

# 改进 CNN 和 Bi-LSTM 的集成化装备故障检测研究

郑乐辉<sup>1</sup>, 孙俊杰<sup>1</sup>, 牛润<sup>1</sup>, 黄莹<sup>2</sup>

(1. 武警工程大学 研究生大队, 西安 710086;

2. 武警工程大学 信息工程学院, 西安 710086)

**摘要:** 集成化装备的故障检测和健康管理 (DHM, fault detection and health management) 已成为装备领域研究的重点, 但是由于其集成度高, 结构复杂, 综合性强等特点, 采用常规的检测方法常面临信息多源异构, 体量浩大, 且实时性难以保证的问题, 不仅消耗大量的人力物力, 而且需要极强的数据分析及管控能力; 为保证准确性、实时性和有效性的统一, 研究提出一种基于 CNN (卷积神经网络, Convolutional neural network) 和 Bi-LSTM (双向长短期记忆网络, Bidirectional short and long memory network) 及其优化算法的故障检测算法, 构建了 Bi-LSTM-CNN-FCM 模型, 并通过田纳西-伊斯曼化工过程数据集进行验证; 在实验过程中通过观察不同激活函数对模型精度和效果的影响选择合适的激活函数, 最终确定在卷积层使用 tanh 激活函数, 在全连接层使用 relu 激活函数; 在确定激活函数后对模型不断优化, 在模型末端加入 FCM 聚类算法, 提高了故障检测分类的准确率, 最后以准确率和损失值为依据, 通过与单一的 LSTM 模型, CNN 模型和 LSTM-CNN 模型对比, 证明该模型的优越性; 该模型使得故障检测的准确率提升至 98.25%, 损失值减少至 0.010 4, 在性能上明显优于其他模型。

**关键词:** 故障检测; 双向长短期记忆网络; CNN; FCM; 田纳西-伊斯曼化工过程

## Research on Integrated Equipment Fault Detection of Improved CNN and BI-LSTM

ZHENG Lehui<sup>1</sup>, SUN Junjie<sup>1</sup>, NIU Run<sup>1</sup>, HUANG Ying<sup>2</sup>

(1. Armed Police Engineering University, Xi'an 710086, China;

2. Information and Communication of Armed Police University, Xi'an 710086, China)

**Abstract:** Integrated equipment fault detection and health management (DHM) have become the focus of the researches on the equipment field, but because of the characteristics of high integration, complicated structure, strong comprehensive, the conventional detection method often faces the questions of multi-source heterogeneous information, size, and difficult to ensure real-time performance. It does not only consume large amounts of resources, but also requires the strong data analysis and controls the skills. A fault detection algorithm based on convolutional neural network (CNN) and bidirectional short and long memory network (Bi-LSTM) and its optimization algorithm are proposed to ensure the unity of accuracy, real-time and validity. The Bi-LSTM-CNN-FCM model is constructed and verified by the Tennessee-Eastman chemical process dataset. During the experiment, the appropriate activation functions are selected by observing the influences of different activation functions on the model accuracy and effect, and finally the Tanh activation function is determined to be used in the convolution layer, and the Relu activation function is used in the full connection layer. After the activation function is determined, the model is continuously optimized, and the FCM clustering algorithm is added at the end of the model to improve the accuracy of the fault detection and classification. Finally, based on the accuracy and loss value, the superiority of the model is proved by comparing with the single LSTM model, CNN model and LSTM-CNN model. This model improves the accuracy of fault detection to 98.25% and reduces the loss value to 0.010 4, which is obviously superior to other models in performances.

**Keywords:** fault detection Bi-LSTM CNN FCM Tennessee-Eastman chemical process

收稿日期: 2022-07-07; 修回日期: 2022-08-03。

基金项目: 国家自然科学基金项目(61833016)。

作者简介: 郑乐辉(1998-), 男, 江西抚州人, 硕士研究生, 主要从事深度学习、故障检测方向的研究。

通讯作者: 黄莹(1976-), 女, 陕西西安人, 博士研究生, 主要从事卫星导航、卫星通信、智能控制、数据融合、故障诊断方向的研究。

引用格式: 郑乐辉, 孙俊杰, 牛润, 等. 改进 CNN 和 Bi-LSTM 的集成化装备故障检测研究[J]. 计算机测量与控制, 2022, 30(11): 52-

## 0 引言

随着科学技术的不断发展和工业水平的不断提高, 现代工业装备为满足产品的各项要求, 不断趋于集成化、复杂化、综合化, 因此其内部的不确定性也越来越大。为保证装备的安全性、稳定性、可靠性, 需要提高对集成化装备的健康管理能力, 保障设备安全稳定地完成产品生产及设备正常工作。因此故障检测与健康管理的(DHM)就应运而生。

