

基于遗传算法优化 BP 神经网络的 探针测量修正方法

孔惟龙¹, 郑光华^{1,2}, 郑皓月¹, 杨善杰¹

(1. 西北工业大学 动力与能源学院, 西安 710129;

2. 中国航发四川燃气涡轮研究院 高空模拟技术重点实验室, 四川 绵阳 621000)

摘 要: 针对探针在航空发动机复杂流场中因多种因素导致的总压测量误差的问题, 采用了一种基于遗传算法优化反向传播 (GA-BP) 神经网络的误差修正方法。基于数值模拟得到的多组样本数据集, 采用 GA-BP 神经网络: 确定隐藏层为 6 节点结构; logsig 和 purelin 分别为隐藏层、输出层的激活函数, trainlm 为训练函数; 优化初始种群规模为 45, 交叉概率 0.8 与变异分布指数为 5 的组合使方均根误差降至 0.375 91。实验结果表明: GA-BP 测试集的方均根误差较标准 BP 模型降低 66.7%, 平均相对误差降幅为 72.4%, 决定系数高于 0.999; 90% 样本误差低于 2×10^{-3} 且在零均值对称分布, 显著提升了模型的修正精度与泛化能力, 为航空发动机气动性能测试提供了参考方案。

关 键 词: 探针; 总压测量; 误差修正; 神经网络; 遗传算法

中图分类号: V211.3

文献标志码: A

Probe measurement correction method based on genetic algorithm-optimized BP neural network

Kong Weilong¹, Zheng Guanghua^{1,2}, Zheng Haoyue¹, Yang Shanjie¹

(1. School of Power and Energy, Northwestern Polytechnical University, Xi'an 710129, China;

2. Science and Technology on Altitude Simulation Laboratory, Sichuan Gas Turbine Establishment,
Aero Engine Corporation of China, Mianyang Sichuan 621000, China)

Abstract: To address total pressure measurement errors caused by multiple factors in complex aero-engine flow fields, an error correction method based on a genetic algorithm-optimized backpropagation (GA-BP) neural network was proposed. Utilizing multi-sample datasets from numerical simulations, the GA-BP neural network was adopted: a 6-node hidden layer structure was determined, with logsig and purelin served as activation functions for the hidden and output layers respectively, and trainlm as the training function. An optimized combination of initial population size of 45, crossover probability of 0.8, and mutation distribution index of 5 reduced the root mean square error to 0.375 91. Experimental results demonstrate that, compared with the standard BP model, the GA-BP model reduced root mean square error by 66.7% and the mean relative error by 72.4% on the test set, while achieving a coefficient of determination above 0.999; errors of 90% samples were below 2×10^{-3} and symmetrically distributed around zero. This proposed approach significantly enhances correction accuracy and generalization capability, providing a reference solution for aero-engine aerodynamic performance testing.

收稿日期: 2026-04-29

作者简介: 孔惟龙(2000—), 男, 硕士, 主要从事航空发动机气动参数测量研究。E-mail: k15566784977@163.com

通信作者: 郑光华(1978—), 男, 副教授, 博士, 主要从事涡轮叶片新型冷却和涡轮气动热力学研究。E-mail: zhengguanghua@nwpu.edu.cn

引用格式: 孔惟龙, 郑光华, 郑皓月, 等. 基于遗传算法优化 BP 神经网络的探针测量修正方法[J]. 航空动力学报, 2027, 42(1): 20250439. Kong Weilong, Zheng Guanghua, Zheng Haoyue, et al. Probe measurement correction method based on genetic algorithm-optimized BP neural network[J]. Journal of Aerospace Power, 2027, 42(1): 20250439.

Keywords: probe; total pressure measurement; error correction; neural network; genetic algorithm

在航空发动机研制和实验过程中,发动机关键截面的流场参数(如总压、总温)的精确测量是评估气动性能和诊断故障的核心依据^[1-2]。探针作为一种传统的测量工具,仍然是获取发动机流道参数的关键手段^[3]。然而,受发动机内部复杂流动特性及探针安装条件的影响,探针的测量值与真实值之间存在显著偏差。在近壁面测量时,探针与壁面会相互干扰破坏附近流场分布,从而产生不同程度的测量误差。同时在某些截面布置多根探针也会对流场产生一定的堵塞作用,随着探针数量的增加,堵塞效应^[4]对流场的影响也愈加明显,偏离发动机的真实工作状态,造成探针的测量误差,严重时还会发生发动机失速。

