

# 基于神经网络的压电能量收集器性能预估模型\*

张金, 张健滔, 宁艺文, 瞿栋

(上海大学机电工程与自动化学院 上海, 200072)

**摘要** 设计了一款双稳态聚偏氟乙烯 (polyvinylidene fluoride, 简称 PVDF) 梁压电振动能量收集器, 并介绍了该款收集器结构特点和工作原理。为了解决传统理论模型预测与能量收集器实际输出性能的偏差, 利用神经网络对其结构参数、激励频率和收集电能之间的非线性关系进行建模。基于误差反向传播训练的多层前馈网络建立了双稳态 PVDF 梁压电能量收集器的人工神经网络模型。以质量块质量、PVDF 压电梁的压缩距离以及外激振力频率作为输入变量, 收集器输出电压均方根 (root mean square, 简称 RMS) 值作为输出变量, 采集了不同条件下压电能量收集器的实验数据。通过将仿真预测结果与实验结果对比, 验证了所设计的人工神经网络能有效地预测压电能量收集器的输出特性, 且无需复杂的收集器理论建模。

**关键词** 能量收集器; 压电; 神经网络; 振动; 性能预估

**中图分类号** TN384; TM619

## 引言

随着微机电系统技术的快速发展, 各类便携式电子器件的应用越来越广泛。如何有效地为这些低功耗电子器件供电已成为学者们的研究难点之一。传统的化学电池存在易污染环境、供电寿命有限、需定期更换成本较高等缺点, 已不能很好地满足嵌入式微系统的供电要求<sup>[1]</sup>。因此, 为了获得生命周期更长、环保可再生供电系统, 学者们着眼于从周围环境中收集能量取代传统电池, 为微型机电系统和低功耗的无线传感网络供电。

在周围环境中存在各种丰富的能源, 例如: 振动能、风能、热能、太阳能、电磁能和水能等。振动能由于存在普遍性且绿色环保, 因此备受研究者的关注。收集振动能的方式多种多样, 包括电磁式、静电式、摩擦式和压电式等<sup>[2-4]</sup>。其中, 压电式能量收集器由于具有结构紧凑、体积小、能量密度高、无电磁干扰和易于集成化等特点, 成为环境能量收集研究的热点<sup>[5-6]</sup>。目前, 学者们对压电能量收集器进行了较广泛地研究<sup>[7-10]</sup>。压电振动能量收集器除了结构和机理方面的研究外, 建立收集器理论模型也是其研究的基础之一<sup>[11-12]</sup>。能量收集器输出特性取决于结构参数、材料参数和电学参数等, 压电能量收集器理论模型的建立依赖于机械参数和电学参数的复杂方程, 而在实际工作中这些参数的确切值很难获知, 部

分参数值可能会受到环境的影响产生变化。因此, 理论模型预测的收集器输出性能和实际值有所出入。

神经网络由于能够对非线性模型的输入和输出数据之间的非线性行为进行近似计算及预估, 且无需事先了解这些数据, 因此备受研究者的关注。张栋等<sup>[13]</sup>建立了改进激活函数的神经网络在线辨识模型, 设计了自适应控制器, 以抑制压电工作台迟滞特性及动态特性对其微定位精度的影响。胡力等<sup>[14]</sup>针对压电执行器迟滞非线性特性, 研究了一种最小二乘法与径向神经网络相结合的执行器迟滞数学模型, 并利用实验检验了模型的准确性。范伟等<sup>[15]</sup>利用遗传算法优化了反向传播 (back propagation, 简称 BP) 神经网络的权值和阈值, 构建了压电执行器基于遗传算法的 BP 神经网络蠕变预测模型。Bagheri 等<sup>[16]</sup>针对传统理论建模数值仿真精度不足的问题, 提出了利用神经网络来评估压电能量收集器的输出特性, 并利用遗传算法作为优化方法, 获取压电能量收集器的最佳设计变量。Emre 等<sup>[17]</sup>利用神经网络对压电能量收集器负载电阻、磁激励频率和输出电能之间非线性关系进行建模, 并以此预测能量收集器的输出功率。

