

# 基于 LSTM 神经网络的管道缺陷模式识别方法研究

谷 晟, 别锋锋, 郭 越, 彭 剑, 赵 威

(常州大学 机械与轨道交通学院, 江苏 常州 213164)

**摘要:** 针对复杂环境下, 管道振动信号特征微弱难以提取的问题, 提出一种基于长短时记忆网络 (LSTM) 深度学习神经网络的管道缺陷模式识别方法; 首先利用改进型自适应噪声的完全集合经验模态分解 (ICEEMDAN) 对采集的原始信号进行分解得到若干个固有模态函数 (IMF) 分量, 随后根据信息熵理论计算 IMF 分量的近似熵作为管道典型状态的特征值构造特征向量集合, 然后构造 LSTM 深度学习神经网络训练模型并调节深度神经网络在训练过程中的相关参数进行网络的结构优化, 最后将特征向量输入到 LSTM 神经网络模型进行训练和识别; 结果表明: 针对管道振动信号特征微弱难以提取的问题, 该方法对管道缺陷模式识别的准确率达到了 95%, 在消除管道振动信号的背景噪声、挖掘特征信息和保证识别准确性方面优势明显。

**关键词:** 管道; ICEEMDAN 分解; 长短时记忆网络 (LSTM); 故障诊断; 深度学习

## Research on the Recognition Method for Pipeline Defect Pattern Based on LSTM Neural Network

GU Sheng, BIE Fengfeng, GUO Yue, PENG Jian, ZHAO Wei

(School of Mechanics and Rail Transit, Changzhou University, Changzhou 213164, China)

**Abstract:** Aiming at the difficulty in feature extraction from pipeline vibration signal in complex environments, a pipeline defect pattern recognition method based on Long Short-Term Memory network (LSTM) deep learning neural network is proposed here. Firstly, the collected original signal is decomposed for several intrinsic modal function (IMF) components with the Improved Complete Ensemble Empirical Mode Decomposition with adaptive noise (ICEEMDAN). Then the approximate entropy of the IMF component is calculated according to the information entropy theory as the eigenvalues of the pipeline running state to construct the feature vector set. And then the typical LSTM deep learning neural network training model is constructed and the relevant parameters of the deep neural network amid the training process are adjusted to optimize the network structure. Finally, the feature vector is input to the LSTM neural network model for training and recognition. The research results show that: for the problem that the pipeline vibration signal features are weak and difficult to extract, the accuracy of the method for pipeline defect pattern recognition has reached 95%, and it has obvious advantages in eliminating the background noise of the pipeline vibration signal, mining feature information, and ensuring recognition accuracy.

**Keywords:** pipeline; ICEEMDAN decomposition; long short-term memory (LSTM); fault diagnosis; deep learning

## 0 引言

管道作为重要的流体输送工具, 其在石油石化、供给排水、天然气等其他流体输送领域中占有非常重要的地位。一旦管道发生故障, 将会造成巨大的经济损失, 甚至还会引发安全事故, 因此对管道状态进行检测与诊断尤为必要<sup>[1-2]</sup>。但是由于现场环境的复杂性, 采集到的管道振动信号往往是非线性, 非平稳的。针对如何从非线性, 非平稳

的管道信号中提取表征管道缺陷类型的故障特征并进行有效的模式识别, 国内外学者进行了大量的研究分析。目前, 针对管道故障特征提取, 最常用的方法是对振动信号进行时频分析。一般, 时频分析方法主要包括经验模态分解<sup>[3]</sup>、小波分析<sup>[4]</sup>、局部均值分解<sup>[5]</sup>、核主元分析<sup>[6]</sup>等。其中, 经验模态分解方法<sup>[3]</sup> (EMD, empirical mode decomposition) 是处理非线性振动信号的强有力的工具, 但是该方法计算效率较低, 易造成模态混叠和虚假分量等问题。为了降低

收稿日期: 2021-03-16; 修回日期: 2021-04-24。

基金项目: 国家自然科学基金项目 (52075050); 江苏省教育厅自然科学基金重大项目 (19KJA43004); 江苏省研究生科研与实践创新计划项目 (SJCX19\_0662)。

作者简介: 谷 晟 (1992-), 男, 江苏淮安人, 硕士研究生, 主要从事机械设备状态监测与故障诊断, 信号处理与分析方向的研究。

通讯作者: 别锋锋 (1979-), 男, 湖北仙桃人, 博士后, 副教授, 主要从事机械设备状态检测与故障诊断、振动信号处理与分析、石油石化设备安全、完整性评价方向的研究。

引用格式: 谷 晟, 别锋锋, 郭 越, 等. 基于 LSTM 神经网络的管道缺陷模式识别方法研究[J]. 计算机测量与控制, 2021, 29(10): 204-210.

