

基于RBF神经网络的飞机油量计算方法

罗云鹤, 赵 铮

(中航贵州飞机有限责任公司, 贵州安顺, 561000)

摘要 针对目前飞机燃油测量采用的查表插值油量计算方法效率低, 以及神经网络应用于飞机油箱油量计算存在的精度不高、容错性不好等问题, 开展了基于径向基函数(RBF)神经网络的飞机油量计算方法研究。通过改善油箱体积特性数据库的离散分布优化训练样本质量, 改进神经网络训练算法提高对输入数据误差容错性, 采用遗传算法优化神经网络设计参数, 有效提升了RBF神经网络在油量计算中的泛化能力和训练效率。经某型飞机燃油箱计算实例和地面试验验证表明, 油箱模型数据离散方法能更为准确描述油箱体积特性, 与等距切割方法相比测试样本插值计算均方根误差下降34.8%。构建的RBF神经网络具有较好的计算精度, 计算效率较插值计算方法提升了约5倍。改进算法与正交最小二乘法(OLS)算法相比, 当输入参数存在误差时测试样本预估均方根误差下降61.5%, 容错性明显提升, 具有工程实用价值。

关键词 飞机燃油测量; 油量计算方法; RBF神经网络; 油箱体积特性

DOI 10.3969/j.issn.2097-1915.2025.02.004

中图分类号 V241 **文献标志码** A **文章编号** 2097-1915(2025)02-0026-08

Research on the Algorithm of Aircraft Fuel Quantity Based on RBF Neural Network

LUO Yunhe, ZHAO Zheng

(Guizhou Aircraft Corporation Ltd., AVIC, Anshun 561000, Guizhou, China)

Abstract In view of the problems that the look-up table interpolation method used in aircraft fuel measurement is low in efficiency, low in accuracy, and is not good at the fault tolerance of the neural network applied to the calculation of aircraft fuel quantity, the fuel quantity algorithm based on RBF neural network is studied. By enhancing the discrete distribution of the fuel tank volume characteristic database to optimize the training samples, refining the neural network training algorithm to improve the fault tolerance for the input data, and employing genetic algorithm to optimize design parameters of the neural network, generalization capability and training efficiency of the RBF neural network in the fuel quantity calculation are effectively improved. According to the calculation example of an aircraft fuel tank and corresponding ground tests, the data dispersed method of tank models in this paper can further accurately describe their volume characteristic, with a 34.8% reduction in RMSE of interpolation calculation compared to the equidistant cutting method. The developed RBF neural network is good at the calculation accuracy, improving efficiency compared with the interpolation calculation method being about 5 times; Compared with the OLS algorithm, the improved algorithm has a 61.5% reduction in the estimated RMSE of test samples when the input parameters have errors, and the fault tolerance is significantly improved; The pro-

收稿日期: 2024-07-17

作者简介: 罗云鹤(1972-), 男, 江西新余人, 研究员, 研究方向为飞机机电系统设计。E-mail: 1319289140@qq.com

引用格式: 罗云鹤, 赵铮. 基于RBF神经网络的飞机油量计算方法[J]. 空军工程大学学报, 2025, 26(2): 26-33. LUO Yunhe, ZHAO Zheng. Research on the Algorithm of Aircraft Fuel Quantity Based on RBF Neural Network[J]. Journal of Air Force Engineering University, 2025, 26(2): 26-33.

posed method has a certain of practical value in engineering.

Key words aircraft fuel measurement; fuel quantity algorithm; RBF neural network; fuel tank volume characteristic

飞机燃油量是关系飞机续航能力,确保飞行安全的重要参数。高精度油量测量是燃油系统智能化管理的基础,提高油量测量精度可以使飞行人员在安全范围内更为有效地使用燃油,对于战斗机而言可以增加飞机航程、作战半径和有效载荷,对于民用飞机而言提高燃油测量精度可以显著提升运营经济性^[1]。