笔者设计了一款双稳态 PVDF 梁压电能量收集器, 为了解决传统理论模型预测与能量收集器实际输出性能的偏差, 基于神经网络建立压电能

\* 国家自然科学基金资助项目 (52175102); 上海市自然科学基金资助项目 (18ZR1414300, 13ZR1416900)

收稿日期: 2020-12-05; 修回日期: 2021-04-22

量收集器性能预估模型。在所建立的系统中,以质量块质量、压电梁压缩距离和外激励频率作为输入变量,收集器输出电压作为输出变量。利用实验中收集到的数据对设计的前馈网络进行训练,并将模型的预测值与实验值进行比较,以检验基于神经网络所建立的性能预估模型的有效性。

## 1 双稳态 PVDF 梁压电能量收集器

如图 1 所示,笔者设计的双稳态 PVDF 梁压电能量收集器包括 PVDF 压电梁、上框架、下框架、质量块、锁紧螺栓及调整结构。上框架与下框架通过连接螺栓连接。PVDF 压电梁中部粘接有质量块,梁的左端由上框架和下框架的左端夹紧固定,右端则固定在调整块左端缝隙中。调整块左端带有缝隙,整体为长方体结构,上框架的右端开有方形的孔,调整结构放置于孔中并可以左右滑动。当调整结构左移推进量增大时,PVDF 压电梁的弯曲挠度也会增大。调整结构移动到位后,通过锁紧螺栓将其锁紧。整个能量收集器通过安装孔与激振器固连在一起。




图 1 双稳态 PVDF 梁压电能量收集器结构图

Fig.1 Structure diagram of a bistable PVDF beam piezoelectric energy harvester

这款双稳态 PVDF 梁压电能量收集器具有上凸弯曲和下凹弯曲 2 个稳定状态,当外界振动激励能量收集器时,质量块将会产生振动。当质量块对 PVDF 压电梁的作用力超过一个临界值时,PVDF 压电梁从一个稳定状态跳转到另一个稳定状态,并伴随有大幅跃迁响应运动,此时通过 PVDF 的压电效应产生电能,实现振动能量的收集。

当调整结构推进量较大时,PVDF 压电梁的弯曲挠度也会较大,PVDF 压电梁在上凸状态、下凹状态之间转换时所需的能量相对较大,此时能量收集器适用于外源激励力较大的场合。当调整结构推进量不大时,PVDF 压电梁的弯曲挠度也相对较小,PVDF 压电梁在上凸状态、下凹状态之间转换时所需的能量也不大,此时的能量收集器适用于激励力

较小的场合。该能量收集器可根据外界不同的振动环境调整 PVDF 压电梁弯曲挠度到合适的位置,以提高能量收集器的工作性能。

## 2 双稳态 PVDF 梁压电能量收集器人工神经网络模型

### 2.1 BP 神经网络模型原理

双稳态 PVDF 梁压电能量收集器采用传统的理论建模方法,建立收集器结构参数、材料参数、电学参数与输出特性之间的非线性关系模型,但需分析复杂的理论公式,解决公式参数与实际值之间的偏差。笔者以质量块质量、PVDF 压电梁的压缩距离以及外源激励力的激励频率作为输入变量,输出电压 RMS 值作为输出变量,构建基于 BP 神经网络的压电能量收集器性能预估模型。BP 神经网络能学习并记忆多种映射函数关系,通过信号前向传播和误差反向传递到各个层次,不断调整 BP 网络的权值和阈值,使网络模型的误差平方和达到最小。