故障检测和健康管理是通过一定的信息获取技术, 通过传感器等精密灵敏的仪器, 对机械设备工作信息进行采集, 然后通过一些优化算法和模块构建智能检测预测模型, 对机械设备进行实时监控, 数据收集, 故障检测, 分析预测等。而集成化设备是在机械设备中普遍存在的, 其由于工作环境复杂, 多系统耦合, 集成复合度高, 在长期服役的过程中, 往往由于其监测信息“体量浩大、多源异构、生成快速、价值稀疏”, 在获取时要耗费大量的人力物力。而在大数据背景下通过建立深层的学习模型, 利用多种算法, 能更好的展现庞大检测数据和集成化装备故障检测和健康管理的映射关系, 大大提高了故障分类、检测和诊断的能力。

综上所述, 对集成化设备实施故障检测和健康管理具有如下意义:

1) 能保证集成化设备安全稳定工作, 防止意外事故发生。通过故障检测模型和相应的检测手段, 及时发现设备异常工作状态, 并采用及时的应对措施, 相对延长设备寿命, 圆满完成工作任务。

2) 高效完成设备管控, 减少人力物力资源, 获得潜在经济效益。能够降低人力、物力资源成本, 提高设备利用率, 完善设备管理方案, 减小设备故障损失。

3) 与大数据背景下的云计算深度学习等紧密结合, 具有时代前沿性。可以在大数据背景下进行特征提取, 不仅大大缩短特征提取的时间, 而且能够做到实时监测。能有效存储利用海量的数据, 发展和优化在集成化装备领域的深度学习方法, 利用边缘运算架构, 在大数据的支持下实现快速精确诊断。

要完成对集成化装备的故障检测和健康管理, 必须收集装备的各项参数指标, 而集成化装备因其自身属性原因在工作过程中往往难以进行人工信息采集, 所以现代工业往往采用一系列的监视监察系统对其工作状态进行获取, 这样能够保障及时获取集成化装备的各项参数指标。在获取装备运行参数和历史运行记录后, 也能连续地对设备运行状态进行诊断和预测分析, 能够大大降低设备发生故障造成的损失, 从而实现对设备的健康管理。

在利用 CNN 模型解决故障检测问题上, 何江江等<sup>[1]</sup>通过经验模态分解 (EEMD) 和支持向量机 (SVM) 对信号进行分解, 并结合 CNN 模型, 解决了端点发散问题, 提高了精确度。文献 [2] 将迁移学习引入滚动轴承, 通过基于

迁移学习的卷积神经网络 (TCNN) 和短时间傅里叶变换 (STFT), 构建在线 CNN 和离线 CNN, 提高实时性, 在有限训练时间内达到期望的诊断精度。曲建岭等<sup>[3]</sup>提出了一种直接作用于原始信号的自适应一维卷积神经网络 (1D-CNN) 用于滚动轴承的故障诊断, 并取得了 99% 以上的故障识别率。文献 [4] 通过对传统的 DCNN 模型进行自适应训练得到了 ADCNN 模型, 使得对轴承的故障诊断的泛化能力得到了提升。文献 [5] 提出了一种具有扩大接收场的增强卷积神经网络 (enhanced convolutional neural network, ECNN) 的行星齿轮箱的故障诊断方法。通过经过扩张的几个卷积层, 扩大接收场, 然后通过 ECNN 训练模型, 在精度上有了很大的提升。文献 [6] 基于 CNN 网络, 通过信号转换, 降低了电机故障诊断模型的复杂性, 克服了过拟合问题。孔子迁等<sup>[7]</sup>使用 CNN 网络在时域和频域上提取信号特征, 完成了齿轮箱健康管理的故障检测, 不仅提高检测精度, 而且准确对故障类别进行分类。利用 CNN 虽然能保证模型的鲁棒性, 并提升泛化能力, 但是其网络结构复杂, 常常需要多层网络结构, 对计算机的要求较高, 因此常常在使用 CNN 网络时结合其他一些算法, 减少计算机的运算时间, 提高效率。

在 FCM 聚类算法方面, 文献 [8] 对 DBN 网络的结构进行改进, 将重构独立分析 (reconstruction independent component analysis, RICA) 方法引入到 DBN 网络中, 提出了 RIDBN 网络, 将 RIDBN 网络与 FCM 算法相结合提出了 RIDBN-FCM 聚类模型并且应用于齿轮故障诊断中, 不仅提高了模型的泛化能力, 而且精度也有所提升。但 FCM 作为一种聚类算法, 并不能单纯地应用于故障检测, 常常要与其他网络综合使用。