目前燃油量测量主要通过安装在油箱内的传感器测量液面高度,通过高度-体积关系曲线查表计算油箱内剩余油量。在飞行姿态改变时液面也会相对于油箱发生变化,为修正姿态误差对油量测量的影响,飞机油量测量还需确定液面与油箱夹角,一般用油面角来表示^[2]。可以通过多根液位传感器同时确定液面高度和液面油面角,实现燃油量测量^[3-4],但是需要在全部测量范围内,始终有不同位置的 3 根传感器处于有效测量区间内^[5],考虑飞机各种俯仰和横滚姿态下油箱底部和顶部可测量要求的约束,油箱内需布置远大于 3 根的传感器。文献[5]表明为实现俯仰和横滚姿态 $\pm 30^\circ$ 的测量,一个 200 L 的矩形油箱需要 10 根传感器,成本和系统复杂程度都将明显增加。油量传感器测量液面高度并结合飞机油面角信息进行修正,可以简化系统设计,降低传感器安装数量。在实际使用中,油箱油量是飞行姿态与液位高度的多元非线性函数,一般难以找到精确解析式,目前一般是通过建立纵向油面角-横向油面角-传感器测量高度-燃油体积特性数据库查表插值实时计算油箱油量^[6-7]。为保证油量计算精度,通常在油箱体积特性数据库中设置大量样本点,对测量值采用多维查表插值计算效率低;当飞机油箱数量多、测量采样率高时,油量计算对机载设备提出了较高要求^[8]。已有学者开始尝试使用误差反向传播(back propagation, BP)神经网络建立测量参数与燃油量的映射关系。BP 神经网络理论上可以逼近有界区域上的任意连续函数,但应用于油量计算却反映出网络泛化能力不强、计算误差较大的问题。文献[9]对网络优化后预测误差可以控制在 10% 以下,文献[10]为提高计算精度,在油箱中间区域使用 BP 神经网络建模计算,在油箱底部和顶部区域仍需采用插值算法。

本文拟通过对油箱体积特性数据库和神经网络训练方法优化研究,提高计算精度,提升神经网络的泛化能力,建立基于径向基函数(radial basis function, RBF)神经网络的燃油测量油量计算方法,替代查表插值计算方法,提高计算效率,并通过计算实

例和试验验证方法的可行性和适用性。

1 基于神经网络的燃油量计算方法

油箱体积特性本质上是油箱燃油量与传感器测量高度、纵向油面角和横向油面角之间的非线性映射关系,这种映射关系一般难以建立多元非线性函数直接描述,通常是在建立油箱体积特性数据库后,根据测量数据查表插值方法计算油箱燃油量,但该类插值至少也需要油面高度、纵向油面角、横向油面角 3 个参数,当数据库容量较大时多维插值计算效率低,且数据库需存储于机载设备中随时进行调用^[11]。

采用神经网络描述此类非线性映射关系是一个较好的解决方案,理论上任意连续非线性函数都可用前向神经网络逼近^[12]。神经网络通过对样本的学习,构造出油箱燃油量与传感器测量高度、油面角之间的多元函数关系,在样本点处逼近样本值,在非样本点处具有预估能力。完成训练的神经网络可以直接应用于燃油量计算,不再需要对油箱体积数据库读取和计算,对每个测量值按照神经网络构建关系计算即可,实时计算量大幅下降。

目前在函数逼近上应用最多的神经网络是 BP 网络、RBF 神经网络等,两种网络均为多层前向神经网络,其中 RBF 神经网络具有非线性映射能力强、泛化性能好、学习速度快等优点^[13],因此本文采用 RBF 神经网络用于燃油测量油量计算。

RBF 神经网络是以径向基函数作为隐含层神经元激励的三层前向型网络,本文采用的激活函数为 Gaussian 函数。通过对油箱体积特性数据库中样本学习训练,可以建立油箱燃油量与传感器测量高度、油面角之间的非线性映射关系。

神经网络的泛化能力是其最主要的性能,指训练后的神经网络对测试样本或工作样本的正确反应能力,以及对噪声干扰的容错性能^[14-15]。神经网络的泛化性能主要受训练样本质量、网络架构和网络设计参数的影响,为此本文拟优化油箱体积特性数据库的离散分布以改善训练样本质量,并通过改进神经网络训练算法和优化神经网络设计参数进一步提升神经网络的泛化性能。

2 油箱体积特性数据库优化

在不考虑油箱油面波动、流体喷溅等因素影响,

油箱内燃油体积由其油平面决定,包括了油箱油面位置高度和油平面与机体坐标轴夹角两个因素。油面位置高度可以通过油量传感器测量得到,飞机在地面静止状态下,油平面法向矢量与燃油所受重力方向相同。