典型的 BP 神经网络分为 3 个层次:输入层、隐含层、输出层。以上 3 层组成 BP 神经网络基本的前馈网络。一个标准的具有双隐含层的 BP 神经网络结构如图 2 所示。图中: $x_i$  为输入层第  $i$  个神经元的输入,  $i=1, 2, \dots, n$ ;  $w_{ji}$  为输入层第  $i$  个神经元与隐含层 I 第  $j$  个神经元之间的连接权值,  $j=1, 2, \dots, p$ ;  $\theta_j$  为隐含层 I 第  $j$  个神经元的阈值;  $\phi_1$  为隐含层 I 的激励函数;  $v_{tj}$  为隐含层 I 第  $j$  个神经元与隐含层 II 第  $t$  个神经元之间的连接权值,  $t=1, 2, \dots, q$ ;  $\gamma_t$  为隐含层 II 第  $t$  个神经元的阈值;  $\phi_2$  为隐含层 II 的激励函数;  $c_{kt}$  为隐含层 II 第  $t$  个神经元与输出层第  $k$  个神经元之间的连接权值,  $k=1, 2, \dots, m$ ;  $\beta_k$  为输出层第  $k$  个神经元的阈值;  $\Phi$  为输出层的激励函数;  $y_k$  为输出层第  $k$  个神经元的输出。

网络的权值和阈值并不是一个定值,可通过调节权值和阈值使网络达到最佳性能。神经网络计算




图 2 具有双隐含层的 BP 神经网络结构

Fig.2 BP neural network structure with double hidden layers

过程主要包括信号的正向传播和误差的反向传播。在信号的正向传播过程中,输入节点的所有变量 $x_i$ 已知,将所有输入变量乘以各自对应的权值再求和,加上对应隐含层I的阈值可以得到隐含层I神经元的输入,则隐含层I第 $j$ 个神经元的输入 $s_j$ 为

$$s_j = \sum_{i=1}^n w_{ji} x_i + \theta_j \quad (1)$$

根据隐含层I的激励函数 $\phi_1$ 可以得到隐含层I第 $j$ 个神经元的输出,则隐含层I第 $j$ 个神经元的输出 $b_j$ 为

$$b_j = \phi_1(s_j) = \phi_1\left(\sum_{i=1}^n w_{ji} x_i + \theta_j\right) \quad (2)$$

同样地,可以得到隐含层II第 $t$ 个神经元的输入 $s_t$ 与输出 $b_t$ ,以及输出层第 $t$ 个神经元的输入 $l_k$ 与输出 $y_k$ 。

函数 $\phi_1, \phi_2, \Phi$ 选用对数 Sigmoid, tanh, ReLu 等激励函数,把输入的样本数据从 $[-\infty, +\infty]$ 映射到 $[0, 1]$ 区间内,用于对加权求和后的信号进行函数运算,限制神经元的输出。根据以上公式原理就可以完成BP神经网络信号正向传播的过程,得到了神经网络的实际输出。

对于一个样本总数为 $P$ 的训练集,样本编号为 $j$ 的样本,其在输出层第 $k$ 个节点的期望输出为 $T_k^j$ 。将实际输出与期望输出之间的误差再反向传播给网络上层,这就是BP神经网络计算过程中误差的反向传播过程。整个训练样本集的总误差函数为

$$E = \frac{1}{2} \sum_{j=1}^P \sum_{k=1}^m (T_k^j - y_k^j)^2 \quad (3)$$

总误差函数反映了整个神经网络的性能,其值越小,表示神经网络对于已知数据集的内涵关系学习地越好。

根据误差梯度下降法可计算出神经网络输出层的权值和阈值的修正量以及隐含层各层的权值和阈值的修正量。输出层权值修正量的调整公式为

$$\Delta c_{kt} = -\eta \frac{\partial E}{\partial c_{kt}} = -\eta \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial l_k} \frac{\partial l_k}{\partial c_{kt}} \quad (4)$$

输出层阈值修正量的调整公式为

$$\Delta \beta_k = -\eta \frac{\partial E}{\partial \theta_j} = -\eta \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial l_k} \frac{\partial l_k}{\partial \beta_k} \quad (5)$$

其中: $\eta$ 为调整因子,即神经网络的学习速率, $\eta$ 的取值范围在 $[0, 1]$ 之间。

同理求得隐含层II的权值修正量 $\Delta v_{tj}$ 和阈值的修正量 $\Delta \gamma_t$ 的调整公式,以及隐含层I的权值修正量 $\Delta w_{ji}$ 和阈值的修正量 $\Delta \theta_j$ 的调整公式。

