

# 基于改进 GA-BP 神经网络的压力传感器校准方法<sup>\*</sup>

吴凯枫<sup>1</sup> 张立新<sup>1,2</sup> 阚希<sup>2</sup> 王军昂<sup>1</sup> 王赛<sup>1</sup>

(1. 南京信息工程大学 南京 210044; 2. 无锡学院 无锡 214105)

**摘要:** 针对压力传感器在实际使用过程中由于温度漂移现象导致输出精度不高的问题,提出了基于改进遗传算法(genetic algorithm, GA)优化反向传播(back propagation, BP)神经网络的校准方法。该方法主要改进了遗传算法的初始化种群和遗传算子,并引入了  $t$  分布扰动。将压力传感器模块的输出电压和温度电压作为输入,通过遗传算法计算出一组最优的初始权重和阈值并建立 BP 神经网络模型,最后将训练好的神经网络模型移植到传感器模块的调理芯片并进行实验验证。结果表明,该方法有效地降低了温度对压力传感器输出的影响,经过算法校准后压力传感器的全量程相对误差为 0.01%FS,零点漂移为  $8.444 \times 10^{-6}$ ,灵敏度漂移为  $2.055 \times 10^{-6}$ ,校准效果优于其他算法。

**关键词:** 压力传感器;遗传算法;BP 神经网络; $t$  分布

**中图分类号:** TP212      **文献标识码:** A      **国家标准学科分类代码:** 510.8060

## Pressure sensor calibration method based on improved GA-BP neural network

Wu Kaifeng<sup>1</sup> Zhang Linxin<sup>1,2</sup> Kan Xi<sup>2</sup> Wang Jun'ang<sup>1</sup> Wang Sai<sup>1</sup>

(1. Nanjing University of Information Science &amp; Technology, Nanjing 210044, China;

2. Wuxi University, Wuxi 214105, China)

**Abstract:** Aiming at the problem that the output accuracy of pressure sensor is not high due to the temperature drift phenomenon in the actual use, a calibration method based on improved genetic algorithm (GA) to optimize back propagation (BP) neural network was proposed. This method mainly improves the initial population and genetic operator of genetic algorithm and introduces  $t$  distribution disturbance. Taking the output voltage and temperature voltage of the pressure sensor module as the input, a set of optimal initial weights and thresholds were calculated by genetic algorithm and a BP neural network model was established. Finally, the trained neural network model was transplanted to the conditioning chip of the sensor module for experimental verification. The results show that this method can effectively reduce the influence of temperature on the output of pressure sensor. The full-scale relative error of pressure sensor after algorithm calibration reaches 0.01%FS, the zero drift reaches  $8.444 \times 10^{-6}$ , and the sensitivity drift reaches  $2.055 \times 10^{-6}$ . The calibration effect is better than other algorithms.

**Keywords:** pressure transducer; genetic algorithm; BP neural network;  $t$  distribution

### 0 引言

随着科学技术的发展,数据已经逐渐呈现出多元化与多维度化,通过自身感官去采集数据的方式早已不可取,因此,人类发明了传感器来代替自身感官。压力传感器的工作原理是因为其内部惠斯顿电桥中 4 个电阻随温度变

化发生压阻效应,使得电桥不平衡输出电信号,因此温度是影响压力传感器精确度的重要因素,但是温度也会使得压力传感器产生零点漂移和灵敏度漂移<sup>[1-3]</sup>。

目前市面上将压力传感器的全量程输出精度大致分为 4 个档次即 0.01%FS~0.1%FS 为超高精度,0.1%FS~1%FS 为高精度,1%FS~2%FS 为普通精度,2%FS~

收稿日期:2022-11-12

<sup>\*</sup> 基金项目:国家自然科学基金委员会青年科学基金项目(42105143)、江苏省教育厅江苏省高等学校基础科学(自然科学)研究面上项目(580221016)资助

10%FS为低精度,精度越高则生产成本也越高,因此要根据具体的应用场合和要求来选择合理的精度。市场上的压力传感器基本都处于普通精度这一档次。如深圳芯韵研发的传感器主要应用于酒精测试仪中,其全量程精度大约1.3%FS;日本的 Nguyen 报道的脉搏压力传感器的全量程精度为1%FS<sup>[4]</sup>。而车用压力传感器的精度要求为全量程范围内精度1%FS,如苏州纳芯微研发的 NSPAS1 系列是针对机动车的压力传感器,其全量程精度大约0.5%FS;本文提出的压力传感器校准方法也同样以车用压力传感器的精度要求为标准。

