## 基于 ReliefF-LMBP 算法的涡轴发动机气路 故障模式识别<sup>\*</sup>

王召广<sup>1</sup>、杨宇飞<sup>1</sup>、闫召洪<sup>2</sup>、鲁峰<sup>2</sup>

(1. 中国航发湖南动力机械研究所,湖南 株洲 412002;2. 南京航空航天大学 能源与动力学院,江苏 南京 210016)

摘 要:针对涡轴发动机气路故障模式识别精度不高的问题,提出了一种基于ReliefF-LMBP故障 特征提取的发动机故障模式识别方法。应用ReliefF算法对发动机传感器参数赋予权值,对传感器参数 特征权重值进行迭代更新和排序,聚集好的特征样本,离散异类样本。根据筛选出的特征子集,利用 LMBP神经网络算法进行发动机故障模式识别。以涡轴发动机为对象进行气路故障诊断验证,结果表明 所提方法能提取特征传感器参数并实现有效的故障模式识别。

关键词:涡轴发动机;气路故障诊断;特征提取;神经网络;ReliefF分析 中图分类号:V235.113 文献标识码:A 文章编号:1001-4055(2021)01-0220-10 DOI: 10.13675/j.cnki.tjjs.200210

### Gas Path Fault Mode Identification of Turboshaft Engine Based on ReliefF-LMBP Algorithm

WANG Zhao-guang<sup>1</sup>, YANG Yu-fei<sup>1</sup>, YAN Zhao-hong<sup>2</sup>, LU Feng<sup>2</sup>

(1. AECC Hunan Aviation Powerplant Research Institute, Zhuzhou 412002, China;

2. College of Energy and Power Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: In order to improve the performance of gas path fault diagnosis for turbo shaft engine, a ReliefF– LMBP based method was proposed to fault feature extraction and pattern recognition. Firstly, the available engine sensor measurements were analyzed and assigned feature weights, and the fault feature subsets were ordered and determined after iterative selection by ReliefF algorithm. The effective feature measured parameters were gathered by similar samples, and the rest parameters fell in the discrete heterogeneous sample subsets. Afterwards, the LMBP Neural Network algorithm was employed to build up the relationship between the fault modes and features of reduced measurements. The tests of gas path fault diagnosis are carried out on a turbo shaft engine, and results show the capability of feature extraction and superiority of fault pattern recognition.

Key words: Turbo shaft engine; Gas path fault diagnosis; Feature extraction; Neural network; ReliefF analysis

1 引 言

涡轴发动机凭借着自身体积小、重量轻、高功

重比等优点,成为现代直升机广泛采用的动力装置。然而,复杂的工况以及恶劣的飞行条件等因 素都会导致发动机性能下降,因此,对涡轴发动机

\* 收稿日期: 2020-04-10;修订日期: 2020-07-16。

基金项目:国家科技重大专项(2017-I-0006-0007)。

 引用格式:王召广,杨宇飞,闫召洪,等.基于ReliefF-LMBP算法的涡轴发动机气路故障模式识别[J].推进技术,2021,42
 (1):220-229. (WANG Zhao-guang, YANG Yu-fei, YAN Zhao-hong, et al. Gas Path Fault Mode Identification of Turboshaft Engine Based on ReliefF-LMBP Algorithm[J]. Journal of Propulsion Technology, 2021, 42(1):220-229.)

通讯作者:王召广,硕士,高工,研究领域为航空发动机总体性能设计。E-mail: cnwangzg@163.com

开展故障诊断技术的研究对于保证发动机性能与 可靠性、降低维护成本而言十分重要<sup>[1]</sup>。由于气 路部件故障在其中所占比重较高,因此实现对气 路部件的故障诊断是发动机健康管理的重要组成 部分<sup>[2-3]</sup>。

目前,航空发动机的气路故障诊断方法主要分 为基于模型和基于数据驱动的方法。基于模型目前 主流的诊断方法是卡尔曼滤波算法,对于测量噪声 具有一定的鲁棒性。但是该方法较依赖发动机数学 模型的精度。而基于数据驱动的发动机健康管理技 术是以其测量数据为依据,在无需建立系统精确数 学模型的情况下,实现对发动机气路故障诊断,随着 相关技术的发展,现已逐渐成为航空发动机故障诊 断的主流解决方案<sup>[4-5]</sup>。同时,例如隐马尔科夫模型、 核极限学习机和深度置信网络等[6-8]一系列典型的智 能算法已被成功地应用于航空发动机故障模式识别 和健康状态预测之中。郭迎清等<sup>[9]</sup>提出了基于GA-AANN 神经网络的 SDQ 算法提高了传感器的阶跃故 障和漂移故障的识别率。缑林峰等100提出了基于 PCA 和支持向量机来诊断发动机的健康退化状态。 航空发动机在实际工作中,其监测的数据包含了噪 声。BP神经网络得益于可以对不完整或存在误差的 信息进行有效的分析,对发动机故障诊断具有良好 的适用性[11]。然而发动机传感器参数众多,选用过 多的参数进行故障模式识别一方面对识别精度造成 影响,同时也不利于保证诊断的实时性。因此,需要 对传感器参数进行降维。