将各级偏导函数进行推导计算,得到输出层各

层的权值修正量以及阈值修正量的调整公式为

$$\begin{cases} \Delta c_{kt} = \eta \sum_{j=1}^P \sum_{k=1}^q (T_k^j - y_k^j) \Phi'(l_k) b_t \\ \Delta \beta_k = \eta \sum_{j=1}^P \sum_{k=1}^q (T_k^j - y_k^j) \Phi'(l_k) \end{cases} \quad (6)$$

通过推导计算得到隐含层II的权值修正量和阈值修正量的调整公式为

$$\begin{cases} \Delta v_{tj} = \eta \sum_{j=1}^P \sum_{k=1}^q (T_k^j - y_k^j) \Phi'(l_k) c_{kt} \phi_2'(s_t) b_j \\ \Delta \beta_k = \eta \sum_{j=1}^P \sum_{k=1}^q (T_k^j - y_k^j) \Phi'(l_k) c_{kt} \phi_2'(s_t) \end{cases} \quad (7)$$

隐含层I的权值修正量和阈值修正量的调整公式为

$$\begin{cases} \Delta w_{ji} = \eta \sum_{j=1}^P \sum_{k=1}^q (T_k^j - y_k^j) \Phi'(l_k) c_{kt} \phi_2'(s_t) v_{tj} \phi_1'(s_j) x_i \\ \Delta \theta_j = \eta \sum_{j=1}^P \sum_{k=1}^q (T_k^j - y_k^j) \Phi'(l_k) c_{kt} \phi_2'(s_t) v_{tj} \phi_1'(s_j) \end{cases} \quad (8)$$

外部的输入信号由输入层传递到隐含层,在隐含层经激活函数处理后,再将隐含层的输出传输到输出层。如果没有得到期望输出,则将误差信号从输出端反向传播,分配给各层单元,调整各层的连接权值。通过多次信息正向传播和误差反向传播,神经网络中的权值和阈值得到不断修正,最终由输出层得到期望的输出结果。

## 2.2 BP神经网络结构优化

BP网络是一种前向神经网络,具有输入输出层和隐含层,并在学习训练期间利用误差反向传播训练算法。BP学习算法的根本原理是梯度搜索技术,该方法的核心是调整权值的大小使得网络总误差最小,即为了让神经网络的期望输出值与实际输出值误差的均方值尽可能小。

由于传统BP神经网络的学习速度收敛太慢,且容易陷入局部极小点,故笔者对其进行优化,在BP网络中加入反馈结构,在此基础上加入2个偏差单元。2个偏差节点分别加在隐含层II和输出层上,隐含层I节点不仅接收来自输入层的输出信号,还接收隐含层II节点经过一步时移的输出信号作为输入信号。优化后的神经网络结构如图3所示。可以看出:隐含层I接收隐含层II节点经过一步时移的输出信号,即 $T$ 时段的隐含层输出将影响 $T+1$ 时段的隐含层输入,这有利于网络存储过去的输入信息,这样网络在其学习期就获得经验知识,有助于改善



传统 BP 神经网络的学习收敛速度慢、容易陷入局部极小点等问题。




图 3 优化后的神经网络结构图  
Fig.3 Optimized neural network structure diagram

2.3 用于能量收集器性能预估的 BP 神经网络建立

以质量块质量、PVDF 压电梁的压缩距离以及外源激振力的激励频率作为输入变量,以能量收集器输出电压 RMS 值作为输出变量,构建用于能量收集器性能预估的 BP 神经网络模型。本仿真的样本数据是通过建立的压电能量收集器模型在不同质量块质量、压电梁压缩距离与外源激励频率下运行得到。笔者采用 Matlab 程序建立 BP 神经网络。

1) 数据的采集。能量收集器在不同质量块质量  $m$ 、压电梁压缩距离  $\Delta L$ 、外源激励振动频率  $f$  下输出电压的 RMS 值实验数据作为初始样本。利用函数 randperm 随机选取部分样本作为训练集,另一部分样本作为测试集。