众多学者为了解决压力传感器的温度漂移问题提出了很多方法,早期普遍采用的是硬件补偿法,例如恒温保持法,电桥串、并联恒定电阻法,外接运算放大器补偿技术等,文献[5]采用的硬件补偿法,作者采用无源电阻网络温度补偿模型对压力传感器的低温区域进行温度补偿,但是这种方法补偿精度仅为2%FS。文献[6]采用聚偏氟乙烯(polyvinylidene fluoride, PVDF)压电薄膜材料作为基底材料来降低体感压力传感器阻抗失谐的影响,最终精度误差仅为3.6%。随着调理芯片的出现,软件补偿法逐渐代替了硬件补偿法,软件补偿法主要是对传感器的输出信号进行处理,主要有查表法、最小二乘法线性拟合法、插值法、神经网络法等。文献[7]采取的是三次样条插值与埃尔米特插值的补偿方法,补偿校准精度可为0.9%FS,已属于目前市场上高精度的范围,但是这种方法的补偿性能对数据规模的变化较为敏感。文献[8]先用三阶非线性多项式对压力变速器进行非线性校准,再采用改进的粒子群优化小波神经网络算法对压力传感器进行温度校准,校准精度可达0.386%FS。文献[9]采用极限学习机(extreme learning machine, ELM)神经网络模型对压力传感器进行校准,精度可达0.2%FS。文献[10]通过离线训练方法将离线训练数据存在RAM中,在FPGA上实现了前馈BP神经网络,但是这种方法需要很大的空间资源。

本文提出了改进遗传算法优化的BP神经网络算法(GA-BP),针对遗传算法容易出现“早熟”现象,采用Tent混沌映射函数来初始化种群;引入改进的自适应遗传算子加快了算法的收敛速度;使用以迭代次数为自由度的 $t$ 分布对每条染色体进行扰动。通过该改进的遗传算法计算出一组最优的初始权值与阈值,建立BP神经网络模型,利用BP神经网络的非线性拟合能力提高压力传感器的输出精度,降低温度漂移现象。

## 1 改进的遗传算法

遗传算法是模拟生物在自然环境下的遗传和进化过程的一种自适应的全局优化搜索算法,其本质是选择—交叉—变异算子的循环过程,直到找到最优结果或者满足终止条件。

### 1.1 Tent混沌映射序列初始化种群

传统遗传算法通过随机初始化的方式确定初始种群,

虽然这种方法保证了初始种群的随机性,但是这种方法会导致一部分染色体的初始位置离最优解的距离过远使得整个算法的收敛速度变慢,提高了出现“早熟”现象的概率。Tent混沌序列具有分布均匀性、不可重复性、不可预测性、全局遍历性等特点,使用此序列初始化种群不仅可以提高种群多样性,而且可以弥补随机初始化的不足<sup>[11]</sup>。

Tent混沌映射函数计算方法如下:

$$x_{i+1} = \begin{cases} 2x_i, & 0 \leq x_i \leq 1/2 \\ 2(1-x_i), & 1/2 \leq x_i \leq 1 \end{cases} \quad (1)$$

Tent混沌映射在区间 $[0,1]$ 产生的混沌序列具有一定的周期性,但是其在迭代过程中依然会出现一些不稳定周期点,这些不稳定周期点也可能影响后续的算法收敛速度,因此通过在Tent混沌映射函数中添加一个变量来解决这个问题,经过优化后的函数计算方法如下:

$$x_{i+1} = \begin{cases} 2x_i + \text{rand}(0,1) \times \frac{1}{N}, & 0 \leq x < \frac{1}{2} \\ 2(1-x_i) + \text{rand}(0,1) \times \frac{1}{N}, & \frac{1}{2} < x \leq 1 \end{cases} \quad (2)$$

