

【航空管理与安全】

基于 EMD-PCA-SVD-CNN 的航空发动机 滚动轴承故障诊断研究

任延涛

(济南大学 自动化与电气工程学院, 山东 济南 250022)

摘要:航空发动机中滚动轴承信号具有非线性和非平稳性的特点,导致故障特征信息难以准确提取及故障类型难以诊断。为此,提出一种基于经验模态分解(EMD)-主成分分析(PCA)-奇异值分解(SVD)-卷积神经网络(CNN)的故障检测方法。首先,通过 EMD 将原始信号分解为本征模态函数分量,提取关键特征;然后,利用 PCA 对特征向量降维,降低冗余信息和计算复杂度;接着,使用 SVD 对降维后的信号进行重构,进一步优化特征表达;最后,将预处理后的信号输入 CNN 中进行学习和分类。在凯斯西储大学轴承数据集上验证了所提方法,实验结果显示,该方法的 F1 分数、召回率以及精确率均高于 99%,且识别准确度达到 99.32%,显著高于其他 5 种对比方法。

关键词:航空发动机;滚动轴承;经验模态分解;奇异值分解;卷积神经网络;故障诊断

中图分类号: TP 277 **文献标识码:** A **DOI:**10.13486/j.issn.2097-4973.2025.02.002

航空发动机是飞行器的核心,其性能和可靠性直接影响飞行安全和经济效益。航空发动机任何故障的发生不仅增加维护成本和停机时间,还可能会引发严重的安全事故^[1-2]。作为关键部件,转子系统中的滚动轴承的健康状态决定发动机的稳定运行^[3]。然而,复杂负载和多变工况导致轴承易出现疲劳、磨损、裂纹等故障^[4-5],使得轴承的故障诊断充满挑战^[6]。

滚动轴承运行过程中产生的信号通常具有非线性和非平稳特性,这增加了故障特征提取的难度。为了有效解决这一问题,Huang 等^[7]提出了基于经验模态分解(Empirical Mode Decomposition,EMD)方法,该法能够将复杂信号分解为若干个不同时间尺度的本征模态函数(Intrinsic Mode Functions,IMF),有效揭示了振动信号中的多尺度特征。张延军等^[8]使用 EMD 与麻雀算法改进的支持向量机相结合的方式对故障进行诊断,显著提高了轴承早期故障诊断的准确率。由于 EMD 可能会产生模态混叠和端点效应问题^[9],仅依赖 EMD 分解得到的 IMF 可能无法直接实现高精度的故障诊断,因此本文引入主成分分析(Principal Components Analysis,PCA)算法来降低数据维度^[10],从而在信号中提取出主要成分。张燕飞等^[11]提出利用 PCA 对 24 维的信息特征矩阵降维,将第一主成分归一化后的向量作为初始证据源,成功应用于故障诊断。汪峰等^[12]提出结合时域分析的 EMD-PCA 方法也在特征提取方面取得较好的结果。尽管 PCA 有效降低了数据维度,但降维后的特征矩阵中仍可能存在微小噪声,因此本文进一步引入奇异值分解(Singular Value Decomposition,SVD),利用其操作便捷、去噪效果好等优点^[13-14],对 PCA 降维后的特征矩阵进行优化,达到消除微小噪声的目的。陈琳等^[15]提出了一种基于奇异值分解和复合平方包络

收稿日期:2024-10-25

作者简介:任延涛(1982—),男,山东济南人,硕士研究生,主要从事飞机系统故障诊断及可靠性研究。

E-mail:59434050@qq.com

谱的滚动轴承诊断方法,该方法在缺少先验知识情况下能够实现有效的轴承故障诊断。随着深度学习技术的发展,越来越多的研究将其应用于复杂工业系统的故障诊断^[16-18]。其中,卷积神经网络(Convolutional Neural Network, CNN)因其卓越的特征提取和分类能力,在故障诊断领域得到了广泛应用。张博文等^[19]提出对一维卷积神经网络进行改进,在传统的卷积层前面增加了 PIRD 的提取层的轴承故障诊断方法。卢一相等^[20]提出一种基于多尺度小波包启发卷积网络的端到端旋转机械故障诊断方法。