特征选择作为机器学习的一个非常重要的预处 理步骤已得到了广泛应用<sup>[12]</sup>。特征选择主要是从原 始数据中挖掘出那些对对象识别、聚类、分类和回归 最有效的特征<sup>[13]</sup>。其中,由Kira提出的ReliefF算法 是一种解决二分类问题的经典过滤式特征选择算 法。Kononenko在此基础上进一步提出了ReliefF算 法,使其可以解决多类问题和回归问题,得到了广泛 的应用<sup>[14]</sup>。

本文提出了一种基于 ReliefF 算法的传感器组 合选取方法,在涡轴应用条件下,算法的输入为选取 的 8 个传感器参数,通过 ReliefF 算法计算出各个特 征的预测权值,在保证识别精度的同时对复杂的传 感器参数进行降维选取后作为 BP 算法的输入, BP 算法的输出为 11 种气路状态模式,通过 BP 算法进 行气路故障模式的识别,仿真结果验证了该方法的 有效性。

#### 2 气路故障诊断模式及算法说明

#### 2.1 涡轴发动机气路故障模式定义

涡轴发动机单转子燃气发生器带自由涡轮的结构形式如图1所示。图中各部件分别为进气道(Inlet)、压气机(Combined compressor)、燃烧室(Combustor)、燃气涡轮(Gas turbine)、动力涡轮(Power turbine)和尾喷管(Nozzle)。随使用时间的延长,压气 机、燃气涡轮等部件发生磨损、腐蚀或积垢,产生性 能衰减<sup>[15]</sup>。由此产生气路突变故障和渐变退化,且 均可体现在相应部件的效率和流量等健康参数的 变化<sup>[16]</sup>。



Fig. 1 Principle diagram of turbo shaft engine

基于数据驱动的发动机故障模式识别方法主要 根据发动机性能变化导致的传感器参数的变化来定 位故障部件,为后续的维修提供参考。涡轴发动机 的健康参数如表1所示,表中第一列为控制量,分别 为燃油量 W<sub>i</sub>和负载扭矩角α;第二列为健康参数,分 别为部件热力学效率 $\eta$ 和部件流量 $\Gamma$ ;第三列为选取 8个传感器参数作为待选特征,它们分别是动力涡轮 转速 $N_{\rm ex}$ 燃气涡轮转速 $N_{\rm ex}$ 压气机出口温度 $T_{\rm ex}$ 压气 机出口压力 p3、动力涡轮出口温度 T5、动力涡轮出口 压力p5、尾喷管进口温度T6、尾喷管进口压力p6。控 制量为涡轴发动机模型的输入来控制发动机的转 速,从而确定发动机的工作状态与功率水平,健康参 数体现的是涡轴发动机各转子部件的退化情况,用 于表征气路故障模式,通过传感器可测参数解算健 康参数,从而获得涡轴发动机模型在某一工作状态 下的健康状态。

根据故障源和发生程度,将涡轴发动机气路部件故障模式状态分为11种,除去所有部件无故障的模式定义如表2所示。利用涡轴发动机部件级模型, 模拟每种故障模式,分别建立训练和测试样本数据 集,对所研究的算法进行分析。

基于数据驱动的故障模式识别方法需要大量的 样本,而发动机的传感器参数较多,而各个量测参数

Control parameters	Health parameters	Measureable parameters
Fuel flow $W_{\rm f}$	Compressor efficiency $\eta_{ m C}$	Power turbine speed $N_{\rm p}$
Load torque $\alpha$	Compressor flow $\varGamma_{\rm C}$	Gas turbine speed $N_{\rm g}$
	Gas turbine efficiency $\eta_{ m g}$	Compressor outlet temperature $T_{\rm 3}$
	Gas turbine flow $\Gamma_{ m g}$	Compressor outlet pressure $p_3$
	Power turbine efficiency $oldsymbol{\eta}_{ ext{p}}$	Power turbine outlet temperature $T_5$
	Power turbine flow $\Gamma_{ m p}$	Power turbine outlet pressure $p_5$
		Nozzle inlet temperature $T_6$

 Table 1
 Health parameters and measureable parameters of turbo shaft engine

之间会有冗余,但冗余的数据特征会使神经网络结构变得复杂,并且不利于故障模式识别,甚至降低识别精度。文中通过 Relieff 算法进行特征选择,作为数据的预处理剔筛选出对于故障模式识别有利的传感器参数输入到 BP 网络,以提高神经网络算法的识别精度,并降低算法的模型复杂度。