式中: $N$ 为种群规模大小。

### 1.2 选择操作

选择操作采用轮盘赌的策略,按照“优胜劣汰,适者生存”的选择原则,每个染色体被选择的概率取决于自身适应度的大小,按照这个概率从旧种群中选择较优秀的个体作为父本,进行接下去的基因遗传操作。具体的选择概率计算方法如下:

$$p_i = \frac{f_i}{\sum_{i=1}^N f_i} \quad (3)$$

式中: $f_i$ 为染色体的适应度; $N$ 为种群规模大小。

### 1.3 改进自适应遗传算子

选择操作结束后,被选择的优秀个体会进行交叉与变异操作。传统遗传算法的交叉概率 $P_c$ 、变异概率 $P_m$ 是固定不变的,这显然对于算法收敛是不利的,Srinivas提出了自适应遗传算法,该算法的交叉、变异概率会在算法迭代过程中动态变化,加快了算法的收敛速度,计算方法如下:

$$p_c = \begin{cases} k_1 \frac{f_{\max} - f'}{f_{\max} - f_{\text{avg}}}, & f' \geq f_{\text{avg}} \\ k_3, & f' \leq f_{\text{avg}} \end{cases} \quad (4)$$

$$p_m = \begin{cases} k_2 \frac{f_{\max} - f}{f_{\max} - f_{\text{avg}}}, & f \geq f_{\text{avg}} \\ k_4, & f \leq f_{\text{avg}} \end{cases}$$

式中: $k_1, k_2, k_3, k_4$ 均小于1; $f_{\max}$ 为最大适应度; $f_{\text{avg}}$ 为平均适应度; $f, f'$ 为个体适应度。

这种自适应遗传算子同样也有一定的缺点,比如当一部分个体的适应度达到最大值时,它们的交叉、变异概率都将为0,那么这部分染色体会直接进入下一代。如果一直这样循环迭代下去,算法就会陷入局部最优。因此本文对自适应算子进行了改进,以最大适应度的1/2作为评判

标准,这样即便染色体的适应度达到最大值,也不会使得算法陷入死循环。并且改进的自适应交叉、变异算子会尽可能的让适应度较大的染色体获得较高交叉率,让适应度较小的染色体获得较高的变异率,从而维持种群的多样性,改进自适应遗传算子计算如下:

$$P_c = \begin{cases} p_{a1}, & f' > \frac{1}{2}f_{\max} \\ p_{a1} - \frac{(p_{a1} - p_{a2})\left(\frac{1}{2}f_{\max} - f'\right)}{\frac{1}{2}f_{\max} - f_{\min}}, & f' \leq \frac{1}{2}f_{\max} \end{cases} \quad (5)$$

$$P_m = \begin{cases} p_{b1}, & f < \frac{1}{2}f_{\max} \\ p_{b1} - \frac{(p_{b1} - p_{b2})\left(f - \frac{1}{2}f_{\max}\right)}{f_{\max} - \frac{1}{2}f_{\max}}, & f \geq \frac{1}{2}f_{\max} \end{cases} \quad (6)$$

式中:  $P_{a1}$ 、 $P_{a2}$ 、 $P_{b1}$ 、 $P_{b2}$  均小于 1,且  $P_{a1} > P_{a2}$ 、 $P_{b1} > P_{b2}$ ;  $f_{\max}$  为最大适应度;  $f_{\min}$  为平均适应度;  $f$ 、 $f'$  为个体适应度。

### 1.4 t 分布扰动策略

$t$  分布统计学科中常用的一种分布,其又被称为学生分布, $t$  分布可以跟随着自由度的变化而变化成高斯分布或者柯西分布,在基因遗传过程中,柯西分布扰动可以维持种群的多样性,提高算法的全局搜索能力,高斯分布扰动的局部开发能力比较强,可以提高算法的局部搜索能力<sup>[12-13]</sup>。服从自由度  $n$  的  $t$  分布的概率密度函数如下:

$$p(x;n) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\sqrt{n\pi}\Gamma\left(\frac{n}{2}\right)}\left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}} \quad (7)$$

从式(8)可知,当自由度  $n=1$  时, $t$  分布即变成了柯西分布,自由度  $n \rightarrow \infty$  时, $t$  分布即变成了高斯分布,因此本文采用服从以迭代次数  $n$  为自由度的  $t$  分布对染色体

进行扰动,使得算法在迭代前期拥有较强的全局探索能力,在迭代后期拥有较强的局部探索能力,具体的染色体扰动公式如下:

$$X'_i = X_i + X_i \cdot p(n) \quad (8)$$

式中: $X'$  为扰动后的染色体; $X$  为被扰动的染色体; $P(n)$  为  $t$  分布变量。

### 1.5 算法性能对比

为了研究遗传算法改进后的实际效果,本文通过典型测试函数 Ackley 进行最小值寻优的测试<sup>[14]</sup>。将 tent 混沌映射初始化种群、改进自适应遗传算子、 $t$  分布扰动策略这 3 种改进方法分别用 A、B、C 来表示。分别将传统遗传算法、A+B+C、A+B、A+C、B+C 五种方法来对比改进的效果。