为了提升降噪效果,高效提取轴承故障特征信号,本文在以上研究基础上提出一种基于 EMD-PCA-SVD-CNN 的故障诊断方法,该方法通过分层优化,逐步提取和强化故障特征,有效提升了诊断性能。具体而言,原始信号首先通过 EMD 进行分解,重构为新的信号后,采用 PCA 对其进行降维处理,获取降维后的信号。然后,对降维后的信号应用 SVD 进行精细分解,最终将分解优化后的信号输入 CNN 以实现故障类型的识别。

1 基本原理

1.1 经验模态分解

EMD 是一种自适应信号处理方法,可以将复杂信号分解为若干个 IMF 的分量,每一个 IMF 都是一个比原始信号更加简单的分量,分别代表不同尺度的波动成分。假设原始信号为 $x(t)$,利用 EMD 算法分解信号的步骤如下:

步骤 1 确定信号的局部极值,构造包络线。通过极大值点和极小值点分别进行 3 次样条插值,构建信号的上包络线 $e_{\max}(t)$ 和下包络线 $e_{\min}(t)$,分别为 $e_{\max}(t) = \text{Spline}(t_i, x(t_i))$, $e_{\min}(t) = \text{Spline}(t_j, x(t_j))$ 。

步骤 2 计算包络线的平均值,提取信号的细节分量 $m(t) = (e_{\max}(t) + e_{\min}(t))/2$,式中: $m(t)$ 是包络线的平均值。将信号的平均值 $m(t)$ 从原始信号中减去,得到细节分量 $h_1(t) = x(t) - m(t)$ 。这个步骤称为“筛选”,其目的是通过反复地迭代去除信号中的低频趋势,留下一个高频的细节分量。

步骤 3 检查 $h_1(t)$ 是否满足 IMF,需要检查以下两个条件。 $h_1(t)$ 的零交叉点和极值点数量必须相等或相差不超过 1;在信号的整个范围内,局部均值应接近于零。如果满足这两个条件,则认为 $h_1(t)$ 是一个 IMF,否则,将 $h_1(t)$ 作为新信号,重复步骤 1、步骤 2,继续筛选,直到满足 IMF 条件为止。经过多次筛选后,最终可以得到第一个 IMF 分量 $c_1(t)$ 。

步骤 4 从原始信号中减去 IMF,剩余信号 $r_1(t) = x(t) - c_1(t)$ 。

步骤 5 对剩余信号进行分解,得到分解的结果。将剩余信号 $r_1(t)$ 作为新的信号,重复步骤 1~4,继续分解得到更多的 IMF 分量,直到剩余信号 $r_n(t)$ 成为一个单调函数或者剩余信号很小,无法进一步分解。此时,原始信号 $x(t) = \sum_{i=1}^n c_i(t) + r_n(t)$ 。式中: $c_i(t)$ 是第 i 个 IMF 分量, $r_n(t)$ 是最终的残余信号。

EMD 通过反复的筛选过程,将复杂信号分解为若干个 IMF 分量和一个残余信号。

1.2 主成分分析

PCA 是一种经典的降维算法,前提是在保持尽量多的信息下,将高维数据映射到低维空间。PCA 通过构造一组互相正交的主成分,实现了去除冗余、减少噪声的功能,每个主成分对应一条新轴,代表原始数据在该方向的变化。PCA 在降维过程中保留了原始特征之间的主要相关性,使得诊断模型在后续的训练和预测阶段能够更加精准地识别不同类型的故障模式。以下是完整的 PCA 算法步骤。

步骤 1 数据预处理。数据标准化是为了避免不同特征尺度差异的影响,并且保证数据的均值为 0、标准差为 1。公式为 $X_{\text{norm}} = (X - \mu) / \sigma$,式中: X_{norm} 是标准化数据, X 是原始数据, μ 是特征均值, σ 是特征的标准差。

步骤 2 构造特征矩阵。将处理后的信号数据分割成多个窗口,从每个窗口提取多个特征,构造特征矩阵

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mn} \end{bmatrix}。$$

式中： \mathbf{X} 表示特征矩阵，每行代表一个样本，每列代表一个特征。

步骤 3 计算协方差矩阵和主成分分析。协方差矩阵用于度量不同特征之间的线性相关性，公式为 $\mathbf{C} = \frac{1}{(n-1)} \mathbf{X}^T \mathbf{X}$ ，式中： n 是样本数量， \mathbf{C} 为协方差矩阵。对协方差矩阵 \mathbf{C} 进行特征值分解，得到特征值和特征向量，公式为： $\mathbf{C} \mathbf{v}_i = \lambda_i \mathbf{v}_i$ 。式中： λ_i 是第 i 个特征值，对应第 i 个主成分的方差大小； \mathbf{v}_i 是对应的特征向量，定义了主成分方向。