国内外许多学者对于探针的测量误差及修正进行了详细的研究,马宏伟等^[5]通过数值模拟去分析了速度梯度、近壁效应和雷诺数对几种叶轮机械流场用压力探针测量误差的影响,发现横向梯度和纵向梯度会分别引起探针偏转角、俯仰角的测量误差。Vukoslavcevic 等^[6-7]研究了热线探针在湍流中的测量误差,特别是速度梯度对测量精度的影响,并提出了一种新型探针配置以减少此类误差。王洪伟等^[8]对单孔探针的误差进行研究,分析了速度梯度对圆柱探针测量的影响,同时提出了探针测量结果的修正方法,通过数值模拟将流动因素与测量误差拟合为函数关系,并在实验中得到了验证。Guo 等^[9]针对光学非球面接触式探针因半径偏差与轮廓变形导致的测量误差问题,通过实验分析了探针半径误差与非线性轮廓误差,构建基于数据驱动的误差建模与补偿方法,研究表明该方法可将探针测量误差从 0.436 μm 降至 0.023 μm ,有效解决了多因素耦合导致的测量精度劣化的问题。王洪伟等^[10]对于五孔探针的数据处理方法进行了详细的研究,发展了一种人工神经网络的数据处理方法,并将其与三维线性插值法进行了全面的对比,证明了神经网络法的精度更高,可靠性更好。吴晓东等^[11]提出了一种新的三孔探针数据修正方法——相交曲线法,通过对比样条插值和最小二乘法,效率提高了一倍以上,具有较高的实用价值。仇宝云等^[12]针对探针杆挠曲导致流场中的流速测量偏差的问题,提出基于“挠曲变形-流速矢量”耦合方程的计算修正方法,结果表明修正后探针测量流速的方均

根误差显著降低。谢金伟等^[13]为探究大梯度流场下五孔探针的失真特性,建立了用于修正速度梯度所引起的测量误差的数据处理方法,通过引入无量纲速度梯度建立角度误差修正公式,可以有效减小梯度流场中气流角的测量误差。

传统修正方法多依赖经验公式或计算流体力学仿真插值,但难以有效处理非线性、高维度的误差耦合问题,导致修正精度显著下降。近年来,数据驱动方法为探针误差修正提供了新思路,其中神经网络凭借其强大的非线性拟合能力^[14],能够从海量数据中挖掘多因素间的隐含关联,而遗传算法等智能算法可进一步优化模型结构与参数,提升模型修正精度。

本文采用基于遗传算法(GA)优化反向传播(BP)神经网络的模型(GA-BP),针对探针总压测量误差修正问题开展研究,通过数值模拟得到大量的探针总压测量数据集对网络进行训练和测试,基于 GA 优化所建立的 GA-BP 神经网络探针测量误差修正模型,对比分析模型优化前后的修正误差,为发动机性能测试与优化提供技术参考与借鉴。

1 数值方法

1.1 几何模型

本文计算域为简化的发动机环形流道,整体结构为内轮毂加外机匣结构,考虑到某中小型涡轴发动机的实际尺寸,计算域外径为 300 mm,内径为 220 mm,计算域长度为 300 mm,其中探针感压管到计算域入口的距离为 150 mm。将 y 轴正方向作为气流的主流方向,计算域中心轴线到探针感压管中心轴线为 z 轴正方向,另一横向方向为 x 轴正方向,计算模型如图 1(a)所示。在计算探针所引起的堵塞比时,所采用的模型为 1/4 环形结构,结构如图 1(b)所示。

本研究所采用探针类型为单点 L 型总压探针和四点梳状总压探针,结构如图 2(a)、图 2(b)所示。单点总压探针的外半径为 1.6 mm,壁厚为 0.2 mm,感压管直线段长度为 6 mm,探针入口处存在倒角为 45°;四点梳状总压探针的各感压管尺寸一致,外半径为 2 mm,壁厚为 0.5 mm,弯管处半径为 2 mm,感压管直线段长度分别为 1.5、3.5、5.5、7.5 mm,入口倒角为 45°,各感压管间距




图1 计算模型(单位: mm)

Fig. 1 Computational model (unit: mm)




图2 总压探针结构


Fig. 2 Total pressure probe configuration

为 8 mm。

1.2 网格划分

本文采用 Fluent Meshing 对模型进行网格划分, 整体采用非结构化网格, 计算域壁面采用 10 层附面层网格, 增长比为 1.2, 保证近壁端湍流模型 y^+ 值为 1 左右, 由于探针尺寸较小, 因此在探针附近进行局部加密处理以捕捉附近流场。网格数量越多可以使计算结果更加准确, 但是会严重占用计算资源, 降低计算效率, 因此在开展计算之前, 确定合适的网格数量就非常有必要。

通过不断加密全局网格尺寸以及局部尺寸, 使整个计算域的网格数量在 105 万、245 万、476 万、735 万、1 100 万, 计算结果如图 3 所示, 其中 Ma_{free} 为来流马赫数, 即自由来流气流速度与当地声速的比值; h 为探针的临壁距离, 即探针的感压管中心轴线与机匣壁面之间的高度。随着网格数量的增加, 计算域的进出口压比($p_{\text{out}}/p_{\text{in}}$)逐

