

基于 ICA 与深度学习的发动机气路系统状态监测*

崔建国¹, 周碧嘉¹, 蒋丽英¹, 于明月¹, 王景霖²

(1. 沈阳航空航天大学自动化学院 沈阳, 110136) (2. 故障诊断与健康管理工作航空科技重点实验室 上海, 201601)

摘要 为提升航空发动机气路系统状态监测的有效性, 提出一种采用深度学习并结合独立分量分析(independent component analysis, 简称 ICA)的新方法, 对航空发动机气路系统的健康状态进行了监测技术研究。首先, 对实际采集的航空发动机气路系统健康监测参数进行预处理, 对预处理后的参数数据采用独立分量分析方法进行处理, 提取代表当前状态的特征系数矩阵; 其次, 由提取的特征矩阵创建深度学习状态监测模型; 最后, 由创建的状态监测模型对航空发动机气路系统健康状态进行监测。为验证所提方法的有效性, 采用典型神经网络与支持向量机分别对由主成分分析(principal components analysis, 简称 PCA)和 ICA 构建的特征矩阵进行了状态监测研究。结果表明, 采用 ICA 和深度学习相结合的状态监测方法, 可以更好地实现对航空发动机气路系统的状态监测, 有良好的应用与推广前景。

关键词 航空发动机; 独立分量分析; 深度学习; 状态监测

中图分类号 TH136; TP206⁺.3

引言

航空发动机是复杂的热动力系统, 其常见的工作状态包括停车、慢车、巡航、小加力及全加力等多种状态。由于发动机结构复杂, 运行环境恶劣, 导致航空发动机易出现各种故障, 而作为飞机的动力源要求其具有极高的安全性与可靠性^[1]。因此, 对航空发动机进行状态监测具有重要的研究价值。

气路系统是发动机的核心系统, 其状态监测方法主要包括基于分析模型的状态监测方法、基于定性经验知识的状态监测方法和基于数据驱动的状态监测方法^[2]。目前, 应用较为广泛的是基于数据驱动的状态监测方法, 其核心是对可利用的过程历史数据进行特征提取, 并转化和表征为监测系统的一种先验知识。由于发动机工作状态多变, 运行环境复杂, 故障间耦合关系复杂, 使得建立准确的发动机气路系统模型较为困难, 因而采用基于数据驱动的监测技术更为实用。实际工程中最为常用的方法是主成分分析(PCA), 它是一种简便且有效的特征提取方法, 但 PCA 方法需要假设主元之间彼此正交, 测量数据呈高斯分布, 独立分量分析(ICA)则不要求样本呈高斯分布。航空发动机实际工作过程中的数据不能保证均呈高斯分布, 因此选取独立分量分

析方法来克服 PCA 方法需假设其测量数据呈高斯分布的限制。ICA 方法解决的是原始数据分解的问题, 由 Comon 给出了 ICA 的一个较为清晰的数学定义。Tian 等^[3]将 ICA 方法应用于频域与小波域进行特征提取, 进而实现齿轮箱的故障诊断。Li 等^[4]将 ICA 应用于分析机械设备的声学信号来实现机械设备的故障诊断。Barnard 等^[5]将 ICA 用于对内燃机的监测信号进行分析。ICA 是 PCA 的一种扩展, 该变换把数据分离成相互独立的非高斯的线性组合, 使用 ICA 方法可以从复合信号中提取出独立成分, 将 ICA 用于航空发动机数据分析处理, 能更有效地从测量数据中提取出独立成分, 这些独立成分能够更加本质地反映出航空发动机气路系统状态的特征, 因而 ICA 具有更广泛的应用价值^[6]。

常用的基于数据驱动的航空发动机气路系统状态监测方法有神经网络、支持向量机(support vector machine, 简称 SVM)、多元统计方法等, 但以反向传播神经网络(back propagation, 简称 BP)为代表的传统浅层神经网络存在泛化能力弱、易产生局部极小值等问题; 而 SVM 参数选择复杂, 训练速度较慢, 使其在状态监测中的应用受到限制^[7]。深度置信网络(deep belief network, 简称 DBN)是一种深度学习的生成模型, 已经在不同领域中取得许多成绩, 如手写体数字识别、ImageNet 分类和语音识