在 LSTM 算法方面, LSTM 算法可以反映前向信息和后向信息的紧密联系, 对时间信号的敏感程度很高, 因此在故障检测和预测应用很多, 比如 LSTM 算法在股票指数预测<sup>[9]</sup>, 电力负荷概率预测<sup>[10]</sup>, 轴承故障预测<sup>[11]</sup>, 车辆轨迹预测和交通流量<sup>[12]</sup>等领域都有应用。但单一的 LSTM 网络远远无法满足现代化集成装备的检测要求, 其检测时间长, 且模型精度达不到高效快速检测的要求。因此其模型的诊断精度和检测速度仍需提升。

在后续的发展过程中, 研究专家们将 LSTM 与 CNN 网络结合起来使用, 不仅提高了模型精度, 缩短了检测时长, 使检测效果大幅提升。在股票指数预测方面, 文献 [13] 将 LSTM 模型和 CNN 模型结合对股票指数进行预测, 基本可以达到实时预测的目的, 使预测效果大大增强。在电力负荷预测方面, 文献 [14] 将 LSTM 结合 CNN 后, 加上注意力机制模块, 使模型精度得到大幅提升。同时在轴承故障预测<sup>[15]</sup>和车辆轨迹预测<sup>[16-17]</sup>方面, 当 CNN 和 LSTM 结合后, 预测效果均得到提升。LSTM 和 CNN 的结合还应用在无人机<sup>[18]</sup>、网络<sup>[19]</sup>、单元设备<sup>[20]</sup>、工业<sup>[21]</sup>、轴承故障检测<sup>[22-23]</sup>等领域得到了应用。文献 [24] 使用双卡尔曼滤波对提升了故障诊断的实时性。利用 CNN 与长短时记忆网络

(LSTM) 网络结合能有效处理时间序列数据的优点，模型精度得到很大提升。文献 [25] 提出了一种 CNN、LSTM 与迁移学习相结合的故障识别方法，可以有效的对多类故障识别。将 CNN 和 LSTM 融合模型结合起来，CNN 先对信息特征进行提取，然后 LSTM 网络将信息的内在联系表达出来。CNN 网络对数据信息具有很大的包容性，可以高效处理数据且不使数据丢失。但 LSTM 无法表现出前向信息和后向信息的关系，而 Bi-LSTM 却能将所获取的时间信息前后联系起来，使检测效果更好。因此 Bi-LSTM 也渐渐被应用于各个领域。文献 [26] 将 Bi-LSTM 应用于人机语言交互上，大大提高了机器人语言识别的准确率。文献 [27] 则将其应用于电子装备故障预测，将电子装备前后时间关系联系起来，提高了预测的精度。

在 Bi-LSTM 和 CNN 结合使用方面，其在船舶<sup>[28]</sup>、锂电池寿命预测<sup>[29]</sup>，风电机组<sup>[30]</sup>，太阳辐射度预测<sup>[31]</sup>等领域均有应用，且取得了非常好的检测效果。因此本文针对集成化装备，基于深度学习的基本框架，提出了一种基于 CNN 和 Bi-LSTM 及其优化算法，建立了 Bi-LSTM-CNN-FCM 模型，提高了故障预测的精度，降低了其损失值，并与其他算法进行对比，证明该算法的优越性。

## 1 系统模型构成

### 1.1 双向长短期记忆网络

循环神经网络 ( recurrent neural network, RNN ) 是一类用于处理序列数据的网络模型。它的本质就是网络不仅在层外建立连接，而且在层内建立连接，其层内的连接可以保留隐藏层节点的状态并提供记忆，其大致结构如图 1 所示。长短期记忆 ( long short term memory, LSTM ) 网络就是 RNN 网络的一种变形，目的就是解决了梯度反向传播过程中的梯度消失和爆炸问题。




图 1 RNN 网络结构

Bi-LSTM 算法就是以 LSTM 算法为基础，在 LSTM 算法只记录前向信息的情况下同时记录后向信息，同时结合前后向信息进行特征提取。对于时间  $t$  的输出，前向 LSTM 层在输入序列中有时间  $t$  和时间  $t$  之前的信息，后向 LSTM 层在输入序列中有时间  $t$  和之后的信息。通过叠加得到正向 LSTM 层  $t$  时刻的输出结果和反向 LSTM 层  $t$  时刻的输出结果，并通过加法、平均法或连接法处理两层 LSTM 层的矢量输出，这样输出信息就较好反映时间信号前后联系。

LSTM 虽然能够较好地捕捉到较长距离的依赖关系，在时间上捕捉特征之间的联系，但是其难以表现出后向信息对前向信息的影响。而故障检测过程中需要将故障前后信息进行综合从而对装备寿命进行预测。因此改进后的新算法 BI-LSTM 算法能很好地解决这个问题。