图3 网格无关性分析($Ma_{\text{free}}=0.3$, $h=3$ mm)Fig. 3 Grid independence study ($Ma_{\text{free}}=0.3$, $h=3$ mm)

渐趋于稳定, 当网格数量超过 400 万时, 进出口压比随着网格数量变化不再继续变化。为了降低计算成本, 平衡计算精度和速度, 本文选取网格数量为 470 万左右进行后续计算, 图 4 为计算域网格及探针附近边界层处理。




图4 网格划分

Fig. 4 Mesh generation

1.3 计算方法

流体的运动需要受到物理守恒定律的影响, 通常要满足三大基本定律: 质量守恒定律、动量守恒定律和能量守恒定律。探针作为一种最常用的接触式测量手段, 为了可以更加准确地捕捉到探针周围的流场细节, 数值模拟中选择合适的湍流模型就格外重要。本文研究聚焦于马赫数为 0.2~0.8 的亚声速可压缩流动, 主要关注探针头部滞止流动和支杆钝体绕流等流动现象, 由于标准 $k-\varepsilon$ 模型对边界层流动与钝体绕流分离特征具有优异的模拟精度, 可准确复现多因素影响下探针周围的流场扰动特性与误差产生机理, 因此本文的湍流模型选为标准 $k-\varepsilon$ 模型, 壁面函数选择适用于高雷诺数流动的增强壁面函数, 不仅能处理高雷诺数下的湍流主导区域, 也能准确模拟低雷诺数近壁区的流动特征。当动量方程、能量方程和湍流方程的残差降低到 1×10^{-6} 且探针总压

测量点的数值不再波动时作为收敛的标准,残差曲线呈现出持续下降后趋于平缓的趋势,表明方程求解已达到稳定状态。

1.4 边界条件

计算域入口设定为压力入口,设置入口总温、总压和气流的方向,在无气流偏转角的工况下气流的流动方向与流道轴线平行,保证流场初始状态均匀;出口设为压力出口,流动方向垂直于出口边界,其余边界均设为绝热无滑移壁面。环境温度、总静压分别与马赫数的关系式如下,环境温度为 293.15 K,静压为 101 325 Pa。本文选取的来流马赫数 Ma_{free} 范围为 0.2~0.8,每间隔 0.1 取一个,共需要设置 7 组进口总温和总压值。

$$T_t = T_{\text{free}} \left(1 + \frac{\gamma-1}{2} Ma_{\text{free}}^2 \right) \quad (1)$$

$$p_t = p_{\text{free}} \left(1 + \frac{\gamma-1}{2} Ma_{\text{free}}^2 \right)^{\frac{\gamma}{\gamma-1}} \quad (2)$$

式中 T_t 为入口总温设定值; p_t 为入口总压设定值; T_{free} 为自由来流环境温度; p_{free} 为自由来流静压; γ 为气流的比热比。

2 数值方法验证

为了验证本文数值模拟方法在真实发动机流场中的适用性,根据数值仿真中的计算域模型,设计实验工况建立对应的实验流场,利用风洞生成与仿真计算条件一致的实际流场环境,通过调节总压探针测点中心轴线与流道壁面的间距,分析总压探针测量值的变化规律,最终与数值仿真结果开展对比分析,为数值模拟方法的可靠性验证提供实验支撑。本实验以单点总压探针为研究对象,共两种实验工况,来流马赫数分别为 0.2 和 0.4,每种工况下探针存在着 9 种临壁距离,分别为 2、3、4、5、6、7、8、9 mm 和 10 mm。

为了实现所需的实验流场环境条件,需要搭建相应的实验系统,实验系统由实验件、实验工装和实验设备组成。图 5 为总压探针的实验系统图,通过压力调节阀调节进口气流的马赫数,利用三向移动架来改变探针的临壁距离,气流进入探针感压管经过压力传感器输出,最终总压测量值由采集系统采集。

图 6 分别展示了来流马赫数为 0.2 和 0.4 时,




图 5 实验系统图

Fig. 5 Experimental system diagram




图 6 不同临壁距离下的总压测量误差实验值与数值模拟结果对比

Fig. 6 Comparison of experimental and numerical simulation results of total pressure measurement error at different wall distances

实验与数值模拟得到的总压测量相对误差随着临壁距离的变化曲线。从图中可以看出,在两种工况下,实验与数值模拟的误差变化趋势基本一致,均呈现出随着临壁距离的增大,总压测量误差逐渐减小的规律。其中来流马赫数为 0.2 时,实验与数值模拟结果的最大偏差为 1.18%;来流马赫数为 0.4 时,两者的最大偏差为 2.81%,偏差处于工程可以接受的范围内。因此本文采用的数值模拟方法可以较为准确地得到探针的总压测量值,数值模拟结果与实验数据具有良好的一致性,验证了数值方法的可靠性。