* 国家自然科学基金资助项目(51605309); 航空科学基金资助项目(20153354005, 20163354004)

收稿日期: 2019-03-15; 修回日期: 2019-07-13

别等,使得深度置信网络受到业界诸多相关人士的关注,国内外一些学者将其应用于状态监测领域。

笔者采用ICA与深度学习结合的新方法,对航空发动机气路系统状态监测的技术进行研究。通过ICA方法实现对原始参数数据的特征提取^[8],并利用深度学习的方法实现对航空发动机气路系统的状态监测。

1 独立分量分析与深度学习原理

1.1 独立分量分析

独立分量分析是一种数据处理技术,描述了如何从已知多元观测数据中获取独立成分的过程,揭示出混合信息中的独立成分。ICA实质是通过线性变换将观察到的数据转换为相互独立的分量^[9-10]。

假定有 N 个传感器监测到 N 个观测信号 x_i ($i=1,2,\dots,N$),每个观测信号是由 M 个独立源信号 s_i ($i=1,2,\dots,M$)的线性混合,即

$$\mathbf{X} = \mathbf{A}\mathbf{S} \quad (1)$$

其中: $\mathbf{X} = [x_1, x_2, \dots, x_N]^T$ 和 $\mathbf{S} = [s_1, s_2, \dots, s_M]^T$ 为混合信号向量和源信号向量; \mathbf{A} 为 $N \times M$ 的未知混合矩阵。

在不明确源信号向量 \mathbf{S} 和混合矩阵 \mathbf{A} 的情况下,期望能找到一个对 \mathbf{X} 做线性变换的矩阵 \mathbf{W} ,使 \mathbf{X} 从混合信号中分离出尽可能相互独立的分量,即

$$\mathbf{B} = \mathbf{W}\mathbf{X} \quad (2)$$

并希望 \mathbf{B} 能较好地逼近真实源信号。

ICA的特征提取过程主要如下。

1) 数据预处理。首先,对数据进行中心化处理,使数据均值为0,即 $\mathbf{X}\{x_i\}=0$;其次,对中心化处理后的数据进行白化,白化后的数据分量是不相关的,并且具有单位方差

$$\mathbf{Z}_0 = \mathbf{A}^{-1/2} \mathbf{U}^T \quad (3)$$

其中: \mathbf{A} 为以 \mathbf{S} 的协方差矩阵的特征值为对角元素组成的对角矩阵; \mathbf{U} 为特征值对应的特征向量矩阵。

将 \mathbf{A} 的特征值由大到小排序,选取前 d 个统计独立的特征向量 \mathbf{U}_d ,于是 $\mathbf{Z}_0 = \mathbf{A}_d^{-1/2} \mathbf{U}_d^T$,从而使特征空间由 N 维降到 d 维,后续只需计算 d 维统计独立的特征。

2) 选取目标函数。目标函数是衡量ICA算法结果好坏的关键,笔者采用负熵最大作为目标函数^[11]

$$J_g(y) = \{S[g(y)] - S[g(y_{\text{Gauss}})]\} \quad (4)$$

其中: $g(\cdot)$ 为非线性函数。

可取 $g_1(y) = y^3$, $g_2(y) = \tanh(a_1 y)$ 或 $g_3(y) = y \exp(-y^2/2)$,常数 a_1 取在 $1 \leq a_1 \leq 2$ 范围内,通常 $a_1 = 1$ 。

3) 求取最优解。笔者选择基于自然梯度的权值 \mathbf{Z} 更新法则

$$\mathbf{Z}^* = \mathbf{S}\{\mathbf{X}g(\mathbf{Z}^T \mathbf{X})\} - \mathbf{S}\{g'(\mathbf{Z}^T \mathbf{X})\} \mathbf{Z} \quad (5)$$

其中: $\mathbf{Z}^T \mathbf{X}$ 为ICA算法具有最大非高斯性的方向确定依据。

由于航空发动机气路系统常拥有大量的监测参数,这些参数数据并不是相互独立的,往往是由少数独立参数所驱动。利用独立分量分析提取这些参数,并进一步对其进行检测,可以有效地减少数据的维数,同时能够更好地反映数据的特征。