步骤 4 数据降维。确定好主成分个数，就可以将原始数据投影到这些主成分方向上，得到降维后的数据 $Z = X_{\text{norm}} \cdot \mathbf{V}_K$ ，式中： \mathbf{V}_K 是前 K 个特征向量构成的矩阵。

PCA 在滚动轴承振动信号的处理过程中可以用于降噪和降维，但由于滚动轴承故障信号通常具有非线性和非平稳性，PCA 作为信号处理手段还需结合其他算法来进一步提高诊断效果。

1.3 奇异值分解

SVD 是线性代数中的一种矩阵分解技术，它可将一个矩阵分解为两个正交矩阵和一个对角矩阵的乘积，并且可以将信号表示为不同的模式，以分离出主要信号成分和噪声。假设原始信号 $x(t) = \{x_1, x_2, \dots, x_n\}$ ，以下是 SVD 用于分解信号 $x(t)$ 的流程。

步骤 1 信号通常是时间序列，但 SVD 需要对矩阵进行操作，因此首先需要将信号 $x(t)$ 转换为矩阵

$$\mathbf{X} = \begin{bmatrix} x_1 & \cdots & x_m \\ \vdots & & \vdots \\ x_{n-m+1} & \cdots & x_n \end{bmatrix}。$$

式中： n 是嵌入矩阵的行数， m 是嵌入矩阵的列数。

步骤 2 进行 SVD 分解，将矩阵 \mathbf{X} 分解为三个矩阵的乘积， $\mathbf{X} = \mathbf{U} \mathbf{Q} \mathbf{V}^T$ 。式中： \mathbf{U} 是一个 $n \times n$ 的正交矩阵，表示左奇异向量矩阵； \mathbf{V}^T 是一个 $m \times m$ 的正交矩阵，表示右奇异向量矩阵； \mathbf{Q} 是一个 $m \times m$ 的对角矩阵，对角元素是奇异值 σ_i ，表示矩阵 \mathbf{X} 的每个模式的重要性。奇异值越大，表示该模式在信号中的贡献越大，矩阵 $\mathbf{Q} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r)$ 。式中： $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r \geq 0$ 为奇异值， r 为矩阵的秩。

步骤 3 奇异值分析。通过 SVD 分解后的信号可以表示为 $\mathbf{X} = \sum_{i=1}^r \sigma_i \mathbf{u}_i \mathbf{v}_i^T$ 。每个分量 $\sigma_i \mathbf{u}_i \mathbf{v}_i^T$ 对应信号的一个模式，其中， σ_i 决定了这个模式的重要性，然后通过分析奇异值 σ_i ，可以识别出信号的主要成分与噪声成分。

步骤 4 信号重构。信号可以通过选择部分较大的奇异值进行重构，从而突出信号的关键频率分量和特征变化。特定频率或振幅上的异常波动往往反映了信号的关键特征，而 SVD 通过保留重要特征来过滤掉无关的干扰项。假设选取 k 个奇异值进行重构，则信号可以表示为 $\mathbf{X}_k = \sum_{i=1}^k \sigma_i \mathbf{u}_i \mathbf{v}_i^T$ 。

SVD 通过将信号构建为矩阵进行奇异值分解，可以将信号分解为不同的模式，其中每个模式对应不同的频率和振幅成分。

1.4 卷积神经网络

CNN 是一种深度学习模型，可以自动学习并提取信号中的特征，实现高效、准确的分类。以下是 CNN 用于故障信号分类关键层的作用。

1.4.1 卷积层

卷积层是 CNN 的核心，用于从输入数据中提取局部特征，能够学习到故障信号中的特定频率或冲击

特征。通过卷积核对输入信号进行滑动卷积操作,可以生成特征映射。对于一维信号,卷积核 w 的大小为 k_c 。卷积操作可表示为 $y_i = \sum_{j=0}^{k-1} w_j \cdot x_{i+j} + b$ 。式中: y_i 表示卷积输出的第 i 个元素, w_j 表示卷积核权重, x_{i+j} 表示信号局部片段, b 表示偏置项。

