【航空电子电气工程】

# 基于 CWT-CNN-LSTM 的滚动轴承的故障诊断方法研究

陈　鑫,袁　伟,刘　松,苗　飞,沈　涛,韩祥泽

(山东航空学院 飞行学院,山东 滨州 256603)

**摘　要**:针对航空发动机转子系统中滚动轴承故障诊断面临的故障特征提取不足及传统算法准确率不高的问题,提出了一种结合连续小波变换(CWT)和卷积神经网络(CNN)内嵌长短期记忆网络(LSTM)的滚动轴承故障诊断方法。具体而言,通过 CWT 对原始振动信号进行处理,生成二维时频图,并将其转化为单通道灰度图,输入 CNN-LSTM 深度学习模型中进行故障识别与分类。实验结果表明,此方法在凯斯西储大学轴承数据集上的平均故障识别准确率达到 99.615%,显著优于其他 7 种对比模型。此外,该方法的故障识别分类准确率方差仅为 0.003 68,充分验证了其在滚动轴承故障识别与分类中的高稳定性和有效性。

**关键词**:连续小波变化;卷积神经网络;长短期记忆网络;滚动轴承;故障诊断

**中图分类号**: TP 277　　**文献标识码**: A　　DOI:10.13486/j.issn.2097-4973.2024.03.001

## 0　引言

在航空发动机中,转子系统是核心部件之一,负责承载高转速任务,并在极端条件下保持稳定运转。滚动轴承作为转子系统中的关键组成部分,直接影响发动机的运转稳定性和工作效率[1]。滚动轴承在高温、高转速和重载荷环境中长期运行,难以避免出现性能退化,进而引发各种故障。这些故障不仅会导致航空发动机的失效,还可能引发严重的安全事故,造成巨大的经济损失[2-3]。因此,航空发动机滚动轴承故障的精确诊断在工程应用中具有重要的现实意义和不可替代的作用。

滚动轴承缺陷会导致旋转机械设备处于一种非正常的运行状态,将产生一系列振动冲击和冲击衰减响应,采集到的滚动轴承振动信号也会因此表现出某种程度的非平稳性和周期性冲击特征[4]。早期的滚动轴承故障检测主要依赖于对故障设备异常振动信号的分析,结合各部件的理论故障频率及相关先验知识,进行故障诊断与分析[5],诊断结果易受人为经验影响,且难以应对复杂工况和多故障类型的场景。因此,各类故障信号处理方法相继提出,包括谱峭度[6]和经验模态分解(EMD)[7]、连续小波变换(CWT)[8]等方法。其中,CWT 在滚动轴承故障诊断中展现出显著优势,能够通过多尺度分析灵活捕捉信号特征,相较于谱峭度更为精确,且优于 EMD。同时,CWT 具备高时频分辨率和强抗噪能力,有效避免了 EMD 的

**收稿日期**:2024-06-30

**基金项目**:山东省自然科学基金项目(ZR2022MF350)

**第一作者简介**:陈　鑫(2000—　),男,重庆垫江人,硕士研究生,主要从事航空载运工具运用工程技术研究。E-mail:chen.0529@foxmail.com

**通信作者简介**:袁　伟(1982—　),男,山东滨州人,副教授,博士,硕士生导师,从事航空载运工具运用工程技术研究。E-mail:yuanweisohu@163.com

模态混叠和端点效应。李阳等[9]通过 CWT、尺度-能量谱统计及快速傅立叶变换识别故障特征频率，并针对微弱内圈故障采用共振解调与 Hilbert 包络提取，实现了强噪声背景下的高精度故障检测。张锐戈等[10]对振动信号进行 CWT 并划分小波系数子列，利用特征值作为特征参数，结合最小香农熵准则和奇异值分解技术优化参数，最终采用连续型隐马尔可夫模型实现轴承高精度故障检测。

近年来，随着人工智能技术的不断发展，深度学习已经被广泛应用于大数据处理的多个领域，也逐步成为故障诊断领域的主流技术[11]，包括深度置信网络[12]、稀疏自编码器[13]、随机森林[14]和卷积神经网络(CNN)[15]等方法。其中 CNN 能够自动提取和学习故障信号的特征，对输入数据(例如振动信号、图像等)进行分类，从而实现滚动轴承故障诊断的高准确度[16]。相较于上述其他神经网络模型，CNN 凭借其多层结构，能够有效学习从低级到高级的特征表示，显著提升了复杂故障模式的识别能力。此外，CNN 还展现出更强的平移不变性，使其在面临噪声和干扰时具备更高的稳定性。这些特性使得 CNN 在滚动轴承故障诊断领域成为一种更为有效且可靠的解决方法。谷玉海等[17]通过 EMD 获取频谱图，并将频谱图压缩成特征二值化图像输入 CNN 分类网络中，从而实现对各类故障进行分类识别。宋乾坤等[18]通过 CWT 生成时频图，并用三次垂直方向随机裁剪的方法补充数据集，最后通过 CNN 分类网络实现了较高精确率的故障分类识别。