Table 2Gas path failure modes of turbo shaft(%)

Modes	$\pmb{\eta}_{ ext{C}}$	$\Gamma_{\rm c}$	$\eta_{_{ m g}}$	$\Gamma_{\rm g}$	$oldsymbol{\eta}_{ ext{p}}$	$\Gamma_{\rm p}$	Failure source
Ι	-1	-	-	-	-	-	
II	-	-1	-	-	-	-	Compressor
Ш	-0.7	-1	-	-	-	-	
IV	-	-	-1	-	-	-	
V	-	-	-	+1	-	-	Power turbine
VI	-	-	-1	-1	-	-	
VII	_	-	-	-	-1	_	
VIII	-	-	-	-	-	-1-	Q . 11
IX	-	-	-	-	-0.4	-1	Gas turbine
Х	-	-	-	_	-0.6	+1	

#### 2.2 LMBP网络

BP 网络是一个单隐含层前馈神经网络(SLFN, Single hidden layer feed forward neural network),它由 输入层、隐含层和输出层组成,其中输入、输出层神 经元节点数分别对应于输入数据和输出数据的维 度。假设一个 SLFN 的输入节点数为*n*,隐含层节点 数 为 *L*,输出节点数为*m*,训练数据集为 $\pi = \{(x_i, t_i) | x_i \in \mathbb{R}^n, t_i \in \mathbb{R}^m, i = 1, 2, ..., N\}$ , SLFN 通过激 活函数来描述输入-输出的非线性映射关系,其拓扑 结构示意图如图 2 所示。

若令 SLFN 的隐含层激活函数为 g(x),则其输出 可以表示为

$$f(\boldsymbol{x}) = \sum_{j=1}^{L} g(\boldsymbol{\omega}_{j}^{\mathrm{T}} \boldsymbol{x} + b_{j}) \boldsymbol{\beta}_{j} = \boldsymbol{h}^{\mathrm{T}}(\boldsymbol{x}) \boldsymbol{\beta}$$
(1)

式中
$$[\boldsymbol{\omega}_{1}^{\mathrm{T}}, \cdots, \boldsymbol{\omega}_{n}^{\mathrm{T}}] \in \mathbf{R}^{L \times n}$$
表示输入层与隐含层之



间 的 输 入 权 值, b 表 示 隐 含 层 的 偏 置,  $\beta = [\beta_1^{T}, ..., \beta_m^{T}] \in \mathbb{R}^{L \times m}$ 表示隐含层与输出层之间的输出 权值, h(x)为隐含层的特征映射向量。标准的 SLFN 的训练目的是通过反向传播(BP)算法找到合适的网 络拓扑参数, 从而实现对所有训练样本的无偏估计, 即满足

$$\sum_{j=1}^{L} g(\boldsymbol{\omega}_{j}^{\mathrm{T}} \boldsymbol{x} + b_{j}) \boldsymbol{\beta}_{j} = t_{i}, i = 1, 2, \cdots N$$
(2)

针对全部训练样本,上式可以改写为

$$H\beta = T$$

(3)

式中 $T = [t_1^T, \dots, t_m^T]$ 是期望输出矩阵,H被称为 隐含层输出矩阵,其表达式为

$$H(\boldsymbol{\omega}_{i},\cdots,\boldsymbol{\omega}_{L},b_{i},\cdots,b_{L}) = \begin{bmatrix} g(\boldsymbol{\omega}_{1}^{\mathsf{T}}\boldsymbol{x}_{1}+b_{1}) & \cdots & g(\boldsymbol{\omega}_{L}^{\mathsf{T}}\boldsymbol{x}_{1}+b_{L}) \\ \vdots & \cdots & \vdots \\ g(\boldsymbol{\omega}_{1}^{\mathsf{T}}\boldsymbol{x}_{N}+b_{1}) & \cdots & g(\boldsymbol{\omega}_{1}^{\mathsf{T}}\boldsymbol{x}_{N}+b_{1}) \end{bmatrix}_{N \times I}$$
(4)