### 1.2 CNN 网络

CNN 是一个典型的前馈神经网络，他是由多个滤波器组成，滤波器提取输入信号的数据特征，然后逐步通过卷积层、子采样层、全连接层和输出层。在逐层通过时不断提取信号中的特征，使得特征逐渐抽象，最终获得输入数据的平移、旋转及缩放不变的特征。其结构图如图 2 所示。




图 2 CNN 网络结构

卷积神经网络学习到的模式具有平移不变性，可以学习模式的空间层次结构。它训练的通常顺序为通常顺序为：输入—卷积层—池化层—卷积层—池化层—…—全连接层—输出。CNN 的核心就是空间卷积核参数共享和池化，卷积层对样本数据的特征进行提取，子采样层对特征进行采样，池化层是对提取特征的选择和信息过滤，全连接层与前一层互连。

CNN 的平移不变性使其能保证模型的鲁棒性，并提升泛化能力，同时 CNN 能对关联信息和数据进行处理，因此其非常适用于集成装备的故障检测。CNN 能克服大噪声的干扰，也非常适用于现代工业，可用于多源信号处理。

CNN 虽然有很多优点，但是其网络结构复杂，常常需要多层网络结构，对计算机的要求较高，并且单独使用 CNN 需要大量带标签的数据，因此，本文在使用 CNN 网络使将结合 LSTM 算法和 FCM 算法，不仅可以降低运算量，使网络复杂结构降低，而且可以优化特征提取的过程，大大提高模型精度。

### 1.3 FCM 算法

FCM 算法是一种常用的聚类分析方法，可以根据样本数据的特征，把有相同或相似特征的样本或时间信息归类，然后提取相似样本数据的特征值。FCM 算法的原理就是通过不断更新聚类中心，使得聚类中心不再改变或两次迭代的目标函数值之差在允许的范围内，从而完成聚类。

FCM 算法因其较为出色的聚类能力，非常适合故障的归类，在经过 CNN 和 Bi-LSTM 处理后的故障信息再经过 FCM 算法后可完成分类，完成对集成化装备故障的检测。FCM 聚类在应用过程中也存在一些缺点，比如选择的模糊

度参数不同, 也会对整个算法的精度产生影响, 所以在使用 FCM 算法时, 常常也需要靠一些先验经验, 参考一些模糊度参数的使用来完善模型。

## 2 Bi-LSTM-CNN-FCM 模型

本文提到的 Bi-LSTM-CNN-FCM 模型的结构图如 3 图所示, 实验过程模型按照如下环节进行, 如图 3 所示。

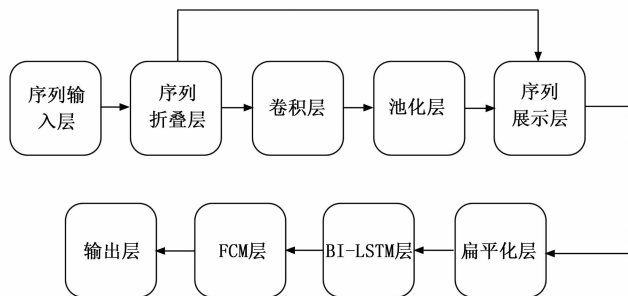


图 3 Bi-LSTM-CNN-FCM 网络结构

对于上述获取的变量中的各类数据, 模型首先通过 CNN 网络提取变量中的各类故障特征, 然后通过 Bi-LSTM 预测获得数据的标签, 通过这两个网络可以直接对变量中的数据进行分类, 模型的输出为属于每一个类别的概率。

获得信号的数据在经过序列折叠层后构建出数据帧, 在特征提取的过程中, 卷积层可实现对故障信号的特征提取, 序列展开层和扁平化层用于恢复序列结构、输出矢量序列。

Bi-LSTM 层和输出层用于对输出的矢量序列进行分类。Bi-LSTM 层在输入的信号中, 不仅包含经过预处理后的特征信息, 而且还包含了原始信息, 通过对信息前向和后向的共同处理, 实现信息融合使输入信号中包含更多信息, 提高了诊断准确率。在 Bi-LSTM 层后设置了 FCM 层, 作为整个模型优化参数设计的一部分, 进一步提高了诊断精度。

## 3 实验过程

### 3.1 数据集获取及预处理

在现代军事装备制造领域, 大型液体运载火箭就是典型的集成化装备。其内部构造冗杂, 且大多数部件不可可视化, 处于黑盒状态。由于大型液体运载火箭故障率低, 且一旦发生故障就会造成巨大损失, 所以本文选取了能代表大部分集成化设备工作工程的田纳西—伊斯曼化工过程。其数据的构成及复杂程度基本与集成化设备吻合。