在飞机飞行过程中,燃油受力情况发生变化,油箱油平面也发生偏转。根据单位质量流体平衡微分方程:

$$\begin{cases} X_g - \frac{1}{\rho} \frac{\partial P}{\partial x_g} = 0 \\ Y_g - \frac{1}{\rho} \frac{\partial P}{\partial y_g} = 0 \\ Z_g - \frac{1}{\rho} \frac{\partial P}{\partial z_g} = 0 \end{cases} \quad (1)$$

式中: X_g 、 Y_g 、 Z_g 为燃油所受质量力在飞机牵连铅锤坐标系 x_g 、 y_g 、 z_g 方向上的分量; P 为燃油所受压强; ρ 为燃油密度。

可以推出等压面方程为:

$$X_g dx_g + Y_g dy_g + Z_g dz_g = 0 \quad (2)$$

因此,由等压面方程可知油箱油平面与燃油所受质量力方向垂直,可以通过受力分析确定油平面法向矢量方向。

另外,飞机姿态改变使得机体坐标系相对于飞机牵连铅锤坐标系发生转动,也会导致油平面法向矢量相对于机体坐标轴发生转动。油面角包括纵向油面角和横向油面角,综合反映了燃油受力情况变化和飞机姿态改变对油平面相对于机体坐标系位置的影响,由俯仰角、横滚角、纵向加速度、横向加速度和法向加速度所确定,可以通过飞参数据计算得到。

设纵向油面角为 α , 横向油面角为 β , 此时油平面法向矢量 n' 与飞机水平静止状态油平面法向矢量 n 之间关系为:

$$\begin{bmatrix} n'_x \\ n'_y \\ n'_z \end{bmatrix} = \begin{bmatrix} \cos \alpha & \sin \alpha \sin \beta & \sin \alpha \cos \beta \\ 0 & \cos \beta & -\sin \beta \\ -\sin \alpha & \cos \alpha \sin \beta & \cos \alpha \cos \beta \end{bmatrix} \begin{bmatrix} n_x \\ n_y \\ n_z \end{bmatrix} \quad (3)$$

根据油平面法向矢量及传感器测量高度,就可以完全确定油平面位置,利用该油平面对油箱实体模型进行切割,可实现用离散数据表示油箱体积特性^[16-17]。目前很多三维 CAD 软件的质量特性计算功能可以方便实现截面切割实体的体积计算,本文通过 CATIA 软件二次开发,采用 CATIA V5 Automation 实现油箱切割及体积计算。

以某型飞机燃油箱为例进行研究,其油箱为马鞍形,油箱模型及油量传感器布置见图 1,在油箱内安装了 2 根油量传感器以满足各飞行姿态下可测油量范围的要求。




图 1 油箱模型及传感器布置

Fig. 1 Tank model and sensor arrangement

当飞行姿态发生改变,燃油量-油量传感器测量高度关系曲线也会发生变化。图 2 给出了 5 种状态下燃油量与油量传感器 S1 和 S2 测量高度关系曲线,图 3 给出了油箱油量 5%、50%、95% 条件下,5 种横向油面角状态下的传感器测量高度与纵向油面角之间的关系曲线。从图 2 和图 3 可以看出,油箱燃油量随传感器测量高度、纵向油面角、横向油面角变化关系中均存在折点和导数不连续,折点位于油箱顶部和底部测量区域内。

造成折点的原因是在油箱底部或顶部区域,存在一根传感器完全露出或完全浸没,此时该传感器已超出其测量范围,不能感知油面变化;当油面变化至该传感器有效测量范围,开始重新感知油面升降情况,因此燃油量与部分传感器测量高度之间关系会存在折点。






图 2 燃油量-传感器测量高度曲线

Fig. 2 Fuel quantity-sensor measurement height curves



(a) 5% 油箱燃油量状态



(b) 50% 油箱燃油量状态

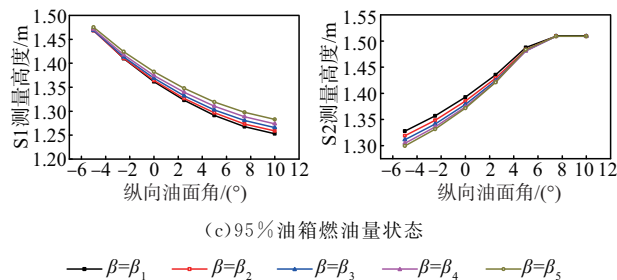


图 3 传感器测量高度-纵向油面角曲线

Fig. 3 Sensor measurement height-longitudinal oil surface angle curves

在不同油面角状态下,对应于该传感器完全露出或完全浸没时的燃油量不同,因此当油面角变化时,也会使部分传感器存在无效测量向有效测量之间转换,就造成了燃油量-测量高度-油面角之间关系中折点的存在。