文献[17-18]通过不同的信号处理方法提取故障特征，并将其输入 CNN 分类网络，成功实现了滚动轴承故障识别分类，取得了一定的研究成果。然而，单一的 CNN 模型在处理过程中忽略了时间序列数据中潜在的长期依赖关系，这可能会导致关键信息的丢失。为了捕捉时间序列的长期时序特征，本研究考虑引入长短期记忆网络(LSTM)[19]模型，LSTM 作为循环神经网络(RNN)[20]的一种变种模型，在处理大规模数据集时展现出比门控循环单元(GRU)[21]更卓越的性能，且在模型的收敛速度和运算时间方面相较于双向循环神经网络(BiRNN)[22]也更为出色。张建付等[23]利用小波包变换技术提取振动数据各频带的能量信息，再将提取的能量信息作为特征向量输入 LSTM 网络中，最后成功实现了对风电机组滚动轴承故障分类。

基于上述分析，本文提出利用 CWT 对滚动轴承原始信号进行故障特征提取，生成对应的二维时频图，转化为单通道的灰度图后输入卷积神经 CNN-LSTM 深度学习模型中，充分利用 CNN 的特征提取能力与 LSTM 对时间序列数据的长期依赖建模能力，从而提高滚动轴承故障诊断的准确性和稳定性，最后通过对比实验验证所提方法的优越性。

## 1 基本原理

### 1.1 连续小波变换

连续小波变换是一种作用于时域和频域上同时分析信号的方法，通过使用不同尺度和位置的小波函数对信号进行变换，获取信号在不同频率和时间上的局部特征，常用于处理非平稳信号。

对于任意信号 $x(t)$，CWT[24]表达式为

$$W_{\varphi}(a,b)=[x(t),\varphi_{a,b}(t)]=\frac{1}{\sqrt{a}}\int_{-\infty}^{\infty}x(t)\varphi(\frac{t-b}{a})\mathrm{d}t。$$

式中：$\varphi_{a,b}(t)$是小波基函数，由母小波函数 $\varphi(t)$位移和伸缩产生，表达式为

$$\varphi_{a,b}(t)=\frac{1}{\sqrt{a}}\varphi(\frac{t-b}{a})。$$

式中：$a>0$，$a,b\in\mathbf{R}$，$a$ 是尺度因子，控制小波窗的大小和在频域中的位置；$b$ 是位移因子，控制小波窗在时域中的位置。

母小波函数的选择是进行连续小波变换的关键。常用的母小波函数包括 Haar、Meyer、Coiflet 和 Morlet。由于 Morlet 函数同时具有高时间分辨率和高频率分辨率，能够精确捕捉信号中的瞬态和周期性

变化,并且其特性与轴承缺陷产生的冲击特征相匹配,因此本研究选用 Morlet 函数进行连续小波变换[25]。Morlet 小波的函数表达式为[26]

$$\varphi(t)=\pi^{-1/4}\mathrm{e}^{i\omega_0 t}\mathrm{e}^{-t^2/2}。$$

式中:$t$ 为无量纲时间,$\omega_0$ 为无量纲频率。

### 1.2　卷积神经网络

卷积神经网络是一种具有局部连接、权重共享等特征的深层前馈神经网络[27]。CNN 的结构包括输入层、卷积层、池化层、全连接层和输出层,这种组合可以让 CNN 适应不同的图像任务,并且可以建立深度网络来提取更高层次的特征,实现更高效的特征提取和分类[25]。