1.4.2 池化层

池化层用于对特征映射进行降采样,以减少数据量并保留重要特征,提高计算效率。常用的池化方法是最大池化(Max Pooling),该方法通过提取局部内的最大值来实现数据采样,突出显著特征。最大池化的公式为 $y_i = \max\{x_i, x_{i+1}, \dots, x_{i+k-1}\}$,式中:池化窗口大小为 k_p 。池化层通过减少特征图的大小,降低过拟合风险,并增强特征的平移不变性。

1.4.3 全连接层

在卷积神经网络模型的最后部分,卷积层提取的特征被展平为向量,并输入全连接层。全连接层用于生成故障信号的分类结果。全连接层的数学公式为 $y = W \cdot x + b$ 。式中: W 表示权重矩阵, x 表示展平后的特征向量, b 为偏置向量。卷积神经网络通过卷积、池化、全连接层等多层处理,从滚动轴承故障信号中自动提取特征,使其在信号处理任务中具有优势,并且可以通过优化算法不断提升模型的性能。

2 算法改进

2.1 经验模态分解

经验模态分解是一种自适应信号处理方法,它根据输入信号的特性自动分解,直到无法进一步分解为止。虽然 EMD 通常会生成多个本征模态函数,这些 IMF 可以保留信号的多尺度特征,但直接处理过多的 IMF 分量不仅会增加计算负担,还可能引入冗余特征,降低诊断的准确度。EMD 分解轴承内圈故障信号产生的部分 IMF 如图 1 所示。从图 1 可以发现,故障信号被分解为 10 个 IMF 分量。为量化 IMF 的信息量,引入排列熵(Permutation Entropy, PE)^[21] 算法。排列熵可以有效量化信号的局部复杂性,熵值较高的 IMF 分量通常包含丰富的动态信息,而熵值较低的 IMF 分量则可能主要由噪声或无关信息构成。

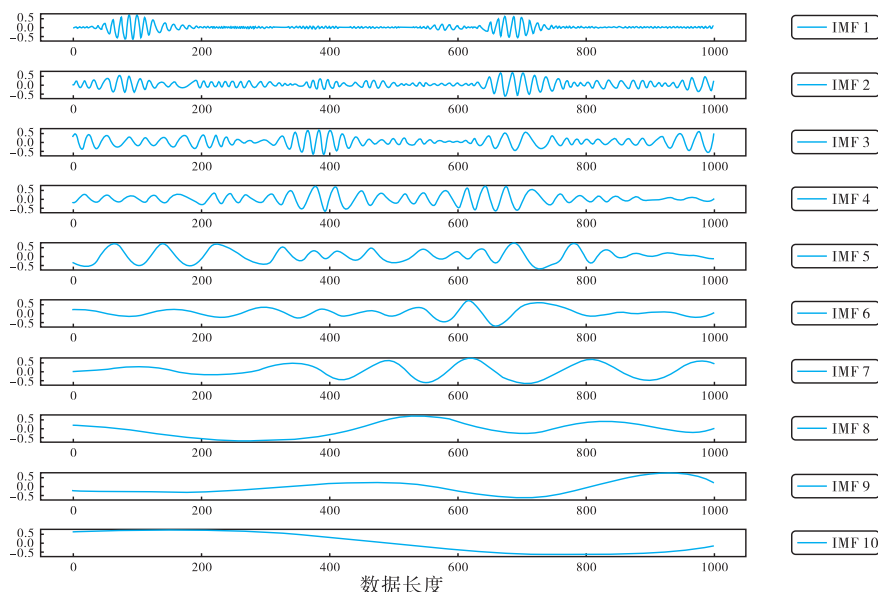


图 1 EMD 分解产生的 IMF

对 10 个 IMF 分量进行排列熵计算,结果如表 1 所示。从表 1 可以发现,IMF 分量的排列熵值呈现逐渐递减的趋势。尤其是前两个 IMF 的熵值明显高于后续分量,表明这两个分量携带了更多的复杂度和信息量,适合作为信号重构的主要成分。而后续分量的熵值变化趋于平稳,表明其主要由噪声或无关成分构成