Ackely 函数在  $x=0$  时有全局最优解 0,是个多峰函数,在解空间中存在大量的局部极值点,表达式如下:

$$f(x) = 20 + e - 20\exp\left(-0.2\sqrt{\frac{1}{D}\sum_{i=1}^D x_i^2}\right) - \exp\left(\frac{1}{D}\sum_{i=1}^D \cos(2\pi x_i^2)\right) \quad (9)$$

为避免偶然性,每种方法都单独进行 10 次实验测试,并将 10 次测试的最优解取平均值进行比较,结果如表 1 所示。5 种方式的最佳适应度迭代进化曲线如图 1 所示。结合表 1 与图 2 可以看出,A+B+C 明显优于其他几种方法。传统 GA 算法收敛时间最长,全局搜索能力和局部开发能力都很弱,需要迭代 40 次才能找到最优解,并且寻优结果误差最大;A+B+C 收敛时间最短,全局搜索能力和局部开发能力最强,寻优结果误差最小,由于 tent 混沌映射的作用,其第 1 代染色体就已经接近最优解;A+B 由于没有  $t$  分布扰动策略,所以在迭代后期的局部开发能力很弱;B+C 由于没有 tent 混沌映射的帮助,所以其第 1 代染色体远离最优解;A+C 因为是固定交叉、变异概率,所以在第 6 代开始,陷入了一段时间的局部最优解,随着迭代次数增加, $t$  分布帮助其脱离了局部最优解。

表 1 测试 10 次的最优解平均值

	传统 GA	A+B+C	A+B	B+C	A+C
最优解	0.064 6	$-8.881\ 8 \times 10^{-16}$	$2.545\ 5 \times 10^{-6}$	$2.659 \times 10^{-15}$	$2.642\ 3 \times 10^{-12}$

## 2 GA-BP 神经网络的建模

### 2.1 BP 神经网络

BP 神经网络是一种按误差反向传播算法训练的多层前馈网络,通常用来进行数据的分类与预测,本质上就是不断优化系统本身的权值和阈值,一般通过正向传输和误差反向传输两种方式对权值与阈值进行优化更新<sup>[15]</sup>。典型的 BP 神经网络一般由输入层、隐含层、输出层 3 个部分组成,主要的训练方法为正向传播即向输入层提供输入数

据,再经过 BP 神经网络模型内部的分层计算,最后将得到的输出值与目标值进行比较,差值即为 BP 神经网络的误差函数。误差的反向传播则是将输出误差通过隐含层向输入层逐层传输,各神经元同时根据误差信号来调整权值与阈值。经过反复学习与训练后,误差函数降低至所设置条件以内即结束训练,获得对应的权值与阈值。本文的 BP 神经网络预测压力传感器输出压力值的结构如图 2 所示,结构以压力传感器模组输出的压力数字信号、温度数字信号作为输入,压力值为输出。

