flow-induced vibration-based piezoelectric energy harvesting[J]. Renewable and Sustainable Energy Reviews,2024, 201: 114624.

[18] Kang X, Li H, Zhang A, et al. Ultra-low-frequency piezoelectric energy harvesting via adjustable nonlinear inertance[J]. Journal of Engineering and Applied Science,2026, 73(1).

[19] Brusa E, Carrera A, Delprete C. A Review of Piezoelectric Energy Harvesting: Materials, Design, and Readout Circuits[J]. Actuators, 2023, 12(12): 457.

[20] Xiu W, Yao Y, Li L, et al. A Novel Piezoelectric-Electromagnetic Vibration Energy Harvesting Device With Real-Time Adjustable Resonant Frequency[J]. IEEE Access, 2025, 13: 91215-91231.

[21] Wu Y, Li S, Lan C. Recent development of piezoelectric energy harvesting structures and the technology of frequency up-converting oscillators[J]. Journal of Mechanical Engineering, 2022,

[22] Liang H, Hao G, Olszewski O, et al. A review on vibration-based piezoelectric energy harvesting from the aspect of compliant mechanisms[J]. Sensors and Actuators A: Physical, 2021, 331.

[23] Ali A, Sheeraz M, Bibi S, et al. Artificial neural network (ANN)-based optimization of a numerically analyzed M-shaped piezoelectric energy harvester[J]. Functional Materials Letters, 2021, 14(8): 2151046.

[24] Xiao Y, Han Q, Wu N. Design, modeling, and optimization of a stepped-beam piezoelectric energy generator under friction-

induced vibration[J]. Smart Materials and Structures, 2025, 34(8): 085018.

[25] Hegendörfer A, Steinmann P, Mergheim J. Numerical optimization of a nonlinear nonideal piezoelectric energy harvester using deep learning[J]. Journal of Low Power Electronics and Applications, 2023, 13(1): 8.

[26] Peralta-Braz P, Alamdari M M, Atroshchenko E, et al. On the joint optimization of energy harvesting and sensing of piezoelectric energy harvesters: case study of a cable-stayed bridge[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(1): 559-570.

[27] Mhiri M T, Larbi W, Chouchane M, et al. Optimization of a macro-fiber piezoelectric energy harvester using artificial neural networks [J]. Composite Structures, 2025, 367: 119269.

[28] He L, Kurita H, Wang Z, et al. Structural optimization of PVDF cellular resonators for energy-harvesting enhancement based on backpropagation neural network and NSGA-II algorithm[J]. Sensors and Actuators A: Physical, 2024, 376: 115608.

[29] Ren M, Wang C, Moshrefi-Torbati M, et al. Optimization of a comb-like beam piezoelectric energy harvester using the parallel separated multi-input neural network surrogate model[J]. Mechanical Systems and Signal Processing, 2025, 224: 111939.

[30] Weng S, Wu L, Li Z. Optimizing wind energy harvester with machine learning[J]. Applied Mathematics and Mechanics (English Edition), 2025, 46(8): 1417–1432.

[31] Somvanshi S, Javed S, Islam M, et al. A survey on Kolmogorov-Arnold network[J]. ACM Computing Surveys, 2025, 58(2): 1-35.

[32] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197.

[33] Sato Y, Sato M. Using dominated solutions at edges to the diversity and the uniformity of non-dominated solution distributions in NSGA-II[J]. SN Computer Science, 2022, 3(6): 432.