如果隐含层节点个数L等于训练样本数N,那么 H矩阵是可逆的方阵,这种情况下 SLFN 可实现对训 练样本无偏估计<sup>[17]</sup>。但在更多情况下,L要小于N,此 时H矩阵是不可逆方阵,将无法实现对训练样本的无 偏估计,这时 SLFN 的训练目标应改为寻找满足如下 要求的网络拓扑参数

$$\left\| \boldsymbol{H}(\hat{\boldsymbol{\omega}}_{i},\cdots,\hat{\boldsymbol{\omega}}_{L},\hat{b}_{i},\cdots,\hat{b}_{L})\hat{\boldsymbol{\beta}} - \boldsymbol{t} \right\| =$$

$$\min_{\hat{\boldsymbol{\omega}}_{i},\hat{b}_{i}\hat{\boldsymbol{\beta}}} \left\| \boldsymbol{H}(\boldsymbol{\omega}_{i},\cdots,\boldsymbol{\omega}_{L},b_{i},\cdots,b_{L})\boldsymbol{\beta} - \boldsymbol{T} \right\|$$

$$(5)$$

上式也等价于最小化损失函数

$$\lambda = \sum_{j=1}^{N} \left( \sum_{i=1}^{L} \beta_{i} g\left( \boldsymbol{\omega}_{i}^{\mathrm{T}} \boldsymbol{x}_{j} + b_{i} \right) - t_{j} \right)^{2}$$
(6)

一般形式 BP 训练方法是利用误差的方向传播, 使得网络拓扑参数值沿着全局最优的梯度方向优 化,即

$$\theta_{k} = \theta_{k-1} - \eta \frac{\partial \lambda(\theta)}{\partial \theta}$$
(7)

式中η表示学习效率, θ表示网络拓扑参数。

BP训练方法也有一些不足:(1)如果选取的η较 小,则算法的收敛速度会降低,反之如果选取的η较 大,算法的训练性能则会出现不稳定和不收敛的情 况;(2)容易陷入局部最优解,从而导致过拟合现象; (3)算法需要多次迭代,导致训练时长偏长。

为了解决以上不足,本文采用LM算法结合了梯 度下降法和高斯-牛顿法的优点,是使用最广泛的非 线性最小二乘算法。当取较小步长时,步长等于牛 顿迭代法步长,反之,步长与梯度下降法的步长近 似。因而它既有高斯-牛顿法的局部收敛性,又有梯 度法的全局特性,在一定程度上缓解了BP网络学习 算法收敛速度慢和容易陷入局部最小点等问题。其 中,学习率的公式为

$$\eta(t) = \eta_{\max} - t \frac{\eta_{\max} - \eta_{\min}}{t_{\max}}$$
(8)

式中 $\eta_{max}$ 为最大学习率, $\eta_{min}$ 为最小学习率, $t_{max}$ 为最大训练次数,t为当前训练次数。

#### 2.3 ReliefF-LMBP网络

Relieff 算法的基本思想是给样本的每一个特征 赋予权值,并对权值进行迭代更新,之后根据权值大 小对相应特征进行排序,并据此选择特征子集,使得 好的特征聚集同类样本,而离散异类样本。设一个 单标签数据集有 K个类标签,其训练数据集为 D ={ $(x_1, y_1), (x_2, y_2), ..., (x_n, y_n)$ },其中  $x_i \in \mathbb{R}^p$ 为样本特征空 间, $y_i \in \mathbb{R}^k$ 为样本类别空间。如果第 i个样本 $x_i$ 属于第 k类,则记为 $y_i(k)=1$ ,否则记为 $y_i(k)=0$ 。因此,数据 集 D可看作是由 $p \times n$ 的特征矩阵  $X = [x_1, x_2, ..., x_n]$ 和  $K \times n$ 的标签矩阵  $Y = [y_1, y_2, ..., y_n]$ 构成的,且矩 阵 Y的每一列只有一个元素值为 1。

ReliefF算法输入为训练数据集D,迭代次数m和 最近邻样本个数k,输出为特征的预测权值W和特征 重要性排序ranks。主要过程为

(1) 对特征的预测权值初始化 ₩(B) = 0.0, B =1, 2, ..., p。

(2)开始迭代,首先从**D**中随机选择一个样本记为*R*<sub>i</sub>。

(3) 找到与样本 R<sub>i</sub> 同类的 k个最近邻 H<sub>i</sub>。

(4) 对每个类  $C \neq class(R_i)$ , 找出与  $R_i$ 不同类的 k 个最近邻  $M_i(C)$ 。

(5)更新每个特征权值。  $\boldsymbol{W}(B) = \boldsymbol{W}(B) - \sum_{j=1}^{k} \operatorname{diff}(B, R_i, H_j) / (m \cdot k) + \sum_{C * \operatorname{class}(R_i)} \left[ \frac{P(C)}{1 - P(\operatorname{class}(R_i))} \sum_{j=1}^{k} \operatorname{diff}(B, R_i, M_j(C)) \right] / (m \cdot k)$ (9)

式中 class (*R<sub>i</sub>*)表示样本 *R<sub>i</sub>*包含的类标签,diff(*B*, 11,12)是样本 11 和 12关于特征 *B* 的距离,*P*(*C*)表示第 *C*类目标的概率,*M<sub>j</sub>*(*C*)表示第 *C*类目标的第*j*个样 本,且*j=1,2,…,k*。其中*m*和*k*的具体大小可根据样 本规模进行设定。得到各个特征对应的权值后,越 大权值表示该特征对样本有越强区分能力,这样通 过权值的大小设阈值就可以得到新的特征子集,从 而达到了对数据进行降维的目的。Relieff 算法对不 同类样本的距离进行加权平均,通过计算分离任意 两个类别之间最近距离的能力来估计特征的重 要性。