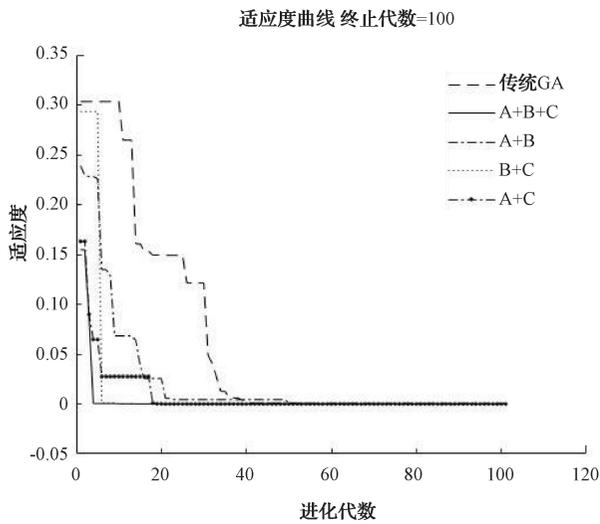


图1 5种方法的寻优曲线

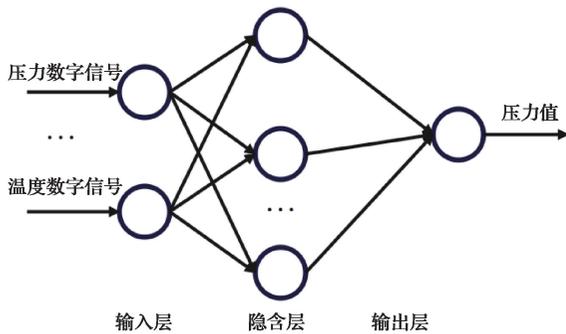


图2 BP神经网络结构

假设输入层的节点个数为  $n$ , 隐含层的节点个数为  $l$ , 输出层的节点个数为  $m$ 。输入层到隐含层的权重为  $\omega_{ij}$ , 隐含层到输出层的权重为  $\omega_{jk}$ , 输入层到隐含层的偏置为  $a_j$ , 隐含层到输出层的偏置为  $b_k$ 。学习速率为  $\eta$ , 输入层与隐含层的传递函数采用双曲正切函数  $g(x)$ , 隐含层的输出为  $H_j$ , 输出层的输出为  $O_k$ , 误差公式为  $E$ , 表达式如下:

$$g(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (10)$$

$$H_j = g\left(\sum_{i=1}^n \omega_{ij}x_i + a_j\right) \quad (11)$$

$$O_k = \sum_{j=1}^l H_j \omega_{jk} + b_k \quad (12)$$

$$E = \frac{1}{2} \sum_{k=1}^m (Y_k - O_k)^2 \quad (13)$$

$$e = (Y_k - O_k)$$

权值和阈值更新公式如下:

$$\begin{cases} \omega_{ij} = \omega_{ij} + \eta H_j (1 - H_j) x_i \sum_{k=1}^m \omega_{jk} e \\ \omega_{jk} = \omega_{jk} + \eta H_j e \end{cases} \quad (14)$$

$$\begin{cases} a_j = a_j + \eta H_j (1 - H_j) \sum_{k=1}^m \omega_{jk} e \\ b_k = b_k + \eta e \end{cases} \quad (15)$$

## 2.2 GA-BP神经网络的实现

BP神经网络的非线性能力很强,可以利用它来发掘输入数据与输出数据之间的非线性关系,但是模型的初始权值和阈值对BP神经网络算法收敛的影响很大,而传统BP神经网络通过随机初始化的方式得到初始权值与阈值,这种方法很容易使得算法陷入局部最优解,最终导致得到的模型不理想<sup>[16]</sup>。因此本文利用改进的遗传算法来优化BP神经网络,利用遗传算法的寻优能力为BP神经网络找到一组最适合的初始权值和阈值,防止BP神经网络陷入局部最优解且加快了收敛速度。

算法步骤如下:

- 1) 遗传算法通过 Tent 混沌映射序列初始化种群,并计算每个染色体的适应度;
- 2) 通过轮盘赌选择染色体;
- 3) 随机挑选两个染色体,以适应度大的染色体为依据,按照改进自适应交叉算子公式计算交叉概率,决定是否交叉;
- 4) 随机挑选一个染色体,按照改进自适应变异算子公式计算变异概率,决定是否变异;
- 5) 利用  $t$  分布对经过基因遗传操作后的种群进行扰动并组成新一代种群;
- 6) 计算种群中每个染色体的适应度,更新最佳染色体;
- 7) 判断是否到达遗传算法预设迭代次数上限;若到达迭代次数上限,即将最佳染色体作为初始权值和阈值。若未到达迭代次数上限,则返回到步骤 2);
- 8) 将经过遗传算法计算得到的初始权值和阈值赋给BP神经网络开始训练;

- 9) 根据逐层计算得到的误差信息不断更新权值和阈值;
- 10) 判断是否达到BP神经网络预设迭代次数上限或者误差低于预设值,若达到条件,即结束BP神经网络训练,得到所需模型的权值和阈值,并计算模型精度。若未达到条件则返回到步骤 9)。

GA-BP神经网络的整体流程如图3所示。

## 3 实验与分析

### 3.1 样本数据来源

实验仿真采用 MATLAB R2019b 编程软件平台,将同一份数据分别用于训练传统 GA-BP 神经网络模型和本文所采用的改进 GA-BP 神经网络模型。压力传感器采用的是华润微研发的 CMP150A,压力传感器输出的是电压信号,本次使用的数据是经过可编程增益放大器以及 A/D 转换后的数字信号值。数据采集流程主要为将压力传感器模组连接气压泵放入温箱中,温度区间设置为