3 神经网络方法

3.1 BP 神经网络

人工神经网络作为数据驱动方法的典型代表,它拥有着强大的非线性拟合能力来解决多变量耦合问题,其中反向传播(backpropagation, BP)神经网络因为结构简单和训练算法成熟的特点而被广泛使用。BP 神经网络是一种基于梯度下降和误差反向传播的前馈型神经网络^[15],在监督学习模型下通过调整网络的权重和阈值使得预测输出值与训练样本真实值的方均根误差达到最小。

BP 神经网络的结构包括输入层、隐藏层和输出层,各层神经元都通过带有权重的连接相互关联,具体网络结构如图 7 所示。




图 7 单隐藏层神经网络结构

Fig. 7 Single hidden layer neural network architecture

隐藏层通过非线性的激活函数对输入特征进行逐层变换,直至输出层产生结果,当结果和真实值存在偏差时,网络会通过反向传播算法优化参数,并基于梯度下降原理,沿误差减小的方向更新参数使损失函数逐步降低,从而实现输入到输出的自适应拟合。

假设神经网络中输入层、隐藏层和输出层的神经元个数分别为 m 、 n 和 e ,输入层的输入特征为 $X_i, i=(1, 2, 3, \dots, m)$,输入层与隐藏层的连接权

重为 $w_{ij}, j=(1, 2, 3, \dots, n)$,隐藏层的输入值和输出值分别为 H_j 和 h_j ,隐藏层与输出层的连接权重为 w_{jk} ,输出层的输入值与输出值为 Y_k 和 y_k , y_k^* 为实际输出。在输入数据集并进行归一化处理后,隐藏层的输入和输出值为:

$$H_j = \sum_{i=1}^m X_i w_{ij} \quad (3)$$

$$h_j = f(H_j) \quad (4)$$

随后将数据传递到输出层,使得输出层的输入和输出值分别为:

$$Y_k = \sum_{j=1}^n h_j w_{jk} \quad (5)$$

$$y_k = f(Y_k) \quad (6)$$

网络对输出值和训练样本的真实值进行方均根误差(E)计算,然后反向传播至隐藏层与输入层:

$$E = \frac{1}{2} \sum_{k=1}^m (y_k - y_k^*)^2 = \frac{1}{2} \sum_{k=1}^m \left[f \left(\sum_{j=1}^n h_j w_{jk} \right) - y_k^* \right]^2 \quad (7)$$

$$E = \frac{1}{2} \sum_{k=1}^m \left\{ f \left[\sum_{j=1}^n f \left(\sum_{i=1}^m X_i w_{ij} \right) w_{jk} \right] - y_k^* \right\}^2 \quad (8)$$

由式(8)可以看出方均根误差与各层的权值 w_{ij} 和 w_{jk} 有关系,因此调整网络各层的权值是减小误差的主要手段。为了将误差不断减小,将权值调整量与误差的梯度下降形成正比关系:

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \quad (9)$$

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} \quad (10)$$

式中 η 为比例系数,即神经网络中训练数据的学习率。

虽然 BP 神经网络可以处理复杂的非线性问题,但是也有其自身的缺陷和不足:在处理大规模数据集时,需要多次迭代调整权值和阈值,训练时间长且容易陷入局部最优^[16]。因为初始权重是随机的,所以网络的性能也会受到影响,不同的初始权重会导致不同的训练结果。在反向传播过程中可能会出现梯度消失或梯度爆炸情况,导致网络的训练结果不稳定。针对上述问题需要采

用优化算法对 BP 神经网络进行优化,从而提高网络的性能,本文采用具有全面搜索能力的 GA 对标准 BP 神经网络进行优化。

3.2 遗传优化算法

GA 是通过模拟自然界中的生物基因与演化过程来实现全面搜索能力的算法,其核心思想是将问题的解编码为“染色体”,通过选择、交叉、变异等遗传操作,在迭代过程中逐步筛选出适应度更高的个体,最终逼近最优解^[17]。本文的适应度值是预测值与真实值的方均根误差:

$$f(\epsilon_i) = \frac{1}{2} \sum_{k=1}^u (y_k - y_k^*)^2 \quad (11)$$

式中 $f(\epsilon_i)$ 为第 i 个染色体的适应度; y_k 为第 i 个染色体在第 k 组样本中的预测值; y_k^* 为第 i 个染色体在第 k 组样本中的真实值; u 为样本的总数量。

本文利用遗传优化算法通过将 BP 神经网络的优化参数实数编码为“染色体”,使用训练数据进行前向传播,计算出输出与真实值的方均根误差,并将其转换为适应度函数,通过适应度排序,筛选出适应度较好的个体进入进化流程。在生成新一代种群后,重新进行适应度评估与遗传操作,直到适应度不再发生变化或者达到了预设的最大迭代次数,最终选取最优的“染色体”所对应的参数,即为问题的最优解,GA-BP 神经网络的具体流程如图 8 所示。