1.2 深度学习

深度学习的概念起源于人工神经网络,其本质是指一类对具有深层结构的神经网络进行有效的训练方法^[7]。基本的深层网络模型可以分为两大类:生成模型和判别模型。生成是指从隐含层到输入数据的重构过程;而判别是指从输入数据到隐含层的归约过程。

深度置信网络作为生成模型的学习过程可以分为两个阶段,先用受限玻尔兹曼机(restricted Boltzmann machine,简称RBM)进行逐层预训练,再用wake-sleep算法进行调优。作为判别模型时,深度置信网络在经过RBM的逐层预训练之后,直接再用反向传播算法进行调优,无需wake-sleep算法参与。笔者采用作为判别模型的深度置信网络对状态监测模型进行构建。

RBM是在玻尔兹曼机的基础上提出的,它的受限体现在模型必须为二分图,从神经网络角度看就是一个层次型的二层网络,连接的边只存在于输入层和输出层之间,输出层本身无连接。

RBM是一个两层循环神经网络,层内各个节点互不连接。其中:第1层称为可见层,即输入层;第2层是隐含层,即特征提取层。如图1所示,神经元在层与层之间是全连接,而层内没有连接^[12]。可见层一般是连接输入,如图像的像素,具有可观测到的性质;而隐含层的意义一般不太明确,它用来获取可见层单元对应变量之间的依赖关系,因此可以看作是输入特征的提取。

图1中: n_v 和 n_h 分别为可见层和隐层的神经元个数; $\mathbf{v} = (v_1, v_2, \dots, v_i, \dots, v_{n_v})^T$ 为可见层(输入层)神经元的状态变量; $\mathbf{h} = (h_1, h_2, \dots, h_j, \dots, h_{n_h})^T$




图1 受限玻尔兹曼机结构图

Fig. 1 Restricted Boltzmann machine structure

为神经元的状态变量； $\mathbf{a} = (a_1, a_2, \dots, a_i, \dots, a_{n_v})^T \in \mathbf{R}^{n_v}$ 为可见层的偏置向量； $\mathbf{b} = (b_1, b_2, \dots, b_j, \dots, b_{n_h})^T \in \mathbf{R}^{n_h}$ 为隐层的偏置向量； $\mathbf{W} = (w_{i,j}) \in \mathbf{R}^{n_v \times n_h}$ 为可见层和隐层之间的权值矩阵，即表示可见层第 i 个神经元与隐层第 j 个神经元之间的连接权值； $\theta = (\mathbf{W}, \mathbf{a}, \mathbf{b})$ 为 RBM 的未知参数。

DBN 是一个有多个无监督的 RBM 层和一个有监督的 BP 层堆叠而成的深层神经网络架构。每个 RBM 层的输入是下个 RBM 层的输出，通过多个 RBM 层的特征提取，在顶层形成一个更适合模式分类的特征向量^[13-14]。图 2 所示是由两个不带标签的 RBM 层和一个带标签 BP 层组成的 DBN 结构。

以图 2 所示的 DBN 为例，其训练模型的过程^[15-16]主要如下。

第 1 阶段为无监督预训练(步骤 1~3)，第 2 阶段为有监督调优(步骤 4~5)：

- 1) 初始化网络参数；
- 2) 训练第 1 个 RBM 并固定其权值和偏移值；
- 3) 使用第 1 个 RBM 的隐含层特征作为第 2 个 RBM 的输入层特征，训练第 2 个 RBM 并将第 2 个 RBM 堆叠在第 1 个 RBM 的上方；
- 4) 在第 2 个 RBM 上方构建一个分类的 BP 网络，使用第 2 个 RBM 的隐含层特征作为它的输入




图2 深度置信网络结构

Fig. 2 Deep belief network structure

特征，进行有监督的训练；

5) 顶层的 BP 网络将错误信息自顶向下传播至每一个 RBM 层，并对整个 DBN 网络进行参数调优^[17]。

2 基于 ICA 与深度学习的状态监测方案

笔者选用某型航空发动机气路系统的参数数据对其进行状态监测。基于 ICA 和深度置信网络的航空发动机状态监测模型包含 ICA 特征提取部分和深度置信网络状态监测模型，先通过 ICA 对发动机相关参数数据进行特征提取，再对特征提取后的特征数据矩阵建立深度置信网络状态监测模型，并对其有效性进行测试。状态监测总体方案如图 3 所示。