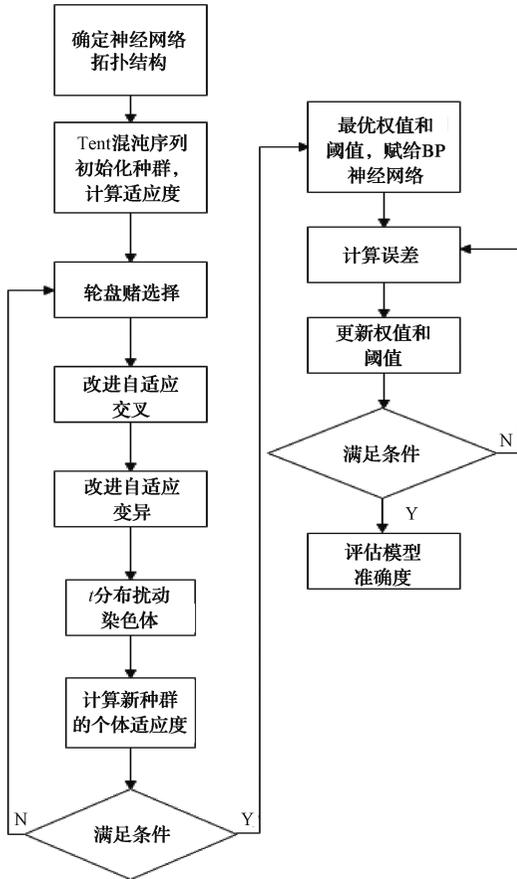


图3 算法流程

-20℃~100℃, 压力区间设置为50~150 kPa。即总共采集247组数据用于训练BP神经网络模型。电压信号和数字信号的转换公式如下:

$$D = \frac{V \times PGA}{1.8} \times 2^{23} \quad (16)$$

### 3.2 仿真实验分析

遗传算法的最佳适应度迭代进化曲线是最直观体现算法优劣的凭证。如图4所示, 传统GA-BP神经网络算法其迭代前期全局搜索能力较差, 在迭代前期即第3~56代就陷入了局部最优解中, 自身跳出局部最优的能力较弱, 在迭代中后期也多次陷入局部最优解中, 证明其迭代后期的局部开发能力同样较弱, 导致算法整体收敛速度很慢。而本文的改进GA-BP神经网络算法经过14次迭代就已经基本收敛并且所找到的解也优于传统GA-BP神经网络算法。该算法在改进自适应遗传算子以及 $t$ 分布扰动的帮助下, 不管在迭代前期还是后期, 收敛能力都远胜于传统GA-BP神经网络算法。

### 3.3 硬件实现与实验验证

将GA-BP神经网络算法移植到调理芯片需要解决一个问题即如何在调理芯片中实现激活函数Tanh。本文采

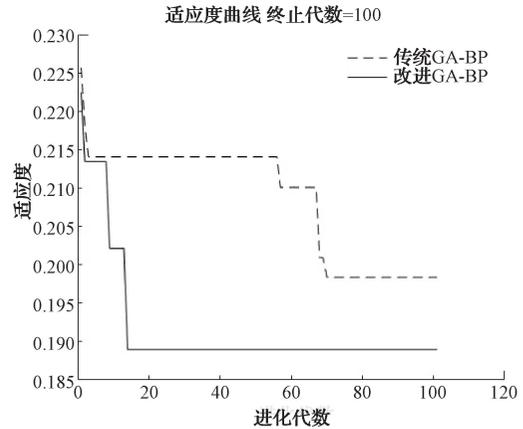


图4 最佳适应度迭代曲线

用的调理芯片是8 bit 低端单片机, 其计算能力不强无法运行Tanh函数。式(11)即Tanh函数公式, 该函数关于原点对称, 当 $x < -4$ 和 $x > 4$ 时, 其函数值可约等于1, 因此只需要对函数的 $[0, 4]$ 进行拟合, 本文采用以0.5为步进的分段线性拟合法实现该函数<sup>[17]</sup>。具体分段函数如下。分段拟合曲线与Tanh函数的误差如图5所示, 由图5可知, 最大误差为0.010 91。

$$y = \begin{cases} 0.927\ 247x + 0.006\ 591, & x \in (0, 0.5) \\ 0.598\ 513x + 0.175\ 358, & x \in [0.5, 1] \\ 0.285\ 827x + 0.484\ 043, & x \in (1, 1.5) \\ 0.117x + 0.733\ 466, & x \in [1.5, 2] \\ 0.044\ 844x + 0.875\ 867, & x \in (2, 2.5) \\ 0.016\ 752x + 0.945\ 313, & x \in [2.5, 3] \\ 0.006\ 197x + 0.976\ 676, & x \in (3, 3.5) \\ 0.002\ 284x + 0.990\ 26, & x \in [3.5, 4] \end{cases} \quad (17)$$