田纳西—伊斯曼化工过程数据是基于田纳西—伊斯曼化学公司的一个真实化工过程的仿真数据。该化工过程比较好的模拟了实际复杂工业过程系统的许多典型特征, 因此被广泛运用于过程监测与故障诊断的研究中。

整个过程主要包含五个操作单元, 反应器, 冷凝器, 循环压缩机, 分离器和气体塔。此过程中包含了 12 个操纵变量和 41 个测量变量。许多研究者提出了该过程的控制方案较为广泛, 被引用的有基本控制, 分散控制和机控制这

三种控制策略。在田纳西—伊斯曼化工过程中共设计了 21 种故障, 用于模拟实际工业过程中常见的故障和扰动。而本文也主要是针对该过程中的故障进行检测和预测, 从而实现集成化装备的健康管理。

在该过程中, 共有 22 个训练集, 22 个测试集, 每个训练集由 52 个测量信号组成, 共 480 行, 每个测试集有 52 个测量信号组成, 共 960 行。本文选取变量中均有正常数据和故障数据, 对于同时段的变量, 每个变量截取 500 个观测值, 构建  $52 \times 500$  的测量数据帧并归一化。

在对信号进行频率提取时, 正常信号与故障信号有明显差异。其正常信号和故障信号对比图 4 所示。




图 4 正常信号与故障信号对比图

其中上图为五个变量在正常工作下的数据状态。正常工作下振动正常波动, 通过设备可实时检测。

当其中变量出现故障时, 其运行图像会发生明显变化, 在一段时间帧上会有一段时间间隔内出现波动异常, 甚至停止波动, 能够明显区分出其故障状态。

由于不同故障其表现状态也不同, 但通过传感器收集到的信息可以在经过一定的预处理后将其分辨出来。但是要寻找到众多故障设备并区分出故障种类, 然后进行故障预测, 仍然是需要考虑的问题。而本文提出的一种基于 CNN 和 LSTM 及其优化算法的 Bi-LSTM-CNN-FCM 模型能很好地解决上述问题。

### 3.2 模型参数配置

在对模型进行训练的过程中, 将 80% 的数据集作为训

练集, 将 20% 用作测试集。同时每个变量有 20% 的概率为故障数据, 这样能够保证数据获取的随机性与独立性, 通过上述的数据处理, 能够保证构建的数据集和数据帧中包含各类正常数据和故障数据的随机组合, 实现数据的随机获取。本文实验使用模型采用的数据集和参数配置如表 1 所示。

表 1 模型的数据集和参数配置

名称	描述
数据集	纳西-伊斯曼化工过程的数据
训练集:测试集	4:1
数据类型	21
数据长度	500
卷积层	1 * 3
池化层步长	2
优化器	Adam
学习率	0.001

## 4 实验结果与分析

### 4.1 激活函数对比

在使用神经网络时, 为解决其深层网络模型的非线性问题, 常常要用到激活函数。激活函数一般有三种: relu 激活函数、tanh 激活函数和 sigmoid 激活函数。

relu 激活函数公式为:

$$a = g(z) = \max(0, x)$$

sigmoid 激活函数公式为:

$$a = g(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

tanh 激活函数公式为:

$$a = g(z) = \frac{1}{1 + e^{-z}}$$

在所有激活函数中, relu 激活函数使用频率最高, 因其具有硬饱和性质, 很多网络都会优先使用。tanh 激活函数和 sigmoid 激活函数都具有软饱和性质, sigmoid 激活函数常常用在输入的数据特征不是很明显的时候, 因此常用于分类问题的输出层。而 tanh 激活函数几乎适用于大部分的神经网络, 但常常还是用于输入的数据不明显时。

因此, 本文探讨的各个网络层使用何种激活函数是基于使用激活函数后模型的效果和精度决定的。其具体使用效果如表 2 所示。

表 2 激活函数选择对模型影响

序号	卷积层	全连接层	模型精度/%	训练时间/s
1	relu	relu	96.3	175
2	relu	tanh	95.4	176
3	relu	sigmoid	93.7	186
4	tanh	relu	98.2	183
5	tanh	tanh	94.2	179
6	tanh	sigmoid	92.1	187
7	sigmoid	relu	61.5	189
8	sigmoid	tanh	81.2	174
9	sigmoid	sigmoid	72.3	178

通过表中内容可知, 在训练时长上, 无论使用什么激活函数, 其训练时间基本没有什么差异, 但在精度率上, 卷积层使用 tanh 激活函数, 全连接层使用 relu 激活函数的模型精度是远高于使用其他激活函数的, 其模型精度达到了 98.2%。