卷积层由若干个卷积核累积而成,用于提取输入数据的局部特征。其主要操作是用滤波器(卷积核)在输入数据上滑动,计算点积以产生特征图。二维卷积的运算公式为

$$(I*K)(i,j)=\sum_m\sum_n I(m,n)\cdot K(i-m,j-n)。$$

式中:$I$ 是输入图像,$K$ 是卷积核。

池化层又称下采样层,其用来处理经过卷积操作之后的特征图数据,减少特征图的尺寸,降低网络参数以及计算量。常用的池化方法为最大池化层和平均池化层,最大池化通过取池化窗口中的最大值来对特征进行降采样,保留图像中的显著特征,故本文采用的池化层为最大池化层,公式为

$$y=\max(x_1,x_2,\cdots,x_n)。$$

全连接层通常位于 CNN 的尾部,其主要作用是将提取到的数据进行分类[28]。最后一层卷积层将特征图转化为一维数组,将其作为全连接层输入,接着全连接层的输出被送入非线性激活函数中处理,使网络能够学习更复杂的模式。

### 1.3　长短期记忆网络

长短期记忆网络是一种特殊的循环神经网络,用于处理和预测序列数据中的长期依赖关系,旨在解决传统 RNN 在训练时遇到的梯度消失和梯度爆炸问题,从而更有效地捕捉长距离依赖[29]。LSTM 的主要组成部分和工作原理如下。

记忆单元是 LSTM 的核心,它负责存储和传递长期信息。记忆单元通过门控机制来更新和维护其状态,从而保持重要的信息并丢弃不重要的信息。

遗忘门决定了记忆单元中哪些信息需要被遗忘。它的输入包括当前时间步的输入和上一时间步的隐藏状态。遗忘门使用 Sigmoid 激活函数输出一个 0～1 的值,表示每个信息的重要性,0 表示完全丢弃,1 表示完全保留。遗忘门输出

$$f_t=\sigma(W_f\cdot[h_{t-1},x_t]+b_f)。$$

式中:$\sigma$ 是 Sigmoid 激活函数,$W_f$ 是权重矩阵,$b_f$ 是偏置项,$h_{t-1}$ 是上一时间步的隐藏状态,$x_t$ 是当前时间步的输入。

输入门控制了新信息如何被添加到记忆单元中,它有两个部分:一个是 Sigmoid 激活函数用于决定哪些信息需要更新,另一个是 tanh 激活函数用于生成新的候选值,供记忆单元更新使用。输入门输出与新候选记忆单元状态分别为

$$i_t=\sigma(W_i\cdot[h_{t-1},x_t]+b_i),\widetilde{C}_t=\tanh(W_C\cdot[h_{t-1},x_t]+b_C)。$$

式中:$W_i$ 和 $W_C$ 是权重矩阵,$b_i$ 和 $b_C$ 是偏置项。

输出门决定了记忆单元中哪些信息会影响当前时间步的输出。它的输入包括当前时间步的输入和上一时间步的隐藏状态。输出门通过 Sigmoid 激活函数控制信息的传递,同时通过 tanh 激活函数调整记忆单元的状态,生成最终的隐藏状态。输出门输出与当前时间步隐藏状态分别为

$$o_t=\sigma(W_o\cdot[h_{t-1},x_t]+b_o),h_t=o_t\cdot\tanh(C_t)。$$

式中:$W_o$ 是权重矩阵,$b_o$ 是偏置项,$C_t$ 是记忆单元的状态。

## 2 滚动轴承故障诊断流程

滚动轴承故障诊断流程如图 1 所示,主要步骤如下。

(1) 采集数据:采集包含 10 种不同类型的滚动轴承故障的原始振动信号数据。

(2) 数据预处理:对这 10 种滚动轴承故障的数据进行 CWT,生成对应的时频图数据集。

(3) 数据划分:将生成的时频图数据集按照预定比例划分为训练集、验证集和测试集。

(4) 模型训练:使用训练集数据对 CNN-LSTM 模型进行训练,通过验证集进行模型的中期验证,并在每次迭代中优化模型,最终保存性能最优模型的相关超参数。

(5) 模型评估:加载保存的最佳模型,利用测试集进行最终验证,并输出滚动轴承振动信号的故障类型。

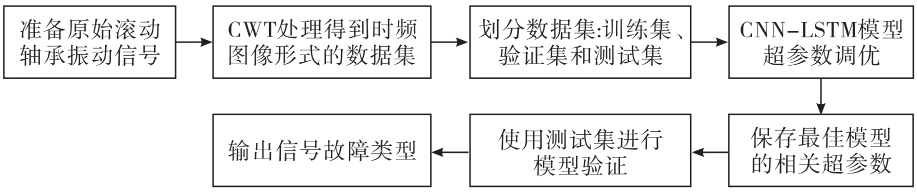


**图 1 CWT-CNN-LSTM 处理滚动轴承故障诊断流程图**

## 3 实验验证与结果分析

### 3.1 数据集选择与处理

本文使用美国凯斯西储大学(Case Western Reserve University,CWRU)提供的轴承数据集[30]作为数据来源,选用驱动端轴承故障数据进行验证,采样频率为 12 kHz,转速为 1 797 r/min,电机负载为 0。