2) 数据的预处理。由于质量块质量、外激励频率和压电梁的压缩距离之间数值有较大差距,为了尽量避免奇异样本的出现,先对原始数据进行归一化处理,使得数据映射在  $[0, 1]$  之间。数据转换函数为

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (9)$$

其中:  $x$  为样本数据;  $x_{\max}$  为样本数据的最大值;  $x_{\min}$  为样本数据的最小值。

在 Matlab 中使用 mapminmax 函数,将数据映射到  $[0, 1]$ 。因为在训练网络时所用数据是经过归一化的样本数据,输出结果需用函数 mapminmax 还原。同样,再次输入网络的新数据和原始样本数据接受相同的预处理,使用函数 mapminmax 进行预处理。

3) 建立 BP 神经网络。隐含层神经元传递函数选择 tansig,输出层神经元传递函数选择 purelin,网

络算法采用 Levenberg-Marquardt 算法。学习函数为 learnGDM,性能函数为 msereg。

4) 训练参数设置。在对模型训练之前,需要设置相关的训练参数,选定学习率为 0.01,限制训练最大迭代次数为 1 000,训练要求精度为  $1 \times 10^{-3}$ ,其余参数直接选用默认值。

5) 模型性能测试。对建立的模型性能进行检测,绘制模型预测输出曲线,并与实验数据曲线进行比较。

6) 模型性能误差。笔者采用数据统计指标决定系数  $R^2$  和均方根误差 (root mean square error, 简称 RMSE) 对模型的预测结果进行评估。 $R^2$  可以用残差平方和 (residual sum of squares, 简称 RSS) 以及总体平方和 (total sum of squares, 简称 TSS) 表示为

$$R^2 = 1 - \frac{RSS}{TSS} = 1 - \frac{\sum_{k=0}^m (T_k - y_k)^2}{\sum_{k=0}^m (T_k - \hat{T})^2} \quad (10)$$

其中:  $T$  为实际值;  $y$  为预测值;  $\hat{T}$  为实际值的平均值;  $k$  为数据序号。

当预测值越接近于实际值,即拟合程度越高,两者之间的残差就会越小,残差平方和  $\sum_{k=0}^m (T_k - y_k)^2$  就会相应减少。 $R^2$  可以有效反映预测值和实际值之间的拟合程度,评估模型预测结果的优劣, $R^2$  越接近 1,表示神经网络的预测值与实际值之间的拟合程度越高。

图 4 为 BP 神经网络模型流程图。首先,对获取

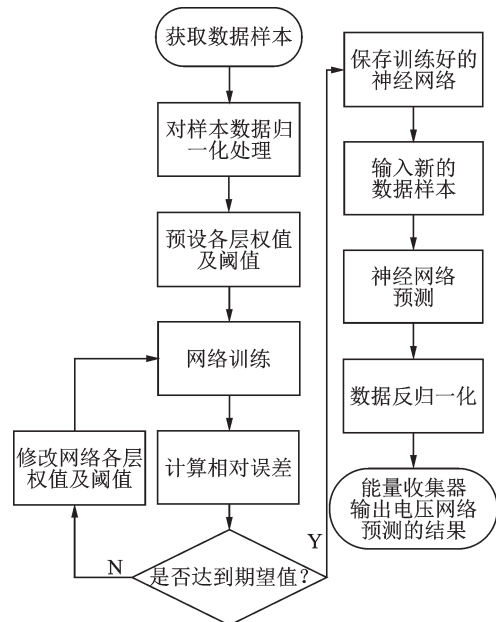


图 4 BP 神经网络模型流程图  
Fig.4 Flow chart of BP neural network model

的数据进行归一化处理,并给建立好的神经网络模型中的权值以及阈值赋初值;然后,对神经网络进行训练。在一个训练过程结束之后计算相对误差,并与期望误差进行比较,若大于期望误差值,则对网络中的权值以及阈值进行修改,再进入到下一个训练周期;若小于或等于期望值,则表示神经网络的性能已经达到了预期,可用于对新的输入数据进行预测,获取预测结果。