ReliefF-BP网络是将 ReliefF 算法和 BP 算法相结 合产生的。首先将数据集通过 ReliefF 算法进行特征 选择,得到样本中各个特征的预测权重 W 和特征重 要性排序 ranks,然后按照权值重要性排序结果依次 逐渐增加特征数到 BP 网络得到各个工作点的诊断精 度。涡轴发动机气路故障模式识别方法包括训练和 测试两个阶段,具体流程如图 3 所示。在训练阶段, 利用训练数据集训练 ReliefF 特征提取器,并根据权 重的大小依次添加相应的特征,训练得到 BP 网络分 类器。在测试阶段,根据得到的特征权值大小的顺



Fig. 3 Gas path fault diagnosis flow chart

序确定特征的重要性顺序,从大到小依次选择特征, 根据测试精度的变化分析验证选取的特征的重要 性。基于BP网络的故障模式分类器是一种"一对多" 分类器。该方法基本原理是根据m类数据样本,构造 m个二分类器,其中第i类数据用于训练第i个分类 器,其标签为正例,而其他任何非本类数据记为反 例,以此类推。该方法有效提高了运算速度,降低了 存储容量。

#### 3 算例与分析

#### 3.1 ReliefF特征选择

本节所使用的故障数据由涡轴发动机模拟产 生<sup>[18]</sup>,根据表2给模型相应的健康参数的偏置,得到 相应的传感器参数,并通过ReliefF算法,在飞行包线 内的不同工作点对已有的传感器参数进行特征选 择。涡轴发动机飞行高度H最大为6km,飞行马赫数 *Ma*最大0.4,如图4所示。为检验特征选择算法适用 性,在常用的2km以下飞行高度随机选取*H*=0m,*Ma*= 0;*H*=100m,*Ma*=0;*H*=1200m,*Ma*=0.1;*H*=900m,*Ma*= 0;*H*=100m,*Ma*=0;*H*=1200m,*Ma*=0.1;*H*=900m,*Ma*= 0,25以及*H*=2km,*Ma*=0.4的5个大气条件,并以发动 机100%转速条件作为设定工况条件。



Fig. 4 Testing point within flight envelop

针对图1所示的不同故障部件,依次对发动机 模型的不同工作点设置表2所示故障模式,在得到 的故障模式模拟测量数据后加入高斯噪声,再将所 有的数据都归一化到[0,1]区间。其中,每种故障 模式包含100组样本分别用于训练和测试,因此训 练数据和测试数据分别包含1100组样本。针对表1 中8种传感器参数,利用 ReliefF 算法对数据进行 特征选择,其中,令最近邻样本个数 k=40,抽样次数 m=100。

ReliefF 算法的仿真结果如表 3 所示,将表中的数据绘制成柱状图如图 5 所示,图中横坐标 1~8 依次代表传感器参数  $N_{\rm P}$ ,  $N_{\rm g}$ ,  $p_3$ ,  $T_3$ ,  $p_5$ ,  $T_{5, P6, T_6}$ ,纵坐标表示由 ReliefF 算法得出的各个特征的预测权值特征向量。将各个传感器参数的特征按照权值从大到小排列,得到的结果如表 4 所示。

结合表 3,表 4 和图 5 的数据对仿真结果进行分 析,可以看出,特征的预测权值有正有负,其中数值 越大代表该特征对于当前状态下故障的模式识别起 到更大的作用,当权值为负数时,则表明该特征在相 同故障模式中变化较大而在不同故障模式中变化较 小,这样的特征不利于对于故障模式的判断,因此优 先考虑将权值为负的特征在样本中去除。通过表 4 中的数据可以看出:*N*<sub>P</sub>,*N*<sub>g</sub>,*T*<sub>5</sub>和*T*<sub>6</sub>在全部飞行状态点 下权值均较大,故这四种特征在发动机故障模式识 别中起到至关重要的作用,而*p*<sub>5</sub>和*p*<sub>6</sub>在全部飞行状态 点下权值均最小且为负,故考虑将这两维特征在样 本中去除。