为增加数据集的样本量,对原始振动信号采用滑动窗口进行采样处理。窗口大小设定为 784,滑动步长为 150。在该配置下,每种轴承状态类型的数据生成 120 个样本,总计生成 1 200 个样本。CWRU 滚动轴承数据集描述如表 1 所示。

**表 1 CWRU 滚动轴承数据集描述**

| 故障类型 | 故障直径/mm | 样本数 | 故障类型 | 故障直径/mm | 样本数 |
|---|---|---|---|---|---|
| 内圈故障 | 0.177 8 | 120 | 滚动体故障 | 0.177 8 | 120 |
| | 0.355 6 | 120 | | 0.355 6 | 120 |
| | 0.533 4 | 120 | | 0.533 4 | 120 |
| 外圈故障 | 0.177 8 | 120 | 正常 | 0 | 120 |
| | 0.355 6 | 120 | | | |
| | 0.533 4 | 120 | | | |

使用 Morlet 函数对上述生成的数据样本进行连续小波变换,得到尺寸为 128×128 的时频图像数据集,打乱图片顺序,再按照 6∶2∶2 的比例划分训练集、验证集和测试集,分别根据对应的运行状态进行相应的命名和保存。使用 python 的 Matplotlib 作图库,得到正常状态和故障状态下的滚动轴承时频图,如图 2 所示。从图中可以看出,滚动轴承在滚动体故障时,时频图中显示出明显浅色亮斑,分布在时频图的中上部分,表明滚动体故障引起的振动信号较强。滚动轴承在内圈故障时,时频图中显示出相对集中的浅色亮斑,且分布比较集中,表明内圈故障引起的振动信号较强且集中在某些频段。滚动轴承在正常状态下,整体呈现出比较平滑的深色背景,只有底部出现少量浅色亮斑,表明正常状态下滚动轴承的振动信号较弱且分布均匀,没有明显的高频成分。说明使用 CWT 可以提取到滚动轴承在不同状态下的一般特征

规律并显示在时频图中。

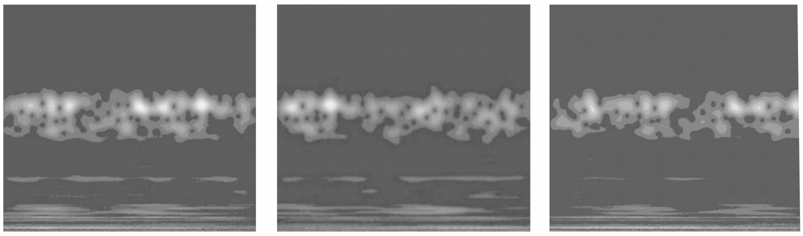

(a) 滚动体故障(故障直径 0.177 8 mm)

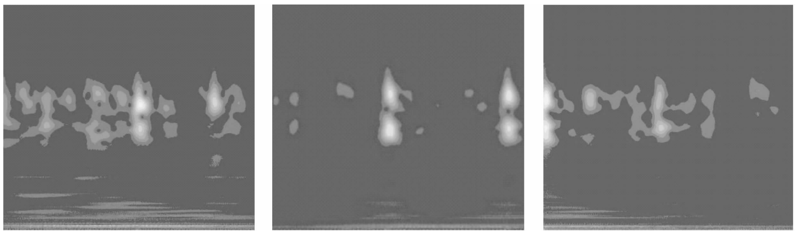

(b) 内圈故障(故障直径 0.355 6 mm)