### 3 实验

#### 3.1 实验平台搭建

为了测试双稳态 PVDF 梁压电能量收集器的输出特性,搭建如图 5 所示的压电振动能量收集器实验平台。该平台包括隔振台、计算机、示波器 (TBS 2014B, Tektronix, Beaverton, Oregon, USA)、信号发生器、功率放大器和激振器 (SA-JZ020) 等。其中,激振器可产生 1 Hz~2 kHz 的振动频率,模拟现实中的各种振动环境。




图5 压电振动能量收集器实验平台

Fig.5 The experimental platform of the piezoelectric vibration energy harvester

#### 3.2 实验数据采集

由于双稳态 PVDF 梁压电振动能量收集器在外界激励未达到临界值时, PVDF 梁不会实现稳态之间的跳转,此时 PVDF 梁在单个势阱内围绕平衡点做小幅周期运动,其输出电压也较小。当外界激励超过临界值时, PVDF 梁在 2 个势阱间实现跳转,并做大幅周期运动,输出较大电压。因此,能量收集器的输出电压与激励频率、结构参数之间的关系是高度非线性,这增加了人工神经网络建模的难度。

利用搭建的压电振动能量收集器实验平台,测试了当激振器激励幅值为 10 mm 时,在不同质量块质量、PVDF 梁的压缩距离以及外激励频率输入条件下,双稳态 PVDF 梁压电能量收集器的输出电压

RMS 值。压电能量收集器输出电压分布如图 6 所示。可以看出,在一定压缩距离和质量的情况下,当激励频率较低时,能量收集器 PVDF 梁未能实现 2 个势阱间跳转,输出电压较小。当激励频率足够高时, PVDF 梁受到的作用力才足以支持其实现 2 个势阱间完成跳转,此时输出电压较大。




图6 压电能量收集器输出电压分布

Fig.6 Distribution diagram of output voltage of piezoelectric energy harvester

#### 3.3 网络训练结果

在神经网络的参数设置中,本仿真实验的输入节点数为 3,输出节点数为 1,隐含层的节点个数对网络性能有较大影响。节点数过多会使得运算量过大,网络训练所需的时间变长,甚至会导致网络不能完成收敛;当节点数过少时,网络的容错能力下降,训练所需的次数也会增多。学习率会影响网络收敛的速度及效果,较小的学习率可以保证网络收敛,但是收敛的过程会相对较慢;相反,学习率过大则有可能使网络振荡或发散,影响识别效果。经调试后确定 BP 神经网络第 1 个隐含层的节点个数为 8,第 2 个隐含层的节点个数为 4,学习率为 0.01。

输入神经网络中的数据样本会被分成训练集、验证集和测试集。在这 3 份数据中,只有训练集数据参加神经网络训练,而验证集和测试集只被用于检验,不会参与网络的训练过程。

在训练完成之后,为了更直观地表现笔者建立的收集器预测模型的性能,将神经网络训练集、验证集和测试集的回归能力进行可视化,如图 7 所示。归一化实际值为能量收集器实验输出电压归一化的值,归一化预测值为预测模型预估的电压归一化的值,两者都是无量纲量。图 7(a)中,  $R^2=0.997$ ; 图 7(b)中,  $R^2=0.992$ ; 图 7(c)中,  $R^2=0.967$ 。图 7(d)体现了神经网络整体的数据预测能力,  $R^2=0.995$ 。