成,对信号重构的贡献有限。此外,从图 1 中可以看出,IMF1 和 IMF2 分量的波动性最高,频率较高且波长最短;其余 IMF 分量的幅值、频率和波长上逐渐减小。为简化计算并避免引入冗余特征,本文仅选取 IMF1 和 IMF2,并将其组合为一个新的分量输入 PCA 中。该处理不仅减少了冗余特征的引入,还降低了后续 PCA 的计算复杂度。

表 1 各 IMF 的排列熵数值

K	排列熵	K	排列熵	K	排列熵	K	排列熵	K	排列熵
1	0.578 996	3	0.409 651	5	0.339 638	7	0.296 342	9	0.278 496
2	0.464 678	4	0.375 190	6	0.314 723	8	0.285 018	10	0.273 658

2.2 主成分分析

传统的 PCA 需要手动指定主成分个数 K 。若 K 设定过小,可能导致部分重要特征丢失,从而降低重构信号的质量;若 K 设定过大,虽然保留了更多的信息,但是增加了不必要的维度。因此选择合适的 K 对 PCA 至关重要。为确保模型的稳健性和通用性,本文采用累计能量法自动选择合适的 K 。此外,为适应不同工况的需求,本文还引入了动态阈值策略,以提升模型的自适应能力,使其在复杂故障模式下能够更有效地调整,从而提高分类的准确性和鲁棒性。

在 PCA 中,方差解释率(Explained Variance Ratio, EVR)用于衡量单个主成分对数据总方差的贡献,反映该主成分独立解释数据的能力。对于第 i 个主成分,其方差解释率定义为 $E_{VR} = \lambda_i / \sum_{j=1}^d \lambda_j$ 。式中: d 是原始特征的维度, λ_i 表示第 i 个主成分的特征值。 E_{VR} 越高,表明该主成分在总方差中的占比越大。

为判断前 K 个主成分是否可以解释足够多的数据方差,采用累计能量(Cumulative Energy, CE)方法,计算前 K 个主成分的累计方差解释率。前 K 个主成分的累计能量定义为 $C_E = \sum_{i=1}^K \lambda_i / \sum_{j=1}^d \lambda_j$ 。式中: K 是选定的主成分个数, $\sum_{i=1}^K \lambda_i$ 是前 K 个主成分的特征值之和, $\sum_{j=1}^d \lambda_j$ 是所有主成分的特征值之和。

3 实验验证

3.1 数据集介绍

本文采用美国凯斯西储大学公开的轴承数据集,该数据集涵盖了多种故障类型以及不同的工况参数,能够为滚动轴承故障诊断提供有效的训练和测试数据。即使航空发动机中的工作环境更复杂,其故障表现形式更多样化,但该数据集所包含的故障类型与航空发动机滚动轴承的故障特征具有一定的相似性,因此可以作为分析故障诊断算法的轴承数据集。选取该数据集驱动端故障数据,包含滚珠、内圈以及外圈 3 种故障状态,采样频率为 48 kHz,负载条件为 1 HP,故障尺寸直径大小为 0.177 8 mm、0.355 6 mm 与 0.533 4 mm。本文采集的滚动轴承信号具体信息如表 2 所示。

表 2 滚动轴承信号数据

信号类别	故障位置	故障直径/mm	负载/HP	信号类别	故障位置	故障直径/mm	负载/HP
0	正常	0	1	5	滚珠故障	0.355 6	1
1	内圈故障	0.177 8	1	6	外圈故障	0.355 6	1
2	滚珠故障	0.177 8	1	7	内圈故障	0.533 4	1
3	外圈故障	0.177 8	1	8	滚珠故障	0.533 4	1
4	内圈故障	0.355 6	1	9	外圈故障	0.533 4	1

3.2 实验流程

本文故障诊断方法的流程如下:

- 步骤 1 将采集的原始信号数据进行滑动窗口处理,以 1 024 个数据点滑动,形成多个数据样本。
 - 步骤 2 将整理好的信号数据应用 EMD 算法进行预处理,分解为相应的本征模态函数,对其进行重构。
 - 步骤 3 对 EMD 产生的信号数据进行 PCA 降维,结合能量阈值方法来确定 PCA 的 K ,然后对其进行 PCA 处理。
 - 步骤 4 对 PCA 处理后的信号进行 SVD 算法分解与信号重构,去除噪声和无关的分量,提取出关键的特征。
 - 步骤 5 将 SVD 重构后的信号进行训练集和测试集的划分,然后将其输入 CNN 中进行故障分类,识别出故障类型。
- 故障诊断流程如图 2 所示。