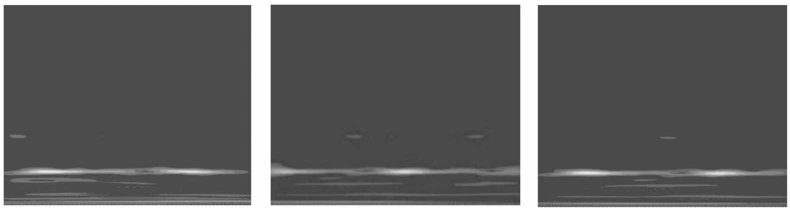

(c)正常状态

图 2　连续小波变换处理结果

### 3.2　CNN-LSTM 模型设计

在 CNN-LSTM 模型训练过程中的相关参数设置如下:迭代次数设置为 100,批次大小设置为 32,初始学习率设置为 0.001,激活函数选用 ReLU 函数,损失函数选用交叉熵函数,网络优化器选用 Adam 优化器,随机失活层设置为 0.6,池化层选用最大池化,感知器函数选用 Softmax 函数。CNN-LSTM 模型整体结构如图 3 所示,其中 CNN 中包括 5 个卷积层、5 个池化层和 5 个批归一化层,LSTM 中有 2 层 LSTM 单元,全连接层为 1 层。具体的内部参数为:卷积层使用 3×3 的卷积核,步幅为 1,填充 1 个像素,激活函数选用 ReLU 函数;批归一化层通道数分别为 16、32、64、64 和 128;池化层使用 2×2 的卷积核,步幅为 2;LSTM 层中隐藏层单元数分别为 245 和 64;全连接层输入维度为 64,输出维度为 10。

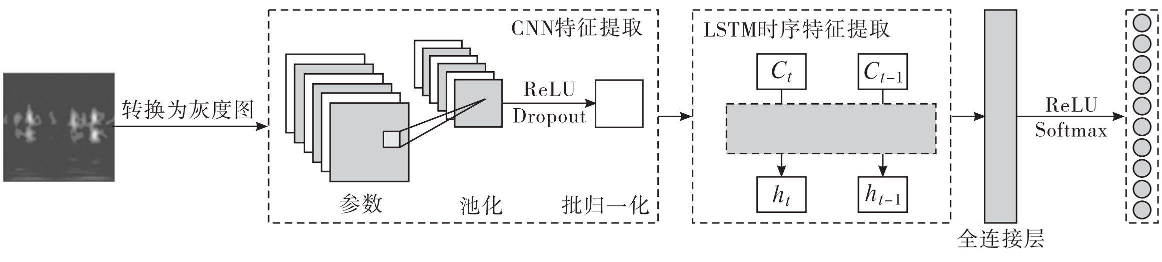


图 3　CNN-LSTM 模型整体结构

### 3.3　实验结果分析

将经过 CWT 处理后的时频图数据集送入 CNN-LSTM 模型中训练,训练集每一次迭代调整超参数后,使用验证集对当前的模型进行验证,模型训练过程中训练集和验证集的准确率曲线和损失曲线如图 4 所示。从图 4 中可以明显看出,随着迭代次数的不断增加,训练集和验证集损失函数逐渐减少并趋于稳定

的，模型经过大约 20 次的迭代，开始收敛。当迭代到 40 次以后，本模型对于训练集和验证集的检测准确度均可达到 100%，说明该模型未出现明显的过拟合或欠拟合问题，模型训练完成后保存最佳模型相关的超参数，用于之后的测试集验证。

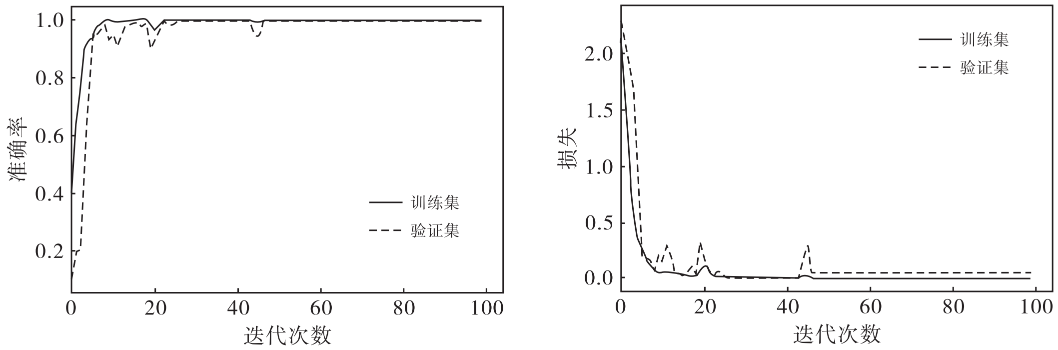


(a) 准确率曲线　　(b) 损失曲线

**图 4　模型训练过程中的准确率曲线和损失曲线**

使用测试集数据验证，CNN-LSTM 模型加载模型训练过程中保存的最佳模型的相关超参数，最终的分类准确率以混淆矩阵的形式展示，可以直观地观察模型在各个类别上的分类性能以及误分类情况，如图 5 所示。从图 5 可以看出，该模型的预测结果绝大多数与真实标签一致，唯一的误分类出现在标签为 0 的样本中，24 个标签为 0 的样本中，仅有 1 个被错误分类为类别 7，此时，模型的检测准确率高达 99.58%，与训练阶段所达到的最终精度基本相符，这充分证明了模型在检测性能上的优越性。综合实验结果，可以得出结论：该模型在滚动轴承故障识别分类任务中表现卓越，具有较高的分类准确率，并能有效区分不同的故障状态。