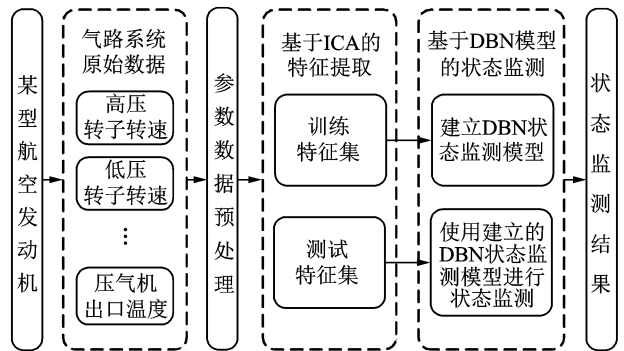


图3 航空发动机气路系统状态监测方案

Fig. 3 Aero-engine gas path monitoring approach

具体流程如下：

- 1) 对发动机相关参数原始数据进行预处理；
- 2) 利用 ICA 方法对预处理后的数据进行特征提取；
- 3) 将特征提取后的数据分为 DBN 网络训练数据集和测试数据集；
- 4) 选取适当 RBM 层数建立 DBN 状态监测模型；
- 5) 利用训练数据集和测试数据集对 DBN 状态监测模型进行训练和测试；
- 6) 对状态监测结果进行分析。

3 航空发动机状态监测试验

3.1 基于 ICA 的发动机状态特征提取

采用专业试验平台对某型航空发动机气路系统

进行测试试验,选取能够较好反应航空发动机气路系统状态的 14 个参数,分别为高压转子转速、低压转子转速、进口空气总温、高压压气机出口空气压力、高压压气机进口空气总温、压气机可调叶片角度、低压涡轮后排气压力、低压涡轮后燃气温度、涡轮落压比、滑油压差、滑油回油温度、喷口喉部直径、增压泵出口燃油温度以及油门角度,并将健康状态和故障状态的数据进行分类。选取进行试验的数据为健康状态和故障状态各 80 组,两种状态共 160 组数据。定义每种状态的前 40 组作为训练数据,后 40 组作为测试数据^[8]。

选取健康数据建立 ICA 特征提取模型,提取出能够代表当前工况的特征系数矩阵。将该型航空发动机气路系统运行状态表示为集合 $\{A_1, A_2\}$,当 $A_1=0, A_2=1$ 时表示航空发动机气路系统处于健康状态;当 $A_1=1, A_2=0$ 时表示航空发动机气路系统处于故障状态。

由表 1 可以看出,前 5 个特征值的累计贡献率已大于 90%,因此可以选取协方差矩阵的特征值对应的特征向量矩阵的前 5 维数据,应用 ICA 算法对其进行特征提取,可得到由 5 个独立元构成的特征矩阵,如表 2 所示。

表 1 数据协方差矩阵的特征值及其贡献率

Tab. 1 Eigenvalue of data covariance matrix and the contribution rate

编号	特征值	贡献率/%
1	9.310 203 9	66.835 6
2	1.236 723 1	8.878 1
3	1.001 755 2	7.191 3
4	0.874 016 4	6.274 3
5	0.478 558 4	3.435 4
6	0.405 046 4	2.907 7
7	0.280 699 9	2.015 0
8	0.239 977 6	1.722 7
9	0.103 018 8	0.739 5
10	$2.905 2 \times 10^{-16}$	$2.085 6 \times 10^{-15}$
11	$2.282 7 \times 10^{-16}$	$1.638 7 \times 10^{-15}$
12	$5.377 0 \times 10^{-17}$	$3.860 0 \times 10^{-16}$
13	$2.523 0 \times 10^{-17}$	$1.811 2 \times 10^{-16}$
14	$6.714 9 \times 10^{-18}$	$4.820 4 \times 10^{-17}$

通过 ICA 方法提取出由 5 个独立元数据组成的特征系数矩阵,表示不同状态的航空发动机气路系统相关参数数据的特征。数据特征提取在很大程度上降低了状态监测模型的复杂度,并减少了状态监测的耗时。