图 2 故障诊断流程图

3.3 实验结果

累计能量和重构误差是衡量信号的两个重要指标,分别用于评估信号的降维效果和信
息保留程度,通过动态选择策略,将累计能量达到 99%、重构误差低于 0.01 作为评估指标,自动选择最优 K ,以保证模型的准确性。实验评估指标数值如表 3 所示。

表 3 评估指标

K	累计能量	重构误差	K	累计能量	重构误差
1	0.105 729 005 137 462	0.894 266 523 507 563	6	0.609 983 517 587 367	0.390 014 532 330 220
2	0.208 356 237 152 892	0.791 639 804 628 293	7	0.709 532 156 007 276	0.290 466 391 653 503
3	0.309 300 998 770 979	0.690 695 547 734 014	8	0.807 777 782 309 642	0.192 221 256 579 268
4	0.410 052 186 934 844	0.589 944 863 326 090	9	0.905 322 150 538 189	0.094 677 376 072 564
5	0.510 129 429 499 557	0.489 868 121 147 589	10	1	$1.118\ 990\ 623\ 3 \times 10^{-30}$

在 PCA 降维中, K 的取值上限为数据的特征数,因此,当 $K=10$ 时,与输入数据的 10 个特征一致,累计能量达到 1,表示已保留所有的原始特征信息,没有信息丢失,重构误差也接近 0,因此,继续增加 K 没有实际意义。从表 3 可以看出,当 $K=10$ 时,重构误差已经低于 0.01,满足累计能量和重构误差的双重条件,故本文最终选择 $K=10$ 作为 PCA 降维的最佳维数。评估指标随 K 大小变化曲线见图 3。




图 3 累计能量和重构误差随 K 变化曲线

经过 PCA 处理后的数据,进入 SVD 进行分解和重构,得到信号预处理阶段最终的信号。最终的信号通过使用 EMD、PCA 和 SVD 等方法,可以从原始信号中有效地分离出关键成分。EMD 首先将信号分解为若干模态,然后 PCA 提取主成分,SVD 则进一步降低噪声影响。这些方法共同作用,确保了关键的故障特征在降噪过程中得以保留。后续的分类实验结果表明,模型能够准确识别各类故障信号,且性能指标表现优秀。

将处理过后的信号按照 7 : 3 的比例划分为训练集和测试集,输入卷积神经网络中进行学习和分类。对信号进行分类的结果如图 4 所示。图 4 展示了模型对训练集的数据识别精度达到 100%,测试集的识

别精度达到 99.32%，表明本文所提方法对故障信号具有优秀的分类能力。

混淆矩阵是用于评估分类模型性能的工具，可直观展示预测结果与真实标签之间的对应情况，适用于多分类问题。为了分析不同信号类别的分类表现及误判情况，本文绘制了测试集的混淆矩阵，如图 5 所示。从图 5 可以观察到，测试集包含 585 个样本，其中主要的误判情况包括：信号类别 0 被误判为类别 2、信号类别 2 被误判为类别 8、信号类别 7 被误判为类别 9，误判样本共计 4 个，对应测试集的分类准确率为 99.32%，与模型训练阶段的识别准确率一致。




图 4 训练集和测试集识别准确度




图 5 测试集混淆矩阵

3.4 实验对比

本部分采用识别准确度、精确度、召回率和 F1 分数作为模型性能的评估指标。识别准确率反映了模型在测试集上的分类性能，越高则说明模型的整体预测准确性越好。精确度表示模型预测为故障的样本中，实际为故障的比例。召回率则衡量实际故障样本中，模型能够正确识别的比例。F1 分数是精确度与召回率的调和平均数，它在平衡精确度和召回率方面发挥着重要作用。为验证本文方法的优越性，将其与 5 种方法进行对比，具体结果如表 4 所示。