#### 3.2 ReliefF-BP网络仿真分析

为了验证 ReliefF 算法结果的有效性,本文将样本中的特征按照表4中的顺序依次添加到样本中,分别利用 BP和LMBP神经网络对5种飞行状态点的故障模式进行分类,并将分类准确率以折线图的形式展现。首先需要搭建 BP神经网络,其结构如图6(a)所示,其中隐含层神经元节点数为16,输出层神经元个数为11,输入层神经元个数随着输入向量维度的增加而增加,其变化范围是1~8,训练样本和测试样本均为100。图6(b)为 BP网络训练过程图,其中设定的目标最小均方差为10<sup>-6</sup>,训练最大迭代次数为500次,最大确认失败次数为默认值6次。定义分类准确率A<sub>cc</sub>如式(10)所示。

Table 3 Prediction weight of individual features under different flight status points

	$N_{ m P}$	$N_{ m g}$	$p_3$	$T_3$	$P_5$	$T_5$	$p_6$	$T_6$
1	0.0066	0.0931	0.0009	-0.0017	-0.0493	0.0126	-0.0453	0.0118
2	0.0617	0.1032	0.0259	-0.0081	-0.0585	0.0206	-0.0646	0.0238
3	0.0825	-0.0014	0.1173	0.0870	-0.0768	0.0230	-0.0796	0.0173
4	0.0502	0.1125	0.0240	-0.0037	-0.0565	0.0097	-0.0601	0.0080
5	0.0210	0.0725	0.0216	0.0042	-0.0497	0.0312	-0.0503	0.0299



Fig. 5 Feature selection results

# Table 4 Individual characteristics are sorted by predicted weight under different flight points

Testing point			Senso	r paran	neter fe	atures		
1	$N_{\rm g}$	$T_5$	$T_6$	$N_{\rm P}$	$p_3$	$T_3$	$p_6$	$p_5$
2	$N_{\rm g}$	$N_{\mathrm{P}}$	$p_3$	$T_6$	$T_5$	$T_3$	$p_5$	$p_6$
3	$p_3$	$T_3$	$N_{\rm P}$	$T_5$	$T_6$	$N_{\rm g}$	$p_5$	$p_6$
4	$N_{\rm g}$	$N_{\rm P}$	$p_3$	$T_5$	$T_6$	$T_3$	$p_5$	$p_6$
5	$N_{g}$	$T_5$	$T_6$	$p_3$	$N_{\rm P}$	$T_3$	$p_5$	$p_6$



(a) BP neural network structure



(b) Tanning process

#### Fig. 6 BP neural network training process

$$A_{\rm cc} = \frac{N_{\rm true}}{N_{\rm total}} \tag{10}$$

式中N<sub>true</sub>是正确分类的样本数,N<sub>total</sub>是总的样本数。

根据上述搭建的 BP 网络进行仿真验证,仿真结 果如表5所示。将表5中的数据整理成图,其结果如 图7所示。由图7可以看出,ReliefF-BP 网络在特征 数较少的时候诊断精度较低,随着特征数的增加,ReliefF-BP 网络的诊断精度逐渐增加,在其中的4个工 况点特征数增加到6时,网络诊断精度达到最高,之 后再随着特征数的增加,网络的诊断精度下降,表明 了训练集中的有些特征会对分类结果起负面影响。

#### 3.3 ReliefF-LMBP网络仿真分析

LMBP神经网络拓扑参数设置和 3.2 节相同,输 入神经元个数根据输入的特征相同,隐层神经元设 置为 16,输出神经元个数为气路状态分类的种类即 为 11 种。反向调优算法使用 LM 算法。将样本中的 特征按照表 4 的顺序依次加入 LMBP 网络。仿真结 果如表 6 所示。

将表6中的数据整理成图,其结果如图8所示。 由图8可以看出,ReliefF-LMBP网络在随着特征数的 增加诊断精度逐渐增加,在到达到分类准确率最高 点之后,诊断结果保持基本稳定。

Table 5         Comparison of simulation results under BP										
Feature nu	umber	1	2	3	4	5	6	7	8	
	1	0.5009	0.7355	0.7764	0.8682	0.8973	0.9991	0.9218	0.8773	
	2	0.4373	0.7018	0.9473	0.8836	0.9082	0.9945	0.9909	0.8818	
Training	3	0.6127	0.7764	0.9309	0.8918	0.9818	0.9927	0.9100	0.9155	
	4	0.4164	0.7382	0.9891	0.9845	0.9655	0.9964	0.9427	0.9127	
	5	0.4173	0.7500	0.7982	0.9518	0.8936	0.9755	0.9345	0.9391	
	1	0.4773	0.7409	0.7609	0.8682	0.8955	0.9973	0.9145	0.8645	
Test	2	0.4345	0.7200	0.9491	0.8918	0.9018	0.9955	0.9945	0.8818	
	3	0.5891	0.7591	0.9227	0.8891	0.9800	0.9964	0.9064	0.9118	
	4	0.3909	0.7127	0.9827	0.9827	0.9700	0.9973	0.9391	0.9191	
	5	0.3800	0.7364	0.8027	0.9345	0.8955	0.9755	0.9291	0.9327	