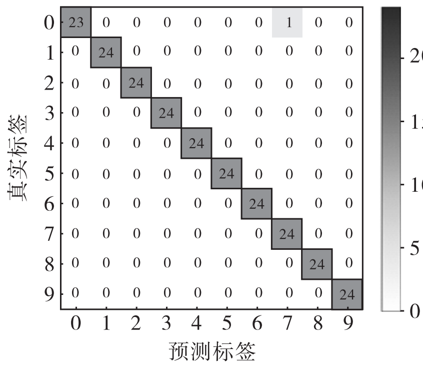


**图 5　验证集混淆矩阵**

## 3.4　实验对比分析

为了充分体现本文模型在滚动轴承故障诊断分类中的优势，将其与其他几种常见的模型进行对比。为了保证对比的公平性，以下模型均使用相同的数据集进行模型训练和检测，故障识别分类数量均为 10，同时神经网络模型在与本文的相关参数设置相同的前提下，进行了优化调试，以达到各自的最佳检测准确率，得到不同模型准确率曲线和损失曲线对比，如图 6 所示。

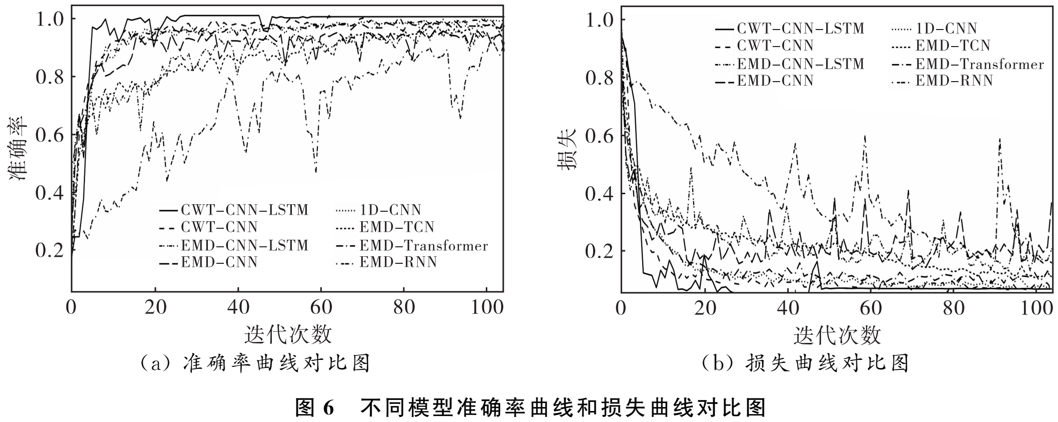


(a) 准确率曲线对比图　　(b) 损失曲线对比图

**图 6　不同模型准确率曲线和损失曲线对比图**

从图 6 可以看出，CWT-CNN-LSTM 模型相比于其他模型在较短的训练迭代次数内达到了更高的检

测准确率。该模型的损失函数收敛速度显著优于其他7种对比模型，表现出较快的优化效果。随着所有模型逐渐收敛，本文模型的准确率曲线和损失函数曲线波动最小，表明其在性能上不仅具备更高的准确率，还拥有更强的稳定性。这一结果表明，相较于CWT-CNN、EMD-CNN-LSTM、EMD-CNN、1D-CNN、EMD-TCN、EMD-Transformer以及EMD-RNN 7种对比模型，本文模型在滚动轴承故障检测任务中展现出更为卓越的性能。无论是在训练早期的收敛速度，还是后期的稳定性，本文模型都具备显著优势，能够更好地适应复杂的滚动轴承的故障分类任务。

在完成模型训练后，利用保存的最佳模型对测试集进行最终验证。每种模型均重复实验4次，记录本文模型与其他7种对比模型的分类准确率，详细结果如表2所示。通过对比分析可以看出，CWT-CNN-LSTM模型在故障识别分类任务中的平均准确率显著高于其他模型，达到了99.615%，在所有模型中表现最佳。此外，本文模型的方差最小，仅为0.003 68，表明其在多次实验中的结果波动极小，具有较高的稳定性。这一结果进一步证实了本文模型在滚动轴承故障检测任务中不仅拥有卓越的分类性能，还在稳定性方面超越其他7种对比模型。