因此本文将 tanh 激活函数在卷积层使用, 将 relu 激活函数在全连接层使用。

### 4.2 迭代次数对比

在实验过程中, 本文通过不断增加迭代次数观察其损失值和精度随迭代次数的变化, 从判断出最适合此过程的迭代次数。同时通过与其他方法的对比, 检验该方法的优越性。

在用训练集将模型训练好后, 用测试集对其进行测试。首先我们对 LSTM 算法进行验证, 测试用单一 LSTM 算法训练的模型, 观察其迭代次数与精度和损失值之间的变化关系。其关系如图 5 所示。




图 5 LSTM 迭代次数与精度和损失值之间的变化关系

通过图 5 分析可知, 单一的 LSTM 算法建立的模型用于诊断时, 其迭代次数在 3 500 次左右时精度和损失值才趋于稳定, 且精度值稳定在 90% 左右, 损失值稳定在 0.1 左右。由此可见需要对 LSTM 算法进行改进并结合新算法, 减少模型运行需要的迭代次数并提高精度和降低损失值, 为达到这一目的我们引入 Bi-LSTM-CNN-FCM 模型, 并对该模型进行评价和对比, 证明其优越性。首先比较迭代次数对损失值和精度的影响。通过合适的训练测试寻找到田纳西-伊斯曼化工过程数据的最适合的迭代次数。通过不断增加迭代次数, 观察其波形图。在对 Bi-LSTM-CNN-FCM 模型进行验证时, 本文最高迭代次数选择为 1 800 次。其损失值和精度随迭代次数变化的波形图如图 6 所示。

通过图像对比, 可以很明显的发现当迭代次数达到 800 次时, 其准确率和损失值趋于稳定, 准确率稳定在 98% 左右, 损失值由于过小, 观测无法准确判断, 将在进一步的




图 6 Bi-LSTM-CNN-FCM 迭代次数与精度和损失值之间的变化关系

实验中进行具体比较。为保证实验的准确性,在后续实验中,迭代次数最高定在了 1 000 次。

由此可见 Bi-LSTM-CNN-FCM 模型在迭代次数上也能有一定的减少,经过一定预处理后的数据在模型运行过程也能使迭代次数减少。

### 4.3 模型性能对比

为验证 Bi-LSTM-CNN-FCM 的优越性,同时将 LSTM 模型、CNN 模型以及 Bi-LSTM-CNN-FCM 模型应用在田纳西-伊斯曼化工过程数据集上,并在准确度和损失值上进行比较。准确率即为模型检测的准确度,损失值即为模型的预测值和真实值不一样的程度,损失值越低,模型性能越好。其对比结果如图 7 所示。

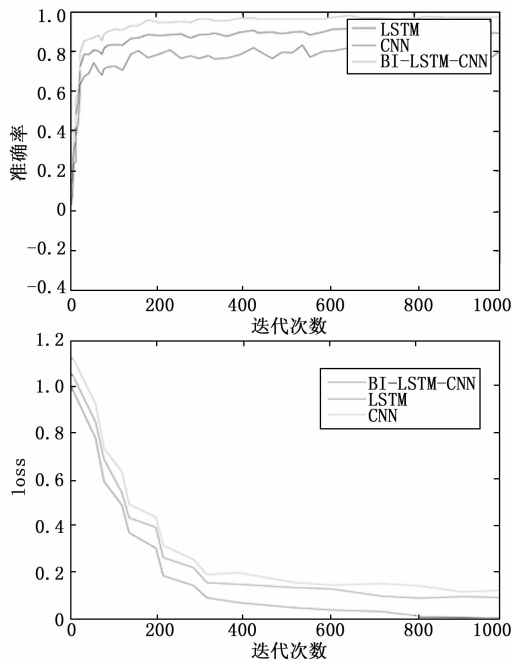


图 7 模型性能对比图

通过查阅文献资料,最新算法中在损失值和准确率综合对比中,效果较好的是 LSTM-CNN 模型,其损失值为 0.051 2,准确率为 0.972 6。为方便对比,本文将 LSTM 模型、CNN 模型以及 Bi-LSTM-CNN-FCM 模型的数值对比总结如表 3 所示。

表 3 模型性能数值对比

模型	损失值	准确率
Bi-LSTM-CNN-FCM	0.010 4	0.982 5
LSTM	0.070 0	0.891 9
CNN	0.132 9	0.800 4
LSTM-CNN <sup>[32]</sup>	0.051 2	0.972 6