表 2 独立分量特征矩阵

Tab. 2 Independent component feature matrix

状态样本	独立元 1	独立元 2	独立元 3	独立元 4	独立元 5
1	1.670 2	1.528 9	-1.295 9	-1.072 8	-1.381 9
2	2.494 2	1.249 4	-0.528 5	-0.699 9	0.788 4
⋮	⋮	⋮	⋮	⋮	⋮
79	1.660 7	1.195 1	-1.757 9	-0.874 7	-0.968 8
80	1.686 7	1.657 9	-1.063 8	-1.069 3	0.156 5
81	-2.140 0	1.574 2	-0.070 6	0.792 5	-1.172 5
82	-1.560 2	1.191 8	0.652 4	0.950 7	-0.421 5
⋮	⋮	⋮	⋮	⋮	⋮
159	-1.849 1	1.478 3	-0.863 5	1.275 4	0.992 4
160	-1.891 3	1.706 6	0.111 5	0.699 4	0.800 0

3.2 基于 DBN 模型的发动机状态监测试验

经多次尝试,DBN 状态监测模型选取由 2 层 RBM 神经网络和 1 层 BP 神经网络构成。第 1 层 RBM 网络的输入节点个数与独立元个数相同,输出节点个数选取 5;第 2 层 RBM 网络的输入输出节点个数分别为 5 和 4。将提取的健康与故障两种状态共 160 组数据分为训练数据集和测试数据集,其中:1~40 组为健康状态的训练数据;41~80 组为健康状态的测试数据;81~120 组为故障状态的训练数据;121~160 组为故障状态的测试数据,如表 3、表 4 所示。

表 3 发动机状态监测模型训练数据

Tab. 3 Engine condition monitoring model training data

训练样本	独立元向量	输出目标值
1	D_1	[0 1]
2	D_2	[0 1]
⋮	⋮	⋮
39	D_{39}	[0 1]
40	D_{40}	[0 1]
41	D_{41}	[1 0]
42	D_{42}	[1 0]
⋮	⋮	⋮
79	D_{79}	[1 0]
80	D_{80}	[1 0]

其中:

$$D_1 = \{1.670 2 \quad 1.528 9 \quad -1.295 9 \quad -1.072 8 \quad -1.381 9\};$$

$$D_2 = \{2.494 2 \quad 1.249 4 \quad -0.528 5 \quad -0.699 9 \quad 0.788 4\};$$

$$\vdots$$

$$D_{39} = \{2.207 2 \quad 1.393 3 \quad -0.757 5 \quad -0.830 3 \quad 0.655 3\};$$

$$D_{40} = \{2.192 2 \quad 1.515 3 \quad 1.355 9 \quad -0.954 5 \quad 0.879 5\};$$

$$D_{41} = \{-2.140\ 0\ 1.574\ 2\ -0.070\ 6\ 0.792\ 5\ -1.172\ 5\};$$

$$D_{42} = \{-1.560\ 2\ 1.191\ 8\ 0.652\ 4\ 0.950\ 7\ -0.421\ 5\};$$

$$\vdots$$

$$D_{79} = \{-2.114\ 3\ 1.232\ 5\ -1.589\ 6\ 0.860\ 8\ -1.164\ 9\};$$

$$D_{80} = \{-1.852\ 5\ 1.242\ 9\ 0.118\ 9\ 1.417\ 7\ -0.156\ 4\}.$$

表4 发动机状态监测模型测试数据

Tab. 4 Engine condition monitoring model test data

测试样本	独立元向量	输出目标值
1	E_1	[0 1]
2	E_2	[0 1]
\vdots	\vdots	\vdots
39	E_{39}	[0 1]
40	E_{40}	[0 1]
41	E_{41}	[1 0]
42	E_{42}	[1 0]
\vdots	\vdots	\vdots
79	E_{79}	[1 0]
80	E_{80}	[1 0]