图 8 GA-BP 神经网络的算法流程图

Fig. 8 Algorithm flowchart for GA-BP neural network

3.3 模型结构设计

3.3.1 网络拓扑结构

本文模型的训练数据集涵盖来流马赫数、临壁距离、堵塞比和气流偏转角这 4 个主要影响因素,将其作为输入特征,输出特征为探针的总压测量真实值,共 148 组数据样本。将数据样本按照 7 : 3 的比例分成训练集和测试集,并按照式(3)

归一化处理,使其映射到 [0,1] 的范围内。神经网络的隐藏层节点数通常由经验公式(12)来进行确定^[18]:

$$m-1 < n < \sqrt{(e+m)} + a \quad (12)$$

式中 m 为神经网络的输入层节点数; n 为隐藏层节点数; e 为输出层节点数; a 为 [0, 10] 之间的整数,

本文 $a=8$ 。

由经验公式可知本模型隐藏层节点数的取值范围为 [3, 10], 其他参数保持不变, 采用穷举法逐一训练模型, 共设计了 7 组重复实验, 表 1 为不同

隐藏层节点数下的模型方均根误差, 当隐藏层节点个数为 6 时, 方均根误差达到了最低, 相比 3 个节点数的误差减小了 0.711, 因此确定隐藏层节点个数为 6 个。

表 1 隐藏层不同节点数时的方均根误差

Table 1 Root mean squared error with different numbers of hidden layer nodes

隐藏层节点数	实验次数							平均值
	1	2	3	4	5	6	7	
3	1.136 6	1.469 3	1.779 2	1.843 3	1.466 3	1.627 6	0.960 4	1.469 0
4	0.885 5	0.805 2	1.848 5	1.746 0	0.901 7	0.378 4	0.537 3	1.014 7
5	0.338 8	0.349 1	0.892 9	1.356 2	0.972 8	1.519 6	1.223 8	0.950 5
6	1.524 2	1.452 4	0.454 7	0.761 6	0.319 7	0.585 5	0.207 4	0.758 0
7	0.613 3	1.402 9	0.586 0	0.868 4	0.367 0	1.509 4	0.764 3	0.873 0
8	1.341 1	0.444 5	1.663 3	0.374 9	1.068 0	1.233 0	0.614 0	0.962 7
9	1.289 4	0.647 8	0.878 1	0.818 0	0.907 4	0.992 8	1.080 2	0.944 8
10	1.414 8	0.776 4	0.627	1.377 9	0.552 4	1.185 7	0.867 7	0.971 7

3.3.2 激活函数和训练函数

激活函数和训练函数会直接影响到 BP 神经网络模型的训练效率和稳定性。在 BP 神经网络中, 比较常见的激活函数主要有 logsig、purelin 和 tansig 函数^[19]; 训练函数主要有 4 类: trainlm、trainbr、trainrp 和 traingdx。通过对比训练步数和方均根误差来选择适配模型的函数, 其训练结果分别如表 2 和表 3 所示。

表 2 不同激活函数的方均根误差对比表

Table 2 Comparison table of root mean squared errors for different activation functions

隐藏层	输出层	方均根误差
logsig	logsig	16.883
purelin	logsig	15.933
tansig	logsig	16.122
logsig	purelin	0.710
purelin	purelin	3.958
tansig	purelin	0.766
logsig	tansig	1.447
purelin	tansig	3.376
tansig	tansig	0.881

在综合考虑收敛速度和准确度下, 隐藏层激活函数设为 logsig, 输出层激活函数设为 purelin, 训练函数选择 trainlm, 既可以达到很好的修正精度, 又有着高效的收敛速度来压缩训练耗时, 加速了从模型搭建到结果验证的流程。

3.3.3 遗传算法参数

本研究针对初始种群数量为 10~70 进行了

多组实验, 结果如表 4 所示, 从结果可以看出, 当初始种群数量为 45 时, 方均根误差达到了最小, 对总压探针测量误差的修正也更加准确, 因此确定初始种群数量为 45。

表 3 不同训练函数的方均根误差对比表

Table 3 Comparison table of root mean squared errors for different training functions

训练函数	训练步数	方均根误差
trainlm	50	0.553
trainbr	290	0.503
trainrp	36	2.272
traingdx	156	4.422

表 4 不同初始种群的方均根误差

Table 4 Root mean squared error with different initial populations

初始种群数量	训练步数	方均根误差
10	34	0.455 546
15	42	0.448 802
20	22	0.767 064
25	24	0.711 038
30	42	0.856 368
35	32	0.704 458
40	27	0.455 836
45	31	0.337 510
50	24	0.637 122
55	30	0.578 608
60	24	0.758 14
65	24	0.390 754
70	38	0.472 082