目前一般采用等距平面切割油箱模型来建立油箱体积特性数据库。这种方法并不适用于全部油量范围,为准确描述油箱体积特性,切割面应靠近折点位置,在非线性特性区域切割面间距应尽量小,而在线性特性区域,较大的间距即可满足精度要求。因此,本文对切割面离散进行了优化,具体方法如下:

1)根据油量测量系统工作包线,按纵向油面角和横向油面角离散工作剖面。在工作剖面下,按固定步长逐次切割油箱模型,计算燃油量-传感器测量高度关系曲线。

2)用插入点法逐次检查各切割面,即在原切割面间插入切割面,插入后应满足式(2)的要求,否则取消插入,完成各工作剖面的切割面检查。

$$\left| \frac{V_n - V_{n-1}}{S_n - S_{n-1}} - \frac{V'_n - V_{n-1}}{S'_n - S_{n-1}} \right| \geq A \quad (4)$$


式中: V_n 为 n 点切割体积; V'_n 为 n 点插入面切割体积; S 由传感器 S1 和 S2 测量高度线性表示; S_n 为 n 点处 S 值; S'_n 为 n 点插入面处 S 值; A 为控制阈值。

3)完成各工作剖面油箱体积特性计算,检查纵向油面角、横向油面角相邻剖面传感器无效工作区域对应的燃油量,如燃油量差值超过设定阈值,则插入剖面,在插入剖面上补充燃油量差值区域的油箱体积特性数据。

通过以上处理,可以使离散点逐渐接近折点位置,在非线性区域分布的离散点密度较大。在离散点数相同条件下采用等距切割和按本文优化的油箱底部、顶部某状态油箱体积特性曲线对比见图 4,可以看出优化后传感器测量过渡区曲线折点位置更为准确。

对于规则形状油箱,在一定油面角状态下不同

油面高度的油箱剖面面积会存在明显差异,因此油箱油量值与传感器测量高度之间也呈非线性关系,且随着油面高度变化油量传感器也存在无效测量区间与有效测量区间的转换,使油量特性曲线中也会存在折点及导数不连续现象。



(a) 油箱底部 S1、S2 体积特性曲线 (b) 油箱顶部 S1、S2 体积特性曲线

图 4 油箱体积特性对比

Fig. 4 Comparison of the fuel tank volume characteristic

3 神经网络泛化能力优化

在训练样本确定的条件下,隐含层节点数量、数据中心和扩展常数是影响 RBF 神经网络泛化性能的关键参数^[18-20]。

3.1 学习算法改进

确定隐含层结构一直被认为是 RBF 神经网络构建的关键和难点,目前 RBF 神经网络常用学习算法有聚类法、梯度训练法和正交最小二乘法(orthogonal least square, OLS)。其中 OLS 算法能够自动调整网络结构,与随机选择数据中心相比,可以避免数值病态并获得一个规模更小的 RBF 神经网络^[21]。

网络输出 \hat{Y} 表示为:

$$\hat{Y} = \hat{H}W \quad (5)$$

第 l 个网络输出的第 m 项 $y_{l,m}$ 可表示为:

$$y_{l,m} = \sum w_{i,m} e^{-\frac{\|x_l - c_i\|^2}{\delta^2}} \quad (6)$$

式中: \hat{H} 为隐含层输出矩阵; W 为权值矩阵; c_i 为隐含层数据中心; δ 为数据中心的扩展常数; $\| \cdot \|$ 为欧式范数; $w_{i,m}$ 为隐含层到输出层的连接权值; x_l 为训练样本。

RBF 神经网络可以看作一个带权重径向基函数组成的多项式,各径向基函数通过对输入数据选择性缩放来控制该数据在局部产生响应,缩放的依据就是中心点位置和扩展常数,中心点位置决定了输入数据至径向基函数中心的距离,表示了输入数据偏离中心的情况;扩展常数决定了径向基函数的宽度,影响函数对数据的缩放程度。

OLS 算法是按照能量贡献直接选取部分训练

样本作为数据中心点,隐含层各神经元使用通用扩展常数,通过逐次增加中心点数量达到训练精度。OLS算法在训练样本中根据规则选取数据中心,只能保证选取其作为数据中心较其他样本更合理,但不能保证其在某类数据中具有较优位置;而通用的扩展常数难以使不同分布情况的径向基函数均达到较优的缩放响应效果。这些都会影响神经网络的泛化性能,尤其当测量数据存在误差,训练样本不能完全覆盖输入数据,此时部分径向基函数可能会产生不合理响应,造成输出值误差偏大。