其中:

$$E_1 = \{1.660\ 7\ 1.195\ 1\ -1.757\ 9\ -0.874\ 7\ -0.968\ 8\};$$

$$E_2 = \{1.686\ 7\ 1.657\ 9\ -1.063\ 8\ -1.069\ 3\ 0.156\ 5\};$$

$$\vdots$$

$$E_{39} = \{1.941\ 2\ 1.324\ 0\ 0.995\ 0\ -0.922\ 1\ -0.683\ 6\};$$

$$E_{40} = \{1.535\ 1\ 1.440\ 5\ -0.455\ 3\ -1.383\ 1\ -0.935\ 2\};$$

$$E_{41} = \{-2.100\ 1\ 1.210\ 2\ 1.363\ 0\ 0.645\ 6\ -0.242\ 7\};$$

$$E_{42} = \{-1.631\ 8\ 1.569\ 1\ 1.493\ 9\ 1.199\ 5\ 0.738\ 3\};$$

$$\vdots$$

$$E_{79} = \{-1.849\ 1\ 1.478\ 3\ -0.863\ 5\ 1.275\ 4\ 0.992\ 4\};$$

$$E_{80} = \{-1.891\ 3\ 1.706\ 6\ 0.111\ 5\ 0.699\ 4\ 0.800\ 0\}.$$

利用表3中训练数据集创建DBN网络状态监测模型,将表4中测试数据集输入创建后的状态监测模型,对输入数据进行诊断,可得到状态监测模型对应的输出值。当DBN网络状态监测模型输出单元的输值大于等于0.5时记为1,小于0.5时记为0,则可得到航空发动机状态监测模型的输出结果,如表5所示。

由表5可知,80组数据中识别结果与实际结果一致的有75组,因此基于ICA与深度置信网络的状态监测结果的准确率为93.75%。

为进一步说明基于ICA与深度置信网络航空发动机状态监测模型的有效性,在相同数据下,分别研究了经过PCA和ICA数据特征提取后,使用支持向量机和BP神经网络方法的发动机状态监测。不同模型的状态检测结果如表6所示。

表5 基于ICA和DBN的发动机状态监测结果

Tab. 5 Status monitoring results based on ICA and DBN

测试样本	模型输出值	识别结果	实际结果
1	[0.003 9 0.996 1]	[0 1]	[0 1]
2	[0.003 7 0.996 3]	[0 1]	[0 1]
\vdots	\vdots	\vdots	\vdots
39	[0.995 9 0.004 1]	[1 0]	[0 1]
40	[0.008 6 0.991 4]	[0 1]	[0 1]
41	[0.992 7 0.007 3]	[1 0]	[1 0]
42	[0.976 9 0.023 1]	[1 0]	[1 0]
\vdots	\vdots	\vdots	\vdots
79	[0.986 2 0.013 8]	[1 0]	[1 0]
80	[0.995 4 0.004 6]	[1 0]	[1 0]

表6 不同模型的发动机状态监测结果

Tab. 6 Engine condition monitoring results for different models

模型	提取的特征/%	
	PCA	ICA
DBN	90.00	93.75
SVM	86.25	88.75
BP	77.50	82.50

4 结论

1) 采用ICA方法对航空发动机原始数据进行特征提取,构建特征系数矩阵,并由此建立深度置信网络的状态监测模型,进行状态监测的准确率为93.75%。

2) 采用ICA方法提取特征系数矩阵,建立支持向量机和BP神经网络模型的状态监测准确率分别为88.75%和82.5%,均低于采用深度置信网络进行状态监测的准确率。

3) 采用PCA方法对原始数据进行特征提取后建立的深度置信网络、支持向量机和BP神经网络状态监测模型,其状态监测的准确率分别为90%、86.25%和77.5%,均低于采用ICA进行特征提取并由此建立相应网络进行状态监测的准确率。

4) 以上验证了该方法的有效性,提高了航空发动机气路系统状态监测的精度,为航空发动机气路系统状态监测提供了新思路。

参 考 文 献

- [1] 潘鹏飞,雷杰,马明明. 基于试飞数据的航空发动机加力瞬态过程模型辨识[J]. 航空科学技术, 2016, 27(5): 27-32.