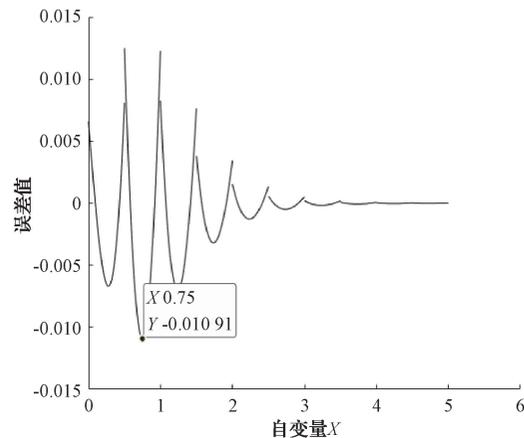


图5 线性拟合Tanh误差曲线

为了评估压力传感器的精度, 本文采用零点漂移系数和灵敏度漂移系数以及满量程相对误差来评估经过神经网络校准后的压力传感器的精度。

零点漂移:

$$\alpha_0 = \frac{|\Delta P_{0\max}|}{\Delta T \cdot P_{FS}} \times 100\% \quad (18)$$

式中:  $|\Delta P_{0\max}|$  是全程内零点输出改变量的最大值;  $\Delta T$  为压力传感器的工作范围;  $P_{FS}$  为压力传感器的满量程输出值。

灵敏度漂移:

$$\alpha_s = \frac{|\max(\Delta P)|}{\Delta T \cdot P_{FS}} \times 100\% \quad (19)$$

式中:  $|\max(\Delta P)|$  是任意一个压差下输出改变量的最大值。

全程相对误差:

$$\theta = \frac{|\max(\Delta P)|}{P_{FS}} \times 100\% \quad (20)$$

用分段线性拟合法将训练好的神经网络移植到压力传感器模组的调理芯片中并连接气压泵,接着放入温箱中进行实验复测,部分复测数据如表2所示。

表2 复测数据

输入压力/kPa	-20 °C	20 °C	100 °C
0	-0.035	0.005	0.117
50	50.070	49.973	50.033
60	60.027	59.974	60.020
输入压力/kPa	-20 °C	20 °C	100 °C
70	70.030	70.034	70.011
80	80.028	80.048	80.009
90	90.039	89.987	89.980
100	99.982	99.958	100.016
110	109.960	109.970	110.007
120	119.997	120.001	120.029
130	130.025	129.974	130.013
140	140.007	139.978	140.075
150	150.005	149.969	149.963

经过神经网络校准后的压力传感器的零点漂移、灵敏度漂移、全程相对误差为:

$$\alpha_0 = \frac{|0.117 - (-0.035)|}{120 \times 150} \times 100\% = 8.444 \times 10^{-6}$$

$$\alpha_s = \frac{|50.07 - 50.033|}{120 \times 150} \times 100\% = 2.055 \times 10^{-6}$$

$$\theta = \frac{|0.117 - (-0.035)|}{150} \times 100\% = 0.101\%FS$$

结果表明,通过改进 GA-BP 神经网络校准后的压力传感器的满量程相对误差精度达到 0.101%FS,远低于数值法校准的 0.9%FS,也低于 ELM 神经网络校准的 0.2%FS。因此,改进 GA-BP 神经网络法可以有效地降低温度对压力传感器输出的影响。