在 GA 中,交叉概率决定了父代个体进行遗传信息交换的可能性,而变异分布指数则控制着变异算子扰动的大小和分布特性^[20]。为确定探针

测量误差修正模型的最优参数组合,本文系统地评估了不同交叉概率(P_c)和变异分布指数组合下的算法性能,结果如表 5 所示。

表 5 不同交叉概率和变异分布指数的方均根误差

Table 5 Root mean squared error for different crossover probabilities and mutation distribution indices

变异分布指数	方均根误差					
	$P_c=0.4$	$P_c=0.5$	$P_c=0.6$	$P_c=0.7$	$P_c=0.8$	$P_c=0.9$
2	0.417 37	0.599 393	0.449 535	0.607 968	0.848 658	1.136 81
3	0.417 895	0.560 195	0.669 135	0.585 493	0.379 86	0.398 423
4	0.435 128	0.650 01	0.847 36	0.775 194	1.048 908	0.775 638
5	0.514 388	0.731 993	0.403 785	0.407 817	0.375 91	1.016 433
6	0.572 373	0.898 44	0.727 013	0.536 35	0.672 43	0.381 245

结果表明,当变异分布指数为 5,交叉概率为 0.8 时,方均根误差为 0.375 910,是所有组合中方均根误差最小的一组。基于此实验结果,本研究最终选择交叉概率为 0.8,变异分布指数为 5 的组合作为 GA 的主要设定参数。

基本同步,训练集的方均根误差为 0.342 140,测试集的方均根误差是 0.338 540,在同一个样本区间内,修正值的偏离程度显著减小。这进一步说明了 GA 通过优化 BP 模型的初始权重和阈值,不仅增强了它的拟合精度,也提升了模型的泛化能力。

4 结果与分析

本文共选取 148 组数据作为数据集,以 7 : 3 的比例划分数据集为训练集和测试集,训练集为 104 组,测试集有 44 组数据,在设置好上述网络参数后对 GA-BP 神经网络进行训练并输出结果,图 9 为 GA 的优化过程。





图 9 适应度变化曲线

Fig. 9 Fitness variation curve


从图 9 中可以看出,0~9 代时 GA 处于全局搜索阶段,适应度值长期保持稳定。当遗传代数达到 9 代时模型的适应度值大幅减小,适应度曲线趋于稳定。训练集和测试集的真实值与修正值的对比如图 10 所示。

探针总压测量的真实值与修正值的波动高度

训练集和测试集的回归如图 11 所示,数据点



(a) 训练集结果对比 (均方根误差为0.342 140)



(b) 测试集结果对比 (均方根误差为0.338 540)

图 10 真实值与修正值结果对比

Fig. 10 Comparison of true values and corrected values results



(a) 训练集 ($R=0.999\ 97$)(b) 测试集 ($R=0.999\ 9$)


图 11 训练集和测试集回归图

Fig. 11 Training and test set regression plots


基本聚集在拟合线周围,且拟合线与理想的 $Y=X$ 参考线高度重合,两者的决定系数 R^2 均达到 0.99,说明真实值与修正值的关联度很高,模型对数据的预测能力较强。

为了多维度验证模型性能,将训练集和测试集每个样本的相对误差变化绘制如图 12 所示,训练集的相对误差均低于 0.008,大部分的数据样本相对误差在 0.002 以下,测试集的大部分样本相对误差低于 0.003,在 140 号样本处出现误差最大值,达到了 0.011 8,平均相对误差略大于训练集样本数据。

全体样本的误差分布如图 13 所示,大部分数据的修正误差主要集中在 $-0.5 \sim 0.5$ 之间,并且在 0 误差附近的样本频数极高,说明绝大多数的样本修正误差是紧密围绕着 0 误差进行波动。训练集的误差分布呈现出以 0 为中心,高度相对集中



(a) 训练集相对误差随样本序号的变化



(b) 测试集相对误差随样本序号的变化

图 12 训练集和测试集相对误差变化

Fig. 12 Training and test sets relative error change




图 13 全体样本误差分布柱状图

Fig. 13 All samples error distribution histogram

的特点,在 $-0.1 \sim 0$ 误差区间内的样本占比是最高的,最高相对误差与最低相对误差相差 0.787%,其均值达到了 -0.01 ;测试集的大部分数据误差分布也相对集中在 $-0.5 \sim 0.5$ 误差区间内,最高相对误差与最低相对误差相差 1.163%,均值达到了 -0.02 ,样本误差占比最大的区间位于 $0 \sim 0.1$ 的误差区域内;从极端误差来看,GA-BP 神经网络在 -2 和 -1.5 等极端误差附近的样本频数几乎为 0,这也进一步说明了探针测量误差修正模型的高精度修正能力和泛化性能。