表 4 6 种方法的评估指标

方法	准确度/%	精确度/%	召回率/%	F1 分数/%
EMD-CNN	94.02	94.14	93.87	93.74
EMD-PCA-CNN	58.97	62.36	58.75	59.32
SVD-CNN	91.11	90.91	90.75	90.76
PCA-SVD-CNN	94.70	94.74	94.68	94.61
EMD-SVD-CNN	84.79	84.63	84.29	84.33
EMD-PCA-SVD-CNN	99.32	99.25	99.31	99.27

由表 4 可以看出，本文提出的 EMD-PCA-SVD-CNN 方法在测试集上达到了 99.32% 的准确度，远高于其他方法，表明该方法在滚动轴承故障信号的识别中具有出色的性能。相比之下，EMD-CNN 方法的准确度为 94.02%，SVD-CNN 为 91.11%，EMD-SVD-CNN 为 84.79%，PCA-SVD-CNN 为 94.70% 而 EMD-PCA-CNN 则仅为 58.97%。这些结果表明，本文方法在准确度上表现出了显著的优势。此外，EMD-PCA-SVD-CNN 方法在精确度、召回率和 F1 分数方面同样表现优异，精确度为 99.25%，召回率为 99.31%，F1 分数为 99.27%，而其他方法的评估指标远低于本文方法。

6 种方法测试集准确度随迭代次数的增加曲线如图 6 所示。由图 6 可以看到，本文提出的方法在整个迭代过程稳定后保持最高的准确度，其曲线明显高于其余 5 种方法，这表明该方法在特征提取和模型分类方面具备




图 6 测试集准确度变化曲线

更优异的性能。综合实验结果,尽管在使用 EMD、PCA 和 SVD 对滚动轴承信号进行降噪和特征提取的过程中可能去除了部分有效信息,但这些信息的去除并未对故障诊断性能产生显著影响,降噪后的信号仍能为分类模型提供充分的关键信息。分类实验结果显示,在准确率、精确率、召回率和 F1 分数指标上,本文的分类模型均表现优异,且混淆矩阵分析进一步验证了模型对各类故障信号的精准识别。因此,在降噪过程中即使丢失了一些有效信息,模型也可以有效地进行故障分类。

4 结论

本文针对航空发动机滚动轴承信号的早期特征提取及诊断问题,提出一种基于 EMD-PCA-SVD-CNN 的故障诊断方法。该方法结合了 EMD、PCA 和 SVD 算法的优势,以多层级数据分解、降维及去噪的方法,有效处理滚动轴承复杂信号并提取出更具代表性的故障特征。通过构建 CNN 分类器,对特征数据实现了高效的故障识别。在实验验证中,本文选取凯斯西储大学滚动轴承数据集作为评估数据集,并与其余 5 种故障诊断方法进行对比分析。实验结果显示,本文所提方法的故障诊断率达到了 99.32%,在识别准确率等多个指标上显著优于对比方法,展现出优越的诊断性能。此外,本文方法通过在早期阶段实现故障信号检测,不仅可以降低维修成本,还能减少因突发故障造成的飞行中断和非计划停机,提升航空运营的安全性和经济效益,具有重要的工程应用价值。

参考文献:

- [1] 林京,张博瑶,张大义,等. 航空燃气涡轮发动机故障诊断研究现状与展望[J]. 航空学报,2022,43(8):7-20.
- [2] ZHANG B, CHEN J, YIN X, et al. Fault diagnosis based on grey relational analysis and synergetic pattern recognition for aero-engine gas-path systems[J]. Proceedings of the institution of mechanical engineers, part G: journal of aerospace engineering, 2019, 233(12): 4598-4605.
- [3] 马艳红,王永锋,公平,等. 航空发动机主轴承接触应力精确仿真计算方法[J]. 航空动力学报,2017,32(8):2000-2008.
- [4] 岳晓晶,刘廷武,李锐. 航空发动机轴承性能试验中磁悬浮电动机失稳现象分析[J]. 轴承,2022(3):86-90.
- [5] 贾艳秋,张兵,陈雪梅. 滚动轴承的故障机理及诊断[J]. 化工装备技术,2011,32(4):55-57.
- [6] 赵俊豪,沙云东,栾孝驰,等. 基于振动与滑油信息决策融合的航空发动机主轴承状态监控方法[J]. 装备环境工程,2024,21(9):34-41.
- [7] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the royal society of london. series A: mathematical, physical and engineering sciences, 1998, 454(1971): 903-995.
- [8] 张延军,杨博. 基于 EMD 与 SSA-SVM 的轴承故障诊断[J]. 组合机床与自动化加工技术,2023(8): 113-117.
- [9] XIANG L, HU A J. Comparison of methods for different time-frequency analysis of vibration signal [J]. Journal of software, 2012, 7(1): 68-74.
- [10] ZHU J, HU T, JIANG B, et al. Intelligent bearing fault diagnosis using PCA-DBN framework[J]. Neural computing and applications, 2020, 32(14): 10773-10781.
- [11] 张燕飞,李赞豪,王东峰,等. 基于多源信息融合的滚动轴承故障监测方法[J]. 轴承,2022(12):59-65.
- [12] 汪峰,周凤星,严保康. 基于特征量融合和支持向量机的滚动轴承故障诊断[J]. 科学技术与工程, 2022, 22(6): 2351-2356.
- [13] 葛兴来,邹丹. 多层降噪技术及 Hilbert 变换的轴承故障诊断方法[J]. 电机与控制学报,2020,24(8):9-17.