**表2　不同滚动轴承故障诊断模型对比**

| 模型 | 准确率/% | | | | | 方差 |
|---|---|---|---|---|---|---|
| | 第1次 | 第2次 | 第3次 | 第4次 | 平均值 | |
| CWT-CNN-LSTM | 99.58 | 99.72 | 99.58 | 99.58 | 99.615 | 0.003 68 |
| 1D-CNN | 98.33 | 99.17 | 99.11 | 99.11 | 98.930 | 0.120 60 |
| EMD-CNN | 94.42 | 95.54 | 94.42 | 89.29 | 93.417 | 5.885 00 |
| CWT-CNN | 99.17 | 98.33 | 99.17 | 98.75 | 98.855 | 0.121 27 |
| EMD-CNN-LSTM | 94.64 | 93.30 | 91.74 | 91.96 | 92.910 | 1.354 10 |
| EMD-TCN | 89.73 | 88.39 | 91.52 | 86.61 | 89.062 | 3.491 17 |
| EMD-Transformer | 92.86 | 94.20 | 93.30 | 95.98 | 94.085 | 1.430 52 |
| EMD-RNN | 96.43 | 91.96 | 91.52 | 91.07 | 92.745 | 4.628 03 |

## 4　结语

为了解决航空发动机转子系统中滚动轴承故障识别与分类问题，本文提出了一种创新的方法，结合CWT与CNN内嵌LSTM的滚动轴承故障诊断方法。该方法通过CWT对原始振动信号进行处理，生成二维时频图，并将其转换为单通道灰度图，随后输入CNN-LSTM深度学习模型中以进行故障识别与分类。实验结果表明：本文方法有效解决了传统算法中故障特征提取不足与准确率偏低等问题；在凯斯西储大学轴承数据集上的平均故障识别准确率达到99.615%，优于其他7种对比模型；此外，本文方法的故障识别分类准确率方差仅为0.003 68，低于其他7种对比模型，显示了本文方法的高稳定性。

## 参考文献：

[1]　康玉祥，陈果，盛嘉玖，等. 低转速航空发动机滚动轴承故障深度异常检测方法[J]. 振动与冲击，2024，43(7)：186-195.

[2]　黄磊，马圣. 基于IGRSSA与IPSO-SVM的滚动轴承故障诊断方法[J]. 轴承，2021(10)：60-66.

[3]　杨云博，宁芊. 基于特征融合与IAFSA-SVM的滚动轴承故障诊断方法[J]. 轴承，2020(8)：56-62.

[4]　杨岗，徐五一，邓琴，等. 基于振动信号的滚动轴承复合故障诊断研究综述[J]. 西华大学学报(自然科学版)，2024，43(1)：48-69.

[5] 华金榜，杨文军，程志材，等. 基于改进 Alexnet 模型的滚动轴承故障诊断方法[J]. 农业装备与车辆工程，2024，63(8)：1-10.

[6] ANTONI J. Fast computation of the kurtogram for the detection of transient faults[J]. Mechanical systems and signal processing，2007，21(1)：108-124.

[7] 张健，张子阳，起雪梅，等. 基于 EMD 和 VPMCD 的滚动轴承故障诊断[J]. 机械设计，2019，36(S2)：91-94.

[8] KANKAR P K，SHARMA S C，HARSHA S P. Fault diagnosis of ball bearings using continuous wavelet transform[J]. Applied soft computing，2010，11(1)：2300-2312.

[9] 李阳，郭瑜，毕新强，等. 连续小波变换的滚动轴承故障诊断[J]. 机械与电子，2009(5)：46-49.

[10] 张锐戈，谭永红. 基于最优 Morlet 小波和隐马尔可夫模型的轴承故障诊断[J]. 振动与冲击，2012，31(12)：5-8.

[11] 龚俊，张月义，陈思戢，等. 基于 SWT 与改进卷积神经网络的轴承故障诊断[J]. 现代电子技术，2024，47(6)：68-74.

[12] CHEN Z，LI W. Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network[J]. IEEE transactions on instrumentation and measurement，2017，66(7)：1693-1702.

[13] 汤芳，刘义伦，龙慧. 稀疏自编码深度神经网络及其在滚动轴承故障诊断中的应用[J]. 机械科学与技术，2018，37(3)：352-357.

[14] 杜小磊，陈志刚，张楠，等. 基于小波和深度小波自编码器的轴承故障诊断[J]. 机械传动，2019，43(9)：103-108.