为此,本文以 OLS 算法数据中心计算聚类,并以类域中心替代原数据中心,即:

$$\mathbf{c}'_i = \frac{1}{N_i} \sum_{x_l \in \Omega_i} \mathbf{x}_l, i = 1, 2, \dots, h \quad (7)$$

式中: N_i 为第 i 个类域 Ω_i 包含样本数; \mathbf{c}'_i 为类域中心,即修正后的数据中心。

计算类域中心之间距离,对于类域中心距离小于阈值的类域进行合并,避免出现由于类域中心距离过小,造成样本数据缩放的不稳定。通过类域中心距离来确定数据中心的扩展常数:

$$\delta_i = k \min \|\mathbf{c}'_i - \mathbf{c}'_j\|, j = 1, 2, \dots, h, j \neq i \quad (8)$$

式中: δ_i 为第 i 个数据中心的扩展常数; k 为重叠系数。完成数据中心和扩展常数修正后,用最小二乘法计算网络输出权值:

$$\mathbf{W} = \hat{\mathbf{H}}^+ \mathbf{Y} \quad (9)$$

式中: $\hat{\mathbf{H}}^+$ 为隐含层输出矩阵 $\hat{\mathbf{H}}$ 的伪逆矩阵; \mathbf{Y} 为训练样本输出。采用上述算法在相同学习规则下,产生的网络结构完全相同,不会出现由于初值不同生成不同结构参数网络的问题。

3.2 神经网络参数优化

在 3.1 中明确了数据中心和扩展常数的修正方法。此外,网络规模即隐含层神经元数量、影响扩展常数值的重叠系数 k 也是与该神经网络泛化能力直接相关的重要参数。

OLS 算法通过训练误差 σ_1 来控制网络规模,因此训练误差 σ_1 可选作优化变量;对不同的训练样本集存在最优的 k 值,可以优化神经网络的分类精度,因此重叠系数 k 也选作优化变量。

神经网络的泛化能力可以用其预估误差来表示,采用留出验证法,将样本集划分为训练集、验证集和测试集,因此神经网络参数优化数学模型可以表示为:

$$\begin{cases} \min: f(s) = \sigma_2 \\ \mathbf{s} = [\sigma_1, k]^T \end{cases} \quad (10)$$

式中: σ_2 为验证集样本的预估误差。

以上优化问题可通过浮点数编码的遗传算法进行求解,采用线性交叉、均匀变异和最优选择策略,并在群体中剔除重复个体,加速收敛。

3.3 数据预处理

由于样本特征的来源和度量单位不同,使得样本特征尺度之间通常存在量级差异,样本特征尺度的差异会增加神经网络训练难度,网络对某些特征过度敏感。因此需要对样本输入、输出数据进行归一化处理。

本文采用最小最大值归一化处理方法,将每一特征的取值范围归一到 $[0, 1]$ 范围内。

对样本输入、输出数据归一化处理可提高神经网络训练效率,同时也可改善其泛化性能^[22-23]。

3.4 神经网络训练流程

根据前述分析及讨论,RBF 神经网络用于飞机油箱油量计算时的训练流程见图 5,训练满足要求后神经网络可以应用于测试样本或工作样本的计算。

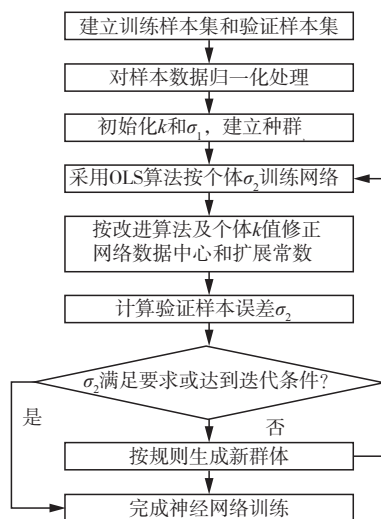


图 5 神经网络训练流程

Fig. 5 Neural network training flow diagram

4 计算实例

以某型飞机燃油箱为例,其油箱外形及油量传感器布置情况见图 1。按第 2 节所述方法建立油箱体积特性数据库,共 3 736 个训练样本,另外建立与训练样本不同的 100 个验证样本和 100 个测试样本,对样本数据进行归一化处理。