模型有 3 种评价指标:方均根误差、决定系数、平均绝对误差和平均相对误差,如下所示。

1) 方均根误差(root mean square error, RMSE):修正值与真实值偏差平方和的算术平均数的平方根,衡量误差的绝对大小。

$$e_{\text{rms}} = \sqrt{\frac{1}{u} \sum_{i=1}^u (y_i - y_i^*)^2} \quad (13)$$

2) 决定系数(coefficient of determination, R^2): 用于评价模型的拟合优度。

$$R^2 = 1 - \frac{\sum_i (y_i - y_i^*)^2}{\sum_i (y_i - \bar{y})^2}$$

(14)

3) 平均绝对误差(mean absolute error, MAE): 直观反映修正值与真实值的平均绝对偏差。

$$e_{\text{ma}} = \frac{1}{m} \sum_{i=1}^m |y_i - y_i^*|$$

(15)

4) 平均相对误差(mean relative error, MRE): 修正值与真实值的相对偏差的算术平均数, 衡量误差的相对比例。

$$e_{\text{mr}} = \frac{1}{m} \sum_{i=1}^m \left| \frac{y_i - y_i^*}{y_i} \right|$$

(16)

式中 e_{rms} 为方均根误差; R^2 为决定系数值; e_{ma} 为平均绝对误差; e_{mr} 为平均相对误差; y_i^* 为样本真实输出值; y_i 为模型修正输出值; $\bar{y}$ 为样本输出值的平均数; m 为训练数据个数。

为了验证 GA 对 BP 神经网络的优化效能, 从上述 4 种评价指标出发对这两种模型进行对比分析, 如表 6 所示, 从结果可以看出 GA 将标准 BP 神经网络的方均根误差减小了 50%, GA 通过全局搜索优化初始权重和偏置, 显著降低了修正值和真实值的离散程度; GA-BP 的决定系数较 BP 模型更加接近 1, 反映了其对数据拟合优度的提升; 从平均绝对误差和平均相对误差来看, GA-BP 的训练集和测试集均比 BP 模型减小了 72% 左右, 这进一步验证了 GA 对 BP 模型训练精度的提升。

表 6 模型评价
Table 6 Model evaluation

评价指标	BP		GA-BP	
	训练集	测试集	训练集	测试集
e_{rms}	0.702 42	1.016 2	0.342 14	0.338 54
R^2	0.998 51	0.996 9	0.999 86	0.999 69
e_{ma}	0.484 48	0.728 81	0.125 07	0.200 89
e_{mr}	0.003 8	0.005 8	0.001 0	0.001 6

5 结 论

本文构建了 GA-BP 神经网络的探针总压测量误差修正模型, 主要结论如下:

1) GA-BP 模型回归分析中的数据点基本都聚集在拟合线周围, 且训练集和测试集的决定系数均达到 0.99, 对数据的拟合优度更好, 在全体样本误差分布图中误差均围绕 0 均值对称分布。

2) 通过 GA-BP 神经网络, 有效解决了 BP 神经网络易陷入局部最优和训练不稳定的缺陷, 测试集的 e_{rms} 降至 0.338 54, 较标准 BP 模型下降了 66.69%, 测试集的 e_{mr} 降至 0.001 6, 降幅达 72.41%。

参考文献:

[1] 姚艳玲, 代军, 黄春峰. 现代航空发动机温度测试技术发展综述[J]. 航空制造技术, 2015, 58(12): 103-107.
Yao Yanling, Dai Jun, Huang Chunfeng. Development for temperature measurement technology in modern aeroengine[J]. Aeronautical Manufacturing Technology, 2015, 58(12): 103-107. (in Chinese)

[2] 单晓明, 高倩, 魏秀利. 航空发动机试验与测试技术发展分析[J]. 航空动力, 2022(3): 67-70.
Shan Xiaoming, Gao Qian, Wei Xiuli. Test and measurement technology for aero engines[J]. Aerospace Power, 2022(3): 67-70. (in Chinese)

[3] 吴志珺, 王毅, 赵俭, 等. 航空发动机试验用气动探针的动力学分析研究[J]. 装备制造技术, 2022(5): 80-84.
Wu Zhijun, Wang Yi, Zhao Jian, et al. Dynamic analysis of pneumatic probes for aeroengine testing[J]. Equipment Manufacturing Technology, 2022(5): 80-84. (in Chinese)

[4] 刘绪鹏, 闫久坤, 王英锋. 叶型探针级间堵塞对压气机性能的影响[J]. 航空发动机, 2015, 41(3): 86-92.
Liu Xupeng, Yan Jiukun, Wang Yingfeng. Blockage effect of inter-stage blade shaped gauge on compressor performance[J]. Aero-engine, 2015, 41(3): 86-92. (in Chinese)

[5] 马宏伟, 蒋浩康. 速度梯度、近壁效应和 Re 数对压力探针测量误差的影响[J]. 航空动力学报, 1995, 10(4): 337-342.
Ma Hongwei, Jiang Haokang. Effect of velocity gradient, near-wall effect and Re number on measurement error of pressure probe[J]. Journal of Aerospace Power, 1995, 10(4): 337-342. (in Chinese)

[6] Vukoslavcevic P V, Petrovic D V. Influence of hot-wire probe configuration on the results of 3-D fluid velocity field measurements [C]//International Symposium on Turbulence. Podgorica: Ministry of Science and Education of Montenegro, 1997: 189-198.