通过对比可以发现 Bi-LSTM-CNN-FCM 模型在性能上明显优越于其他两种算法。在准确率上,Bi-LSTM-CNN-FCM 模型的准确率为 98.25%,而单一的 LSTM 模型的准确率仅为 89.19%,在准确率上该模型提升了 9.06%,相比于 LSTM-CNN 模型,准确率也有小幅提升,由此可以看出在准确率方面 Bi-LSTM-CNN-FCM 模型确实有其可取之处,能大大提高模型的准确率。在损失值方面,Bi-LSTM-CNN-FCM 模型的损失值仅为 0.010 4,而单纯的 LSTM 模型的损失值却为 0.070 0,LSTM-CNN 模型为 0.051 2,该模型在损失值方面虽然减少了不多,但也有小幅提升。由此可见 Bi-LSTM-CNN-FCM 模型适用于田纳西-伊斯曼化工过程数据集,适用于现代化集成装备的故障检测,并且在模型性能上相比于单一的 LSTM 模型有较大的提升。虽然相对来说这也消耗了更大的算力和运行时间,但其模型性能得到了较大的提升,能在故障诊断和预测领域有较好的运用。

## 5 结束语

本文从集成化装备故障检测与健康管理的角度出发,并用田纳西-伊斯曼化工过程数据进行验证,提出了一种基于 CNN 和 Bi-LSTM 及其优化算法,通过对 LSTM 算法的改进,建立了 Bi-LSTM-CNN-FCM 模型。首先,通过观察不同激活函数对模型精度和效果的影响选择合适的激活函数,然后通过对模型迭代次数的研究,确定 Bi-LSTM-CNN-FCM 模型的基本性能结构,最后通过实验验证以及模型对比,证明了 Bi-LSTM-CNN-FCM 模型在准确率上有很大的提升,达到了 98.25%,同时损失值也有小幅的降低,减小量达到 0.040 8。由此可以看出 Bi-LSTM-CNN-FCM 模型在集成化装备故障检测与健康管理方面适用性较好。但是,由于模型复杂程度高,其所需要的算力和消耗时长也更多,因此在下一步的工作中会解决模型运行时间长等问题,对模型进行进一步的优化提升,同时在掌握故障检测模型后,对模型进行在次用化,建立故障预测模型,用 RUL 对模型剩余寿命进行预测。