可见,经训练后的预测模型可满足预设定的精度要求。

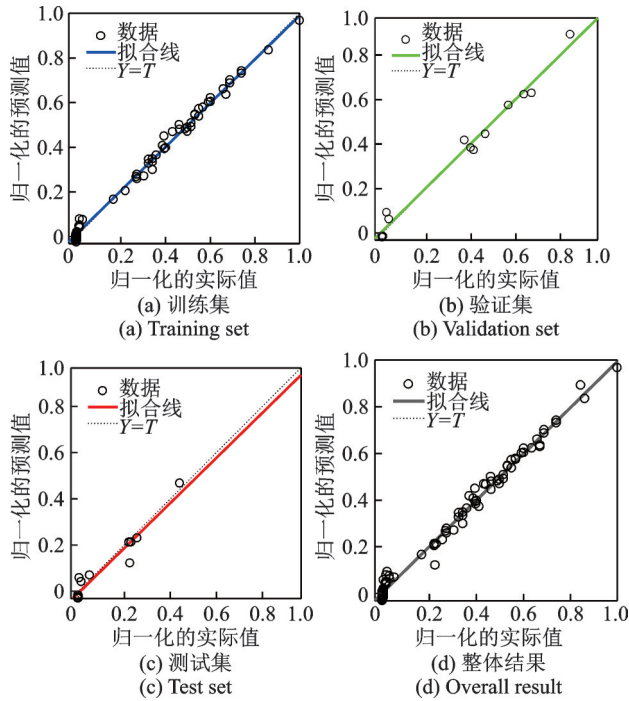


图 7 回归能力可视化

Fig.7 Visualization of regression capability

### 3.4 仿真结果与实验数据对比

图 8 为神经网络训练结果和实验值对比。可以看出,训练后网络输出 RMS 值与实验值基本吻合。图 9 为神经网络训练结果输出误差。可以看出,在 90 个数据样本中,模型预测值与实验值之间的误差大多控制在 0~0.25 V 之间,其中只有极少数的数据样本点偏差较大。




图 8 神经网络训练结果和实验值对比

Fig.8 Comparison of neural network training results and experimental values




图 9 神经网络训练结果输出误差

Fig.9 Output error of neural network training results

以上结果反映了人工神经网络训练相关的性能。预估模型不只是能记住训练的数据结果,还应具备泛化能力,对未训练过的输入数据能较为准确地预估其输出性能。为了检验神经网络的预估性能,将未在训练过程中使用的实验数据和神经网络预估结果进行对比。神经网络测试结果对比如图 10 所示。可以看出,预测值和实验值基本一致、吻合性很好,其  $R^2 = 0.99104$ ,说明改进后的神经网络对能量收集器在不同实验参数下的输出电压具有较好的预测效果。




图 10 神经网络测试结果对比

Fig.10 Comparison of neural network test results

图 11 为  $m=9\text{ g}$ ,  $\Delta L=0.2\text{ mm}$  时不同激励频率下输出电压预测值和实验值对比。可以看出,预测值和实验值的变化趋势一致,虽然在低频段的预测曲线有所偏差,但当激励频率在 8 Hz 之后的数值曲线吻合性较好,整体的  $R^2 = 0.98618$ 。




图 11  $m=9\text{ g}$ ,  $\Delta L=0.2\text{ mm}$  时不同激励频率下输出电压预测值和实验值对比

Fig.11 Comparison of predicted output voltage and experimental value under different excitation frequencies when  $m=9\text{ g}$ ,  $\Delta L=0.2\text{ mm}$

## 4 结束语

针对所设计的双稳态 PVDF 梁压电能量收集器,利用人工神经网络建立其性能预估模型,解决了由于压电能量收集器设计参数和输出特性之间的非线性关系造成理论建模困难的问题。在基于误差反向传播训练的多层前馈网络基础上,加入反馈结构



和偏差单元,构建了压电能量收集器人工神经网络模型。实验测试了不同质量块质量、PVDF压电梁的压缩距离以及外激励频率下收集器的输出特性,并用训练所设计的神经网络模型。利用训练好的神经网络预测压电能量收集器的输出特性,预测值和实验值的变化趋势一致,数值吻合性较好。