为检查训练样本质量,另外对该油箱模型等距切割产生 3 764 个样本。依据本文优化方法产生的 3 736 个样本和等距切割产生的 3 764 个样本,对

100 个测试样本分别进行插值计算,计算结果见图 6。2 次计算最大偏差分别为 0.5% 和 0.78%,均方根误差分别为 0.15% 和 0.23%。本文优化方法与等距切割方法相比,测试样本插值计算最大偏差下降 35.9%、均方根误差下降 34.8%,说明本文优化方法产生的样本分布更为合理,在样本数量基本一致情况下,较等距切割可以提高插值计算精度。




图 6 2 种插值计算结果对比

Fig. 6 Comparison of the two interpolation calculation results

使用本文方法建立的训练样本,通过改进算法和 OLS 算法分别对 RBF 神经网络进行训练,训练完成后测试样本计算结果见图 7。其中 OLS 算法计算最大偏差为 0.42%,均方根误差为 0.12%;改进算法计算最大偏差为 0.40%,均方根误差为 0.10%。OLS 算法和改进算法均有较好的计算精度,略优于插值算法。但 OLS 算法需多次优化选取神经网络参数才能得到较好的预估精度,而改进算法通过遗传算法优化确定神经网络参数,训练效率显著提高。

OLS 算法和改进算法对测试样本计算时间较插值计算明显缩短,仅为插值计算的 19.7%。




图 7 测试样本计算结果

Fig. 7 Calculation results of test samples

在实际使用中测量参数会存在误差,计算模型应对该类误差具有较好的抗干扰能力。为验证计算模型容错性,对 100 个测试样本在纵向油面角和横向油面角参数中注入 $[-1\%, 1\%]$ 范围内随机噪声信号,在 S1 和 S2 传感器测量高度参数中注入 $[-1.5\%, 1.5\%]$ 范围内随机噪声信号,测试数据注入误差分布见图 8。




图 8 测试样本误差分布情况

Fig. 8 Error distribution of test samples

采用 OLS 算法、改进算法和插值算法分别对 100 个带误差的测试样本进行计算,结果见图 9。OLS 算法计算最大偏差为 6.45%,均方根误差为 1.79%;改进算法计算最大偏差为 1.70%,均方根误差为 0.69%;插值算法计算最大偏差为 1.84%,均方根误差为 0.78%。OLS 算法和改进算法对测试样本计算时间为插值计算的 19.1%。

计算结果表明,改进算法与 OLS 算法相比,当输入参数存在误差时测试样本预估最大偏差下降 73.6%、均方根误差下降 61.5%。OLS 算法对输入信号误差敏感,部分测试样本的计算误差增加过大,其主要原因是由于网络数据中心和扩展常数设置不合理,部分径向基函数对一些加入误差的输入信号缩放不准确;改进算法具有较好的容错性,抗噪声干扰能力强。




图 9 带误差的测试样本计算结果

Fig. 9 Calculation results of test samples with error

开展地面试验对改进算法进行验证,选取 5 种油面角状态共 20 个试验点。首先将油箱调整至规定角度状态,开始定量放油;放油量达到试验点时记录油量传感器测量值,并采用改进算法计算油箱剩余油量,计算结果与油箱实际剩余油量进行比较,20 个试验点相对误差分布见图 10,最大偏差 0.76%,均方根误差为 0.39%。




图 10 试验点误差分布

Fig. 10 Error distribution of test points

5 结论

本文基于 RBF 神经网络构建了油面角、油量传感器测量高度与油箱燃油量之间非线性映射关系,通过改善训练样本质量、改进训练算法和优化参数提升神经网络泛化能力,并进行了计算实例和油箱地面试验验证,研究结果表明:

1) 本文设计的油箱模型离散切割方法与等距切割方法相比,样本分布更加合理,可更为准确地描述油箱体积特性,提高了插值计算精度。

2) 在相同样本条件下,OLS 算法和改进算法的 RBF 神经网络测试样本预估精度略高于插值算法,对测试样本计算时间则明显少于插值算法,显著提升了计算效率。

3) 改进算法采用留出验证法设定优化目标,建立神经网络参数优化目标方程,通过遗传算法优化求解,与 OLS 算法相比不需反复调整神经网络参数,训练效率显著提升。

4) 当油面角、油量传感器测量高度等参数存在误差时,使用改进算法的 RBF 神经网络进行油量计算容错性明显优于 OLS 算法,OLS 算法对输入参数误差较为敏感。