### 参考文献:

[1] 何江江,李孝全,赵玉伟,等. 基于改进 EEMD 的卷积神经

- 网络滚动轴承故障诊断 [J]. 重庆大学学报, 2020, 43 (1): 82-89.
- [2] 毛冠通, 洪流, 王景霖. 基于迁移学习的滚动轴承在线故障诊断 [J]. 航空科学技术, 2020 (1): 61-67.
- [3] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法 [J]. 仪器仪表学报, 2018, 39 (7): 134-143.
- [4] 陈玉昇, 杨燕华, 林萌, 等. 基于深度学习神经网络的核电厂故障诊断技术 [J]. 上海交通大学学报, 2018, 52 (S1): 58-61.
- [5] HAN Y, TANG B P, DENG L. An enhanced convolutional neural network with enlarged receptive fields for fault diagnosis of planetary gearboxes [J]. Computers in Industry, 2019, 107: 50-58.
- [6] HAN J, CHOI D, HONG S, et al. Motor Fault Diagnosis Using CNN Based Deep Learning Algorithm Considering Motor Rotating Speed [C] // 2019 IEEE 6th International Conference on Industrial Engineering and Applications (ICIEA). Washington, DC, USA: IEEE Computer Society, 2019: 440-445.
- [7] 孔子迁, 邓蕾, 汤宝平, 等. 基于时频融合和注意力机制的深度学习行星齿轮箱故障诊断方法 [J]. 仪器仪表学报, 2019, 40 (6): 221-227.
- [8] 张晗. 基于改进深度学习的聚类模型及其在旋转机械故障诊断中的应用 [D]. 长沙: 湖南大学, 2019.
- [9] 杨青, 王晨蔚. 基于深度学习 LSTM 神经网络的全球股票指数预测研究 [J]. 统计研究, 2019, 36 (3): 65-77.
- [10] 李丹, 张远航, 杨保华, 等. 基于约束并行 LSTM 分位数回归的短期电力负荷概率预测方法 [J]. 电网技术, 2021, 45 (4): 1356-1364.
- [11] ZHANG Z Q, ZHOU F N, CHEN D M. Application of improved parallel LSTM in bearing fault diagnosis [C] // 2019 Chinese Automation Congress (CAC), Hangzhou, China, 2019: 5755-5760.
- [12] 季学武, 费聪, 何祥坤, 等. 基于 LSTM 网络的驾驶意图识别及车辆轨迹预测 [J]. 中国公路学报, 2019, 32 (6): 34-42.
- [13] 耿晶晶, 刘玉敏, 李洋. 基于 CNN-LSTM 的股票指数预测模型 [J]. 统计与决策, 2021, 37 (5): 134-138.
- [14] 魏健, 赵红涛, 刘敦楠, 等. 基于注意力机制的 CNN-LSTM 短期电力负荷预测方法 [J]. 华北电力大学学报 (自然科学版), 2021, 48 (1): 42-47.
- [15] 陈保家, 陈学力, 沈保明, 等. CNN-LSTM 深度神经网络在滚动轴承故障诊断中的应用 [J]. 西安交通大学学报, 2021, 55 (6): 28-36.
- [16] 李磊, 张青苗, 赵军辉, 等. 基于改进 CNN-LSTM 组合模型的分时段短时交通流预测 [J]. 应用科学学报, 2021, 39 (2): 185-198.
- [17] 晏臻, 于重重, 韩璐, 等. 基于 CNN+LSTM 的短时交通流量预测方法 [J]. 计算机工程与设计, 2019, 40 (9): 2620-2624, 2659.
- [18] FU JM, SUN C, YU Z, et al. A hybrid CNN-LSTM model based actuator fault diagnosis for six-rotor UAVs [C] // 2019 Chinese Control And Decision Conference (CCDC), Nanchang, Chia, 2019: 410-414.
- [19] TAN Z L, PAN P S. Network Fault Prediction Based on CNN-LSTM Hybrid Neural Network [C] // 2019 International Conference on Communications, Information System and Computer Engineering (CISCE), Haikou, China, 2019: 486-490.
- [20] ZHENG L, XUE W H, CHEN F, et al. A Fault Prediction Of Equipment Based On CNN-LSTM Network [C] // 2019 IEEE International Conference on Energy Internet (ICED), Nanjing, China, 2019: 537-541.
- [21] GAO Y, GONG P, LI L X. An End-to-End model based on CNN-LSTM for Industrial Fault Diagnosis and Prognosis [C] // 2018 International Conference on Network Infrastructure and Digital Content (IC-NIDC), Guiyang, 2018: 274-278.
- [22] DU W, WANG Y X. Stacked Convolutional LSTM Models for Prognosis of Bearing Performance Degradation [C] // 2019 Prognostics and System Health Management Conference (PHM-Qingdao), Qingdao, China, 2019.
- [23] QIAO M Y, YAN S H, TANG X X, et al. Deep Convolutional and LSTM Recurrent Neural Networks for Rolling Bearing Fault Diagnosis Under Strong Noises and Variable Loads [J]. IEEE Access, 2020, 8: 66257-66269.
- [24] 赵治国, 李航宇, 雷丹. 干式 DCT 离合器无刷直流作动机双卡尔曼滤波故障诊断 [J]. 机械工程学报, 2018, 54 (2): 138-149.
- [25] 于洋, 何明, 刘博, 等. 基于 TL-LSTM 的轴承故障声发射信号识别研究 [J]. 仪器仪表学报, 2019, 40 (5): 51-59.
- [26] 张锋, 陶浩兵, 慕京生, 等. 基于 Bi-LSTM 的人机语音交互 [J]. 传感器与微系统, 2022, 41 (4): 104-107, 116.
- [27] 倪祥龙, 石长安, 麻曰亮, 等. 基于 Bi-LSTM 的电子装备故障预测方法研究 [J/OL]. 航空兵器: 1-9 [2022-05-04]. <https://kns.cnki.net/kcms/detail/detail.aspx?dbcode=CAPJ&dbname=CAPJLAST&filename=HKBQ20220412002&uniplatform=NZKPT&v=5tqP7B6fjpuMU65KI9G4shJKQzsNZJFXpydglUHKftyBfdrKw4aenKVh4qUetd7>
- [28] 刘姗姗, 马社祥, 孟鑫, 等. 基于 CNN 和 Bi-LSTM 的船舶航迹预测 [J]. 重庆理工大学学报 (自然科学), 2020, 34 (12): 196-205.
- [29] 梁海峰, 袁芃, 高亚静. 基于 CNN-Bi-LSTM 网络的锂离子电池剩余使用寿命预测 [J]. 电力自动化设备, 2021, 41 (10): 213-219.
- [30] 胡爱军, 连俭, 向玲. 基于 ACNN 和 Bi-LSTM 的风电机组故障早期识别 [J]. 太阳能学报, 2021, 42 (12): 143-149.
- [31] 倪超, 王聪, 朱婷婷, 等. 基于 CNN-Bi-LSTM 的太阳辐照度超短期预测 [J]. 太阳能学报, 2022, 43 (3): 197-202.
- [32] 邢砾文, 姚文凯, 黄莹. 基于深度学习的含未知复合故障多传感器信号故障诊断 [J]. 重庆大学学报, 2020, 43 (9): 93-100.