[7] Vukoslavcevic P V, Wallace J M. The influence of the arrangements of multi-sensor probe arrays on the accuracy of simultaneously measured velocity and velocity gradient-based statistics in turbulent shear flows[J]. Experiments in Fluids, 2013, 54(6): 1537.

[8] 王洪伟, 方剑, 王治. 速度梯度对圆柱探针测量的影响及修正[J]. 航空动力学报, 2008, 23(4): 712-717.
Wang Hongwei, Fang Jian, Wang Zhi. Error correction for cylinder probes measuring the flow with velocity gradient[J]. Journal of Aerospace Power, 2008, 23(4): 712-717. (in Chinese)

[9] Guo Xipeng, Yin Shaohui, Shu Chengsong, et al. Contact on-machine measurement probe error correction method for optical aspheric surface ultraprecision machining[J]. Measurement, 2023, 214: 112731.

[10] 王洪伟, 陈小龙. 五孔探针的神经网络处理方法[J]. 航空动力学报, 2010, 25(2): 417-423.
Wang Hongwei, Chen Xiaolong. Five-hole probe and its neural

- network algorithm[J]. Journal of Aerospace Power, 2010, 25(2): 417-423. (in Chinese)
- [11] 吴晓东, 王迎国, 刘志刚, 等. 一种新的三孔探针试验数据处理方法[J]. 燃气涡轮试验与研究, 2019, 32(6): 54-60.
Wu Xiaodong, Wang Yingguo, Liu Zhigang, et al. A new data processing method for three-hole probe[J]. Gas Turbine Experiment and Research, 2019, 32(6): 54-60. (in Chinese)
- [12] 仇宝云, 黄季艳, 袁寿其. 探针杆挠曲水流场测量误差修正方法及其收敛性[J]. 水动力学研究与进展 A 辑, 2003, 18(1): 47-51.
Qiu Baoyun, Huang Jiyun, Yuan Shouqi. Correcting method and its convergence of water flow field measurement errors of a probe because of its rod bending[J]. Journal of Hydrodynamics, 2003, 18(1): 47-51. (in Chinese)
- [13] 谢金伟, 郭涛, 张京, 等. 大梯度低速流场中五孔探针测量误差修正方法研究[J]. 实验流体力学, 2025, 39(5): 11-18.
Xie Jinwei, Guo Tao, Zhang Jing, et al. Study on correction method for measurement error of five-hole probe in large gradient low-speed flow field[J]. Journal of Experiments in Fluid Mechanics, 2025, 39(5): 11-18. (in Chinese)
- [14] Su Cheng, Liang Jingwei, He Zengsheng. E-PINN: a fast physics-informed neural network based on explicit time-domain method for dynamic response prediction of nonlinear structures[J]. Engineering Structures, 2024, 321: 118900.
- [15] Li Chunguang, Liao Xiaofeng, Wu Zhongfu, et al. A multilayer complex neural network training algorithm and its application in adaptive equalization[J]. Journal of Electronics (China), 2001, 18(4): 321-329.
- [16] Herrmann L, Sigmund O, Li V M, et al. On neural networks for generating better local optima in topology optimization[J]. Structural and Multidisciplinary Optimization, 2024, 67(11): 192.
- [17] 张丽娜, 杨春信, 王安良. 应用遗传算法优化设计板翅式换热器[J]. 航空动力学报, 2004, 19(4): 530-535.
Zhang Lina, Yang Chunxin, Wang Anliang. Optimum design of plate-fin heat exchanger with genetic algorithm[J]. Journal of Aerospace Power, 2004, 19(4): 530-535. (in Chinese)
- [18] 辛建池, 吴化银, 陆华伟, 等. 基于七孔探针环形校准与神经网络插值方法的研究[J]. 工程热物理学报, 2025, 46(1): 127-137.
Xin Jianchi, Wu Huayin, Lu Huawei, et al. A research based on a scheme of ring calibration of seven-hole probe and an interpolant method using neural network[J]. Journal of Engineering Thermophysics, 2025, 46(1): 127-137. (in Chinese)
- [19] Xia Zhenxing, Dai Wei, Liu Xin, et al. Data-specific activation function learning for constructive neural networks[J]. Neurocomputing, 2025, 617: 129020.
- [20] Rosa P P, Sriwindono H, Nugroho R A, et al. Comparison of crossover and mutation operators to solve teachers placement problem by using genetic algorithm[J]. Journal of Physics: Conference Series, 2020, 1566(1): 012021.

(编辑: 陈 越)