5) 本文构建的 RBF 神经网络训练方法,在油量计算中具有较好的计算精度、容错性及学习效率,可以替代目前广泛使用的查表插值算法,能够显著提升计算效率,具有工程实用价值。

参考文献

- [1] 杜荣超,苗清杰. 直升机燃油测量技术研究[J]. 工程技术研究,2023,5(4): 96-98.
DU R C, MIAO Q J. Research on Helicopter Fuel Measurement Technology[J]. Engineering Technology Research,2023,5(4): 96-98. (in Chinese)
- [2] 戴浩,李海泉,潘若刚. 飞机动态质量特性分析方法研究与集成化软件工具开发[J]. 飞机设计,2019,39(3): 23-26.

DAI H, LI H Q, PAN R G. Study on the Analysis Methods of Aircraft Dynamical Mass Properties and Integrated Software Development[J]. Aircraft Design, 2019,39(3): 23-26. (in Chinese)

- [3] LI Y F, XU J H. Multi-Sensor Aviation Fuel Quantity Measurement Algorithm Based on SVR [C]//AIP Conference Proceedings, 2ND International Conference on Green Energy and Sustainable Development (GESD 2019). Chongqing: AIP Publishing, 2019: 020060. 1-020060. 5.
- [4] JUDT D, LAWSON C, VANHEERDEN A S J. Rapid Design of Aircraft Fuel Quantity Indication Systems via Multi-Objective Evolutionary Algorithms [J]. Integrated Computer-Aided Engineering, 2021, 28(2): 141-158.
- [5] 谭公礼. 多传感器的飞机油箱燃油测量系统的研究[D]. 南京: 南京航空航天大学, 2015.
TAN G L. Research on Multi-Sensor Fuel Measurement System for Aircraft Fuel Tank [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2015. (in Chinese)
- [6] LEE J, KIM B, YANG J M, et al. Fuel Quantity Estimation of Aircraft Supplementary Tank Using Markov Chain Monte Carlo Method[J]. International Journal of Aeronautical and Space Sciences, 2019, 20(4): 1047-1054.
- [7] 师显强, 樊伟. 飞机燃油测量液位高度解算方法研究[J]. 电子元器件与信息技术, 2018, 2(6): 95-100.
SHI X Q, FAN W. Research on Calculation Method of Aircraft Fuel Measurement Liquid Level Height[J]. Journal of Electronic Components and Information Technology, 2018, 2(6): 95-100. (in Chinese)
- [8] 郭毅博, 李舜尧, 陈艳华, 等. 基于时间序列的飞机燃油测量方法[J]. 航空科学技术, 2022, 33(5): 63-68.
GUO Y B, LI S Y, CHEN Y H, et al. A Fuel Measurement Method Based on Time Series Data[J]. Aeronautical Science & Technology, 2022, 33(5): 63-68. (in Chinese)
- [9] 张广涛. 航空发动机滑油油量测量关键技术的研究[D]. 沈阳: 沈阳航空航天大学, 2013.
ZHANG G T. Research on Key Technology of Measuring Lubricating Oil Quantity of Aero-Engine [D]. Shenyang: Shenyang Aerospace University, 2013. (in Chinese)
- [10] 常伟, 李建军, 李钊, 等. 基于 BP 神经网络的飞机燃油量测量改进算法[J]. 无线电工程, 2016, 46(4): 63-66.
CHANG W, LI J J, LI Z, et al. Improved Calculation