- [14] 李辉,范智超,李华,等. 基于 SVD 和 DBN 的水电机组故障诊断[J]. 水力发电学报,2020,39(12):104-112.
- [15] 陈琳,陶涛,李洪强. SVD 和复合平方包络谱的滚动轴承故障诊断[J]. 机械设计与制造,2024(3):297-304.
- [16] LI X, YANG Y, PAN H, et al. A novel deep stacking least squares support vector machine for rolling bearing fault diagnosis[J]. Computers in industry,2019,110:36-47.
- [17] WU Y, ZHAO R, JIN W, et al. Intelligent fault diagnosis of rolling bearings using a semi-supervised convolutional neural network[J]. Applied intelligence,2021,51(4):2144-2160.
- [18] ZHU Z, LEI Y, QI G, et al. A review of the application of deep learning in intelligent fault diagnosis of rotating machinery[J]. Measurement,2023,206:112346.
- [19] 张博文,庞新宇,程宝安,等. 基于 PIRD-CNN 的航空发动机轴承故障诊断方法研究[J]. 振动与冲击,2024,43(18):201-207.
- [20] 卢一相,钱冬生,竺德,等. 基于多尺度小波包启发卷积网络的旋转机械故障诊断[J]. 振动与冲击,2024,43(17):203-213.
- [21] BANDT C, POMPE B. Permutation entropy: a natural complexity measure for time series[J]. Physical review letters,2002,88(17):174102.

Fault diagnosis of rolling bearings in aero-engines based on EMD-PCA-SVD-CNN

REN Yantao

(School of Electrical Engineering, University of Jinan, Jinan 250022, China)

Abstract: The rolling bearing signals in aero-engines exhibit nonlinear and non-stationary characteristics, making it challenging to accurately extract fault feature information and diagnose fault types. To address these issues, this paper proposes a fault detection method based on empirical mode decomposition (EMD), principal component analysis (PCA), singular value decomposition (SVD), and convolutional neural networks (CNN). First, EMD is applied to decompose the raw signals into intrinsic mode functions (IMFs) to extract key features. PCA is then employed to reduce the dimensionality of the feature vectors, minimizing redundant information and computational complexity. SVD is used to reconstruct the dimensionally-reduced signals, further optimizing feature representation. Finally, the preprocessed signals are fed into a CNN for learning and classification. The proposed method is validated on the Case Western Reserve University (CWRU) bearing dataset. Experimental results demonstrate that the F1 score, recall, and precision of the method all exceed 99%, with an accuracy of 99.32%, significantly outperforming five other comparative methods. These results highlight the superior performance of the proposed method in fault classification and its potential value for fault detection applications.

Keywords: aero-engine rolling bearings; empirical mode decomposition; singular value decomposition; convolutional neural network; fault diagnosis

(责任编辑:唐立平)

引用格式 任延涛. 基于 EMD-PCA-SVD-CNN 的航空发动机滚动轴承故障诊断研究[J]. 山东航空学院学报,2025,42(2):9-17.

REN Y T. Fault diagnosis of rolling bearings in aero-engines based on EMD-PCA-SVD-CNN[J]. Journal of Shandong University of Aeronautics,2025,42(2):9-17.