- PAN Pengfei, LEI Jie, MA Mingming. Identification of aero-engine afterburner transient process based on flight test data[J]. *Aeronautical Science and Technology*, 2016, 27(5): 27-32. (in Chinese)
- [2] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. *控制与决策*, 2011, 26(1): 1-9.
- LI Han, XIAO Deyun. Survey on data driven fault diagnosis methods [J]. *Control and Decision*, 2011, 26(1): 1-9. (in Chinese)
- [3] TIAN X, LIN J, FYFE K R, et al. Gearbox fault diagnosis using independent component analysis in the frequency domain and wavelet filtering[C]// *International Conference on Acoustics, Speech, and Signal Processing*. Hongkong, China: IEEE, 2003: 245-248.
- [4] LI L, QU L S. Machine diagnosis with independent component analysis and envelope analysis[C]// *International Conference on Industrial Technology*. Bangkok, Thailand: IEEE, 2002: 1360-1364.
- [5] BARNARD J P, ALDRICH C. Diagnostic monitoring of internal combustion engines by use of independent component analysis and neural networks[C]// *International Joint Conference on Neural Networks*. Portland, USA: International Neural Network Society, 2003: 869-872.
- [6] 彭喜元, 彭宇, 刘大同. 数据驱动的故障预测[M]. 哈尔滨: 哈尔滨工业大学出版社, 2016: 59-62.
- [7] 逢邈, 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(11): 218-226.
- PANG Shan, YANG Xinyi, ZHANG Yong, et al. Application of deep kernel extreme learning machine in aero engine components fault diagnosis[J]. *Journal of Propulsion Technology*, 2017(11): 218-226. (in Chinese)
- [8] 崔建国, 刘瑶, 于明月, 等. 基于KPCA与模糊积分的燃气轮机状态识别方法[J]. *振动、测试与诊断*, 2018, 38(5): 948-952.
- CUI Jianguo, LIU Yao, YU Mingyue, et al. Gas turbine state recognition based on fuzzy integral technology research[J]. *Journal of Vibration, Measurement & Diagnosis*, 2018, 38(5): 948-952. (in Chinese)
- [9] 柏林, 陆超, 赵鑫. 基于相空间重构和ICA-R的轴承故障特征增强方法[J]. *振动、测试与诊断*, 2016, 36(6): 1097-1102.
- BO Lin, LU Chao, ZHAO Xin. A method of enhancing the fault characteristics in early stage of rolling bearing based on phase-space reconstruction and ICA with reference[J]. *Journal of Vibration, Measurement & Diagnosis*, 2016, 36(6): 1097-1102. (in Chinese)
- [10] 黄立坤. 独立分量分析的重盲分离研究及其在机械故障诊断中的应用[D]. 天津: 天津大学, 2010.
- [11] 顾明亮, 刘俊. 独立主成分ICA在表面肌电信号特征提取中的应用研究[J]. *自动化应用*, 2017(8): 14-16.
- GU Mingliang, LIU Jun. Application of independent principal component ICA in feature extraction of surface EMG signals. [J]. *Automation Application*, 2017(8): 14-16. (in Chinese)
- [12] 周永章, 王俊, 左仁广, 等. 地质领域机器学习、深度学习及实现语言[J]. *岩石学报*, 2018, 34(11): 3173-3178.
- ZHOU Yongzhang, WANG Jun, ZUO Renguang, et al. Machine learning, deep learning and python language in field of geology[J]. *Acta Petrologica Sinica*, 2018, 34(11): 3173-3178. (in Chinese)
- [13] COURVILLE A, BERGSTRA J, BENGIO Y. A spike and slab restricted Boltzmann machine[J]. *Journal of Machine Learning Research-Proceedings Track*, 2011, 15: 233-241.
- [14] 苏志达, 祝跃飞, 刘龙. 基于深度学习的安卓恶意应用检测[J]. *计算机应用*, 2017(6): 1650-1656.
- SU Zhida, ZHU Yuefei, LIU Long. Android malware application detection using deep learning[J]. *Journal of Computer Applications*, 2017(6): 1650-1656. (in Chinese)
- [15] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. *Neural Computation*, 2006, 18(7): 1527-1554.
- [16] 李强. 基于DBN的移动自组织网络入侵检测技术研究[D]. 成都: 电子科技大学, 2015.
- [17] LAROCHELLE H, BENGIO Y, LOURADOUR J, et al. Exploring strategies for training deep neural networks [J]. *Journal of Machine Learning Research*, 2009, 10(6): 1-40.



第一作者简介: 崔建国,男,1963年8月生,教授。主要研究方向为飞行器健康诊断、预测与综合健康管理等。曾发表《基于遗传算法和ARMA模型的航空发动机寿命预测》(《航空学报》2011年第32卷第8期)等论文。

E-mail: gordon_cjg@163.com