- Method for Aircraft Fuel Quantity Gauge Based on BP Neural Network[J]. Radio Engineering, 2016, 46(4): 63-66. (in Chinese)
- [11] 孙尧,刘繁,宋涵,等. 飞机油量监测技术研究进展[J]. 飞机设计, 2023, 43(6): 64-73, 80.
SUN Y, LIU Y, SONG H, et al. Research Progress of Aircraft Fuel Monitoring Technology[J]. Aircraft Design, 2023, 43(6): 64-73, 80. (in Chinese)
- [12] 邱锡鹏, 飞桨教材编写组. 神经网络与深度学习: 案例与实践[M]. 北京: 机械工业出版社, 2022.
QIU X P, Paddle Textbook Writing Team. Neural Networks and Deep Learning: Case and Practies[M]. Beijing: China Machine Press, 2022. (in Chinese)
- [13] 姚明辉,王兴志,吴启亮,等. 基于 RBF 神经网络的压机叶片面压力场预测研究[J]. 应用数学和力学, 2023, 44(10): 1187-1199.
YAO M H, WANG X Z, WU Q L, et al. RBF Neural Network Based Prediction on Blade Surface Pressure Fields in Compressors[J]. Applied Mathematics and Mechanics, 2023, 44(10): 1187-1199. (in Chinese)
- [14] 刘崇阳,刘勤让. 一种神经网络模型剪枝后泛化能力的验证方法[J]. 计算机工程, 2019, 45(10): 234-238.
LIU C Y, LIU Q R. A Verification Method on Post-Pruning Generalization Ability of Neural Network Model[J]. Computer Engineering, 2019, 45(10): 234-238. (in Chinese)
- [15] 许峻彬,张勇,赵鸿. 机器学习泛化能力在小型数据库上的鲁棒性研究[J]. 新疆师范大学学报(自然科学版), 2021, 40(2): 61-66.
XU J B, ZHANG Y, ZHAO H. Robustness of Machine Learning Models for Small Structured Datasets [J]. Journal of Xinjiang Normal University (Natural Sciences Edition), 2021, 40(2): 61-66. (in Chinese)
- [16] 宋伟,钟若瑛. 基于实体分割的飞机燃油液面位置确定方法[J]. 计算机仿真, 2020, 37(2): 72-77.
SONG W, ZHONG R Y. Determination Method of Aircraft Fuel Level Position Based on Solid Segmentation[J]. Computer Simulation, 2020, 37(2): 72-77. (in Chinese)
- [17] 李群,李丽,张志超. 油量传感器优化布局仿真平台开发[J]. 飞机设计, 2019, 39(3): 43-47, 68.
LI Q, LI L, ZHANG Z C. Development of Oil Sensor Optimization Layout Simulation Platform[J]. Aircraft Design, 2019, 39(3): 43-47, 68. (in Chinese)
- [18] 乔彦平,郭迎清,高红岗. 基于 RBF 神经网络的进气压力控制方法研究[J]. 测控技术, 2024, 43(2): 11-16.
QIAO Y P, GUO Y Q, GAO H G. Intake Pressure Control Method Based on RBF[J]. Measurement & Control Technology, 2024, 43(2): 11-16. (in Chinese)
- [19] 翟莹莹,左丽,张恩德. 基于参数优化的 RBF 神经网络结构设计算法[J]. 东北大学学报(自然科学版), 2020, 41(2): 176-181, 187.
ZHAI Y Y, ZUO L, ZHANG E D. Algorithm for Structure Design of RBF Neural Network Based on Parameter Optimization[J]. Journal of Northeastern University (Natural Science), 2020, 41(2): 176-181, 187. (in Chinese)
- [20] 陈聪,娄高,高洁,等. 基于 ABC-RBF 神经网络的飞机燃油流量监测与故障诊断[J]. 航空发动机, 2022, 48(3): 89-93.
CHEN C, LOU G, GAO J, et al. Aircraft Fuel Flow Prediction and Fault Diagnosis Based on ABC-RBF Neural Network[J]. Aeroengine, 2022, 48(3): 89-93. (in Chinese)
- [21] DONG J, ZHAO Y X, LIU C, et al. Orthogonal Least Squares Based Center Selection for Fault-Tolerant RBF Networks [J]. Neurocomputing, 2019, 339: 217-231.
- [22] 陈君毅,陈磊,蒙昊蓝,等. 基于神经网络的车辆交通协调性评价模型[J]. 同济大学学报(自然科学版), 2021, 49(1): 135-141.
CHEN J Y, CHEN L, MENG H L, et al. Evaluation Model of Vehicle Traffic Coordination Based on Neural Network[J]. Journal of Tongji University (Natural Science), 2021, 49(1): 135-141. (in Chinese)
- [23] 郑燕鹏,王晓娜,侯德鑫,等. 数据预处理对 BP 神经网络拟合铁氧体导热系数的影响[J]. 中国计量大学学报, 2019, 30(1): 19-24.
ZHENG Y P, WANG X N, HOU D X, et al. Effect of Data Preprocessing on Fitting Ferrite Thermal Conductivity by BP Neural Network[J]. Journal of China University of Metrology, 2019, 30(1): 19-24. (in Chinese)

(编辑:陈斐)