#### 4 结论

为了降低温度漂移对压力传感器输出的影响,本文提

出了改进 GA-BP 神经网络算法对压力传感器进行校准补偿。算法利用 Tent 混沌映射来初始化种群,从而使得种群个体在初始化阶段就更接近最优解;在染色体遗传阶段,由于改进的自适应遗传算子可以动态更新交叉概率和变异概率,从而可以维持种群的多样性,使得算法不易陷入局部最优解;然后通过  $t$  分布对染色体进行扰动,使得算法在迭代前期拥有较强的全局搜索能力,在迭代后期拥有较强的局部开发能力,从而让算法更容易找到最优解。本文通过消融实验进行对比,证明了改进的遗传算法可以取得更好的寻优效果。最后使用该遗传算法得到 BP 神经网络的一组最优的初始权值与阈值,并进行神经网络训练,然后将训练好的神经网络通过分段线性拟合法移植到调理芯片中进行实验验证。实验数据表明,本算法的校准精度优于其他算法,有效地降低了温度漂移对压力传感器输出的影响。当然,研究仍有问题需要改进,BP 神经网络对样本数据的需求量较大,因此在工程应用中需要耗费更多的成本。

#### 参考文献

- [1] 李陆一. 电子信息技术在物联网中的应用与分析[J]. 数字通信界, 2021(10):99-100.
- [2] 于向前, 刘斯, 肖池阶, 等. 惠斯通电桥式磁阻传感器的零位温度漂移研究[J]. 北京大学学报(自然科学版), 2021, 57(3):401-406.
- [3] 乔维德. 基于 BP 神经网络模型的压力传感器温度补偿[J]. 淮阴师范学院学报(自然科学版), 2019, 18(4):322-327.
- [4] 罗静静, 左晶晶, 季仲致, 等. 面向脉诊客观化的脉搏传感器研究综述[J]. 仪器仪表学报, 2021, 41(8):1-14.
- [5] 薛胜方, 梁庭, 雷程, 等. 单存良压阻式高温压力传感器温度补偿与信号调理设计与测试[J]. 计算机测量与控制, 2021, 29(2):256-261, 266.
- [6] 吉彬, 张永建, 狄长安, 等. 基底材料对 PVDF 体感压力传感器测量的影响分析[J]. 国外电子测量技术, 2022, 41(2):60-64.
- [7] 贺红林, 许佳豪, 周战洪, 等. 压阻式压力传感器温度误差的插值补偿方法研究[J]. 电子测量与仪器学报, 2021, 35(12):1-7.
- [8] 朱志峰, 张海宁. 压力变送器非线性校准及温度补偿方法的研究[J]. 电子测量技术, 2021, 44(21):71-76.
- [9] ZHOU G W. A smart high accuracy silicon piezoresistive pressure sensor temperature compensation system [J]. Sensors, 2014, 14(7): 12174-12190.
- [10] ZHANG C, WANG Y, GUO J, et al. Digital recognition based on neural network and FPGA implementation[C]. 2017 9th International Confere-

- nance on Intelligent Human-Machine Systems and Cybernetics (IHMSC), 2017, 280-283.
- [11] 岳龙飞,杨任农,张一杰,等. Tent混沌和模拟退火改进的飞蛾扑火优化算法[J],哈尔滨工业大学学报, 2019,51(5):146-154.
- [12] 张伟康,刘升. 自适应  $t$  分布与黄金正弦改进的麻雀搜索算法及其应用[J]. 微电子学与计算机, 2022, 39(3):17-24.
- [13] 徐亦凤,刘升,张伟康,等. 精英反向学习  $t$  分布饥饿游戏搜索算法[J/OL]. 计算机仿真: 1-11[2023-01-06]. <http://kns.cnki.net/kcms/detail/11.3724.TP.20220824.1444.002.html>.
- [14] GAO W F, LIU S Y, HUANG L L. A novel artificial bee colony algorithm with Powell's method[J]. Applied Soft Computing, 2013,13(9):3763-3775.
- [15] ZHANG D J, ZHANG G Y, LI L Q. Calibration of a six-axis parallel manipulator based on BP neural network[J]. The Industrial Robot, 2019, 46(5): 692-698.
- [16] 范佳静,曹玉华,曹敏. 基于 GABP 神经网络预测法的工程机械再制造员工效率研究[J]. 工业技术经济, 2018,37(8):147-153.
- [17] 张尧. 激活函数导向的 RNN 算法优化[D]. 杭州:浙江大学,2017.

#### 作者简介

吴凯枫,硕士研究生,主要研究方向为嵌入式系统、传感器系统开发。

E-mail:473119348@qq.com

张立新(通信作者),硕士,高级工程师,主要研究方向为计算机技术、嵌入式系统。

E-mail:zhanglx@cwzu.edu.cn