Fig. 7 Accuracy of classification varies with the number of characteristics under BP

Table 6         Comparison of simulation results under LMBP									
Feature nu	umber	1	2	3	4	5	6	7	8
	1	0.5355	0.9582	0.9973	0.9991	1.0000	1.0000	1.0000	1.0000
	2	0.4555	0.8855	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
Training	3	0.5073	0.8955	0.9973	1.0000	1.0000	1.0000	1.0000	1.0000
	4	0.4418	0.8455	0.9973	0.9955	1.0000	1.0000	1.0000	1.0000
	5	0.4218	0.8164	0.9936	0.9982	1.0000	1.0000	0.9991	0.9973
	1	0.5009	0.9709	0.9964	0.9991	1.0000	0.9982	0.9982	0.9991
Test	2	0.4227	0.8818	0.9982	0.9991	1.0000	1.0000	1.0000	1.0000
	3	0.5036	0.8964	0.9973	0.9991	1.0000	1.0000	1.0000	1.0000
	4	0.3982	0.8455	0.9900	0.9964	1.0000	0.9955	1.0000	1.0000
	5	0.3818	0.8155	0.9900	0.9936	1.0000	0.9991	0.9991	0.9973



Fig. 8 Accuracy of classification varies with the number of characteristics under LMBP

#### 3.4 仿真结果对比分析

仿真结果可以看出,BP网络的分类准确率最高点出现在特征数6个情形下,而且随着特征数的加入,BP网络算法的分类准确率并没有越来越高, 呈现一定的波动性。而LMBP网络的分类准确率 最高的点依然出现在特征数4~6个的情形下,再次 验证了ReliefF算法的结果,并且随着特征数的增 多,LMBP网络的分类准确率越来越高,并趋近基本 稳定,在特征数变化至5之后,有小幅下降,但相较 于BP网络,LMBP算法的分类准确率也更高。由表 5和表6可以看出,在不进行特征选择的情况下,即 输入维度为8个传感器参数时,BP网络的测试准确 率在0.9左右,而LMBP算法的测试准确率都在0.99 以上,这表明了LMBP算法具有更好的全局寻优 能力。

均值和标准差的计算如式(11)和式(12)所示。 在训练点和测试点的均值和标准差如表7所示。可 以看出LMBP算法在训练点和测试点的均值高于BP 算法,而标准差低于BP算法,表明了ReliefF-LMBP 网络相比于ReliefF-BP网络有着更高的诊断精度和 稳定性。考虑到*p*<sub>5</sub>和*p*<sub>6</sub>的预测权值在各个飞行状态 点都为负值,故这两维传感器参数对发动机故障模 式识别起到的正面影响较小,在既保留发动机的故 障信息的基础上,又不影响算法故障识别精度的情 况下,可以考虑去除这两维传感器参数。

$$E_{\rm ean} = \frac{1}{N} \sum_{i=1}^{N} y_i$$
 (11)

$$V_{\rm std} = \sqrt{\frac{1}{N} \sum_{i=1}^{N} (y_i - \hat{y})}$$
(12)

Table 7 Comparison of the mean and standard deviation of training points and test points	Table 7	Comparison of the mean	and standard deviation of	f training points and test points
--	---------	------------------------	---------------------------	-----------------------------------

Fe	ature number	1	2	3	4	5	6	7	8
Train	ReliefF-BP	0.4769	0.7403	0.8883	0.9159	0.9292	0.9916	0.9399	0.9052
$E_{ean}$	ReliefF-LMBP	0.4723	0.8802	0.9971	0.9985	1.0000	1.0000	0.9998	0.9994
Train	ReliefF-BP	0.0833	0.0269	0.0949	0.0497	0.0412	0.0093	0.0310	0.0256
$V_{\rm std}$	ReliefF-LMBP	0.0473	0.0539	0.0022	0.0018	0	0	0.0004	0.0012
Test	ReliefF-BP	0.4543	0.7338	0.8836	0.9132	0.9285	0.9924	0.9367	0.9019
$E_{ean}$	ReliefF-LMBP	0.4414	0.8820	0.9943	0.9974	1.0000	0.9985	0.9994	0.9992
Test	ReliefF-BP	0.0846	0.0182	0.0964	0.0456	0.0426	0.0094	0.0346	0.0280
$V_{ m std}$	ReliefF-LMBP	0.0573	0.0588	0.0040	0.0024	0	0.0018	0.0008	0.0011

#### 4 结 论

通过本文研究获得的结论如下:

(1)通过 ReliefF 算法分析,提取获得了涡轴发 动机气路故障特征,获得了降维后的传感器表征 参数。

(2)利用提取的故障特征子集以及 BP 和 LMBP 算法对比,表明了 ReliefF-LMBP 算法有着更高的诊断精度和稳定性。

(3)通过涡轴发动机典型气路故障模式仿真分析,以及包线内典型工作点的验证,表明了所提出方法的气路故障诊断有效性。

致 谢:感谢国家科技重大专项基金的资助。

#### 参考文献

[1] Volponi A J. Gas Turbine Engine Health Management Past, Present and Future Trends [J]. Journal of Engine for Gas Turbines and Power-Transactions of the ASME, 2014, 136(5).