[15] MUSTAFA A. Experimental analysis of artificial neural networks used for function approximation[J]. International journal of computer science and network security，2019，19(9)：82-90.

[16] SRINIVAS S，BABU R. Deep learning in neural networks：an overview[J]. Neural networks，2015，61：85-117.

[17] 谷玉海，朱腾腾，饶文军，等. 基于 EMD 二值化图像和 CNN 的滚动轴承故障诊断[J]. 振动测试与诊断，2021，41(1)：105-113.

[18] 宋乾坤，周孟然. 基于 CWT-CNN 的滚动轴承故障诊断[J]. 重庆工商大学学报(自然科学版)，2023，40(3)：42-47.

[19] LEI J，LIU C，JIANG D. Fault diagnosis of wind turbine based on long short-term memory networks[J]. Renewable energy，2019，133：422-432.

[20] ELMAN J L. Finding structure in time[J]. Cognitive science，1990，14(2)：179-211.

[21] CHUNG J，GULCEHRE C，CHO K H，et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[J]. Eprint arXiv，2014：1412. 3555.

[22] LI W，NIE W，SU Y. Human action recognition based on selected spatio-temporal features via bidirectional LSTM[J]. IEEE access，2018，6：44211-44220.

[23] 张建付，宋雨，李刚，等. 基于长短时记忆神经网络的风电机组滚动轴承故障诊断方法[J]. 计算机测量与控制，2017，25(1)：16-19.

[24] SADOWSKY J. The continuous wavelet transform：a tool for signal investigation and understanding[J]. Johns hopkins APL technical digest，1994，15(4)：306-318.

[25] 李飞龙，和伟辉，刘立芳，等. 结合 CWT 和 LightweightNet 的滚动轴承实时故障诊断方法[J]. 智能系统学报，2023，18(3)：496-505.

[26] 刘俊利，缪炳荣，张盈，等. 基于 Morlet 小波与 CART 决策树的滚动轴承故障诊断方法[J]. 机械强度，2024，46(1)：1-8.

[27] LECUN L，BOTTOU Y，BENGIO P H. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE，1998，86(11)：2278-2324.

[28] 潘宏刚，李员禄，郭宝仁，等. 基于卷积神经网络的转子系统故障诊断与研究[J]. 汽轮机技术，2024，66(2)：145-148.

[29] YU Y，SI X，HU C，et al. A review of recurrent neural networks：LSTM cells and network architectures[J]. Neural computation，2019，31(7)：1235-1270.

[30] SMITH W A，RANDAL R B. Rolling element bearing diagnostics using the Case Western Reserve University data：a benchmark study[J]. Mechanical systems and signal processing，2015(64/65)：100-131.

# Research on Rolling Bearing Fault Diagnosis Method Based on CWT-CNN-LSTM

CHEN Xin，YUAN Wei，LIU Song，MIAO Fei，SHEN Tao，HAN Xiangze

(*Flight College*，*Shandong University of Aeronautics*，*Binzhou* 256603，*China*)

**Abstract**：To address the challenges of insufficient fault feature extraction and low accuracy of traditional algorithms in rolling bearing fault diagnosis for aerospace engine rotor systems，this paper proposes a rolling bearing fault diagnosis method that combines continuous wavelet transform (CWT) with convolutional neural networks (CNN) embedded with long short-term memory networks (LSTM). Specifically，CWT is used to process the raw vibration signals to generate two-dimensional time-frequency maps，which are then converted into single-channel grayscale images and fed into a CNN-LSTM deep learning model for fault recognition and classification. Experimental results demonstrate that the proposed method achieves an average fault recognition accuracy of 99.615% on the Case Western Reserve University bearing dataset，significantly outperforming seven other comparison models. Furthermore，the method exhibits a classification accuracy variance of only 0.003 68，which confirms its high stability and effectiveness in rolling bearing fault diagnosis and classification.

**Keywords**：continuous wavelet transform；convolutional neural network；long short-term memory network；rolling bearing；fault diagnosis

(责任编辑：唐立平)

**引用格式**　陈鑫，袁伟，刘松，等. 基于 CWT-CNN-LSTM 的滚动轴承的故障诊断方法研究[J]. 山东航空学院学报，2024，41(3)：5-13. CHEN X，YUAN W，LIU S，et al. Research on rolling bearing fault diagnosis method based on CWT-CNN-LSTM[J]. Journal of Shandong University Aeronautics，2024，41(3)：5-13.