### 参 考 文 献

- [1] 王宁. 基于压电悬臂梁的振动能量收集器的研究[D]. 武汉:华中科技大学, 2010.
- [2] CARNEIRO P, DOS-SANTOS M P S, RODRIGUES A, et al. Electromagnetic energy harvesting using magnetic levitation architectures: a review [J]. *Applied Energy*, 2020, 260: 114191.
- [3] ZHANG Y, WANG T, LUO A, et al. Micro electrostatic energy harvester with both broad bandwidth and high normalized power density [J]. *Applied Energy*, 2018, 212: 362-371.
- [4] 曾洲. 弛豫铁电单晶在穿戴式压电能量收集器中应用的基础研究[D]. 上海:中国科学院大学(中国科学院上海硅酸盐研究所), 2018.
- [5] XIA G H, FANG F, WANG Q, et al. Performance analysis of piezoelectric energy harvesters with a tip mass and nonlinearities of geometry and damping under parametric and external excitations [J]. *Archive of Applied Mechanics*, 2020, 90(10): 2297-2318.
- [6] COVACI C, GONTEAN A. Piezoelectric energy harvesting solutions: a review [J]. *Sensors*, 2020, 20(12): 3512.
- [7] SOMKUWAR R, CHANDWANI J, DESHMUKH R. Wideband auto-tunable vibration energy harvester using change in centre of gravity [J]. *Microsystem Technologies*, 2018, 24(7): 3033-3044.
- [8] WEN S, XU Q, ZI B. Design of a new piezoelectric energy harvester based on compound two-stage force amplification frame [J]. *IEEE Sensors Journal*, 2018, 18(10): 3989-4000.
- [9] IZADGOSHASB I, LIM Y Y, TANG L, et al. Improving efficiency of piezoelectric based energy harvesting from human motions using double pendulum system [J]. *Energy Conversion and Management*, 2019, 184: 559-570.
- [10] QIAN F, XU T B, ZUO L. Piezoelectric energy harvesting from human walking using a two-stage amplification mechanism [J]. *Energy*, 2019, 189: 116140.
- [11] LI X, UPADRASHTA D, YU K, et al. Analytical modeling and validation of multi-mode piezoelectric energy harvester [J]. *Mechanical Systems and Signal Processing*, 2019, 124: 613-631.
- [12] ZHOU K, DAI H L, ABDELKEFI A, et al. Theoretical modeling and nonlinear analysis of piezoelectric energy harvesters with different stoppers [J]. *International Journal of Mechanical Sciences*, 2020, 166: 105233.
- [13] 张栋, 张承进, 魏强, 等. 压电工作台的神经网络建模与控制 [J]. *光学精密工程*, 2012, 20(3): 587-596. ZHANG Dong, ZHANG Chengjin, WEI Qiang, et al. Neural network modeling and control of piezoelectric worktable [J]. *Optical Precision Engineering*, 2012, 20(3): 587-596. (in Chinese)
- [14] 胡力, 李国平, 吕雪军, 等. 基于RBF神经网络的压电执行器迟滞建模 [J]. *压电与声光*, 2018, 40(5): 697-699. HU Li, LI Guoping, LYU Xuejun, et al. Hysteresis modeling of piezoelectric actuator based on RBF neural network [J]. *Piezoelectric and Acousto-Optics*, 2018, 40(5): 697-699. (in Chinese)
- [15] 范伟, 林瑜阳, 李钟慎. 遗传算法优化的BP神经网络压电陶瓷蠕变预测 [J]. *电机与控制学报*, 2018, 22(7): 91-96. FAN Wei, LIN Yuyang, LI Zhongshen. Creep prediction of piezoelectric ceramics based on BP neural network optimized by genetic algorithm [J]. *Journal of Motor and Control*, 2018, 22(7): 91-96. (in Chinese)
- [16] BAGHERI S, WU N, FILIZADEH S. Simulation-based optimization of a piezoelectric energy harvester using artificial neural networks and genetic algorithm [C] // 2019 IEEE 28th International Symposium on Industrial Electronics. [S. l.]: IEEE, 2019: 1435-1440.
- [17] EMRE Ç, EROL K, YUNUS U, et al. A neural network design for the estimation of nonlinear behavior of a magnetically-excited piezoelectric harvester [J]. *Electronic Materials*, 2018, 47(8): 4412-4420.



**第一作者简介:**张金,男,1997年3月生,硕士生。主要研究方向为压电能量收集器。

E-mail: zjin\_1997@sina.com

**通信作者简介:**张健滔,男,1979年7月生,副研究员、硕士生导师。主要研究方向为压电能量收集、超声电机技术。

E-mail: zhangjt@shu.edu.cn