- [2] Lu F, Ju H F, Huang J Q. An Improved Extended Kalman Filter with Inequality Constraints for Gas Turbine Engine Health Monitoring [J]. Aerospace Science and Technology, 2016, 58(1): 36-47.
- [3] You C X, Huang J Q, Lu F. Recursive Reduced Kernel Based Extreme Learning Machine for Aero-Engine Fault Pattern Recognition [J]. Neurocomputing, 2016, 214: 1038-1045.
- [4] Peng K, Hu Y J, Fan D, et al. An Adaptive Feedback Turning SIR Particle Filter and Its Application on Fault Diagnosis of Auxiliary Power Unit [C]. Orleans: 9th International Conference on Mechanical and Aerospace Engineering, 2018.
- [5] Yan X, Jia M P. Compound Fault Diagnosis of Rotating Machinery Based on OVMD and a 1.5-Dimension Envelope Spectrum [J]. Measurement Science & Technology, 2016, 27(7).

- [6] Li L, Wang Z, Jiang H. Aero-Engine Abrupt Failure Prognosis Based on Multi-States MOG-HMM and Viterbi Algorithm[J]. Journal of Vibration Measurement & Diagnosis, 2014, 34(2); 310-314.
- [7] 逄 珊,杨欣毅,张 勇,等.应用深度核极限学习 机的航空发动机部件故障诊断[J].推进技术,2017, 38(11): 2613-2621. (PANG Shan, YANG Xin-yi, ZHANG Yong, et al. Application of Deep Kernel Extreme Learning Machine in Aero Engine Components Fault Diagnosis [J]. Journal of Propulsion Technology, 2017, 38(11): 2613-2621.)
- [8] 李本威,林学森,杨欣毅,等. 深度置信网络在发动机 气路部件性能衰退故障诊断中的应用研究[J]. 推进技 术, 2016, 37(11): 2173-2180. (LI Ben-wei, LIN Xuesen, YANG Xin-yi, et al. Research on Application of Deep Belief Networks on Engine Gas Path Component Performance Degradation Defect Diagnostics [J]. Journal of Propulsion Technology, 2016, 37(11): 2173-2180.)
- [9] 吕 升,郭迎清,孙 浩.基于GA-AANN神经网络的SDQ算法的航空发动机传感器数据预处理[J].推进技术,2018,39(5):1142-1150. (LYU Sheng,GUO Ying-qing,SUN Hao. Aero-Engine Sensor Data Preprocessing Based on SDQ Algorithm of GA-AANN Neural Network [J]. Journal of Propulsion Technology,2018,39(5):1142-1150.)
- [10] Gou L F, Zhong Y. A New Fault Diagnosis Method

Based on Attributes Weighted Neutrosophic Set [J]. *IEEE Access*, 2019, (7): 117740-117748.

- [11] 刘元芳. 航空发动机气路故障的智能诊断方法研究 [D]. 厦门: 厦门大学, 2018.
- [12] Huang Z K, Yang C H, Zhou X J, et al. A Hybrid Feature Selection Method Based on Binary State Transition Algorithm and ReliefF [J]. *IEEE Journal of Biomedical* and Health Informatics, 2019, 23(5): 1888-1898.
- [13] 潘 锋.特征提取与特征选择技术研究[D].南京:南 京航空航天大学,2011.
- [14] Spolaôr N, Cherman E A, Monard M C, et al. ReliefF for Multi-Label Feature Selection [C]. Fortaleza: 2nd Conference on Intelligent Systems, 2013.
- [15] 黄金泉,冯 敏,鲁 峰.基于自适应粒子滤波的涡扇发动机故障诊断[J].航空动力学报,2014,29(6): 1498-1504.
- [16] 胡 宇,张世英,杨月诚,等.基于超球体平方根无迹 Kalman 滤波算法的涡扇发动机气路部件故障诊断
   [J].航空动力学报,2014,29(3):689-695.
- [17] Tamusa S, Tateishi M. Capabilities of a Four-Layered Feedforward Neural Network: Four Layers Versus Three
  [J]. IEEE Transactions on Neural Networks, 1997, 8 (2): 251-155.
- [18] 董 桢,周文祥,潘慕绚,等.涡轴发动机部件特性修正及更新方法[J].航空发动机,2018,44(6): 11-16.

(编辑:张 贺)