模态混叠, 文献[7]提出了集合经验模态分解 (EEMD, ensemble empirical mode decomposition) 方法, 虽然该方法可以在一定程度上抑制模态混叠, 但计算效率依旧相对较低。随后, 文献[8]提出了一种带有自适应白噪声的完全集合经验模态分解 (CEEMDAN, complete ensemble empirical mode decomposition with adaptive noise) 算法, 该算法在 EEMD 的基础上, 既减少了模态混叠又提高了信号的分解效率。

深度学习理论作为机器学习领域的最新研究成果, 自提出以来已经在图像识别<sup>[9]</sup>、语音识别<sup>[10]</sup>、故障诊断<sup>[11]</sup>等领域得到了广泛的应用。深度学习以数据为驱动, 相比于传统的机器学习方法具有更强的特征学习能力, 对于分析复杂多变, 非结构化的模型具有显著的优势<sup>[12]</sup>。其中, 长短时记忆网络 (LSTM, long short term memory) 作为一种特殊的循环神经网络 (RNN), 它很好的弥补了一般 RNN 模型中的梯度爆炸及消失等不足, 并且对于一些时间序列信息的处理具有较高的自适应性<sup>[13]</sup>。于洋等<sup>[14]</sup>针对不同工况下轴承故障声发射信号的辨识问题, 基于长短时记忆网络与迁移学习方法构建模型, 充分挖掘不同工况下轴承声发射信号之间的关系, 从而实现了多工况下轴承故障声发射信号的智能辨识。王鑫等<sup>[15]</sup>从复杂系统的历史故障数据出发, 提出一种基于 LSTM 的故障时间序列预测模型, 并且通过实验证明, 该模型在故障时间序列分析中具有更强的适用性以及更高的准确性。陈伟等<sup>[16]</sup>利用 LSTM 对时间序列优异的处理能力, 将轴承的振动信号数据作为深层 LSTM 的输入, 取得了很好的辨识准确率。王维锋等<sup>[17]</sup>提出基于 LSTM 的齿轮故障诊断模型, 成功解决了在诊断过程中数据量大、提取特征困难等问题。

本文采用 ICEEMDAN-LSTM 深度神经网络方法, 改进的完全集合经验模态分解方法<sup>[10]</sup> (ICEEMDAN) 通过对加入的噪声作进一步优化, 可有效的减少信号在分解过程中分量产生的残余噪声和虚假分量等问题。LSTM 深度神经网络算法则在分类过程中具有更强的学习和分类能力。因此, 针对管道故障特征微弱难以提取的问题, 本文提出了一种基于 LSTM 深度神经网络的管道缺陷模式识别方法。首先利用 ICEEMDAN 对管道振动信号进行分解生成一系列本征模态分量 (IMF), 随后根据相关峭度准则筛选有效 IMF 分量并计算近似熵作为特征向量集合, 然后基于深度神经网络的理论基础构造 LSTM 深度神经网络模型并对其进行参数优化, 最后将特征向量集合导入进行训练和识别。

## 1 基本原理

### 1.1 ICEEMDAN 算法

ICEEMDAN 作为 CEEMDAN 的改进算法, 其主要在 CEEMDAN 的基础上, 在信号进行分解迭代时加入高斯白噪声并且对生成的新的信号求平均。相比较 CEEMDAN 信号分解方法该方法极大的抑制了信号在分解过程中产生的残余噪声及虚假分量的现象并且有效提高了信号分解效

率<sup>[18]</sup>。其具体的信号分解过程如下:

步骤 1: 原始信号加入高斯白噪声

$$X_1^{(n)} = x + e_1 E_1(\omega^{(n)}), (n = 1, 2, \dots, L, N) \quad (1)$$

其中:  $x$  为原始信号;  $\omega^{(n)}$  为被添加的第  $n$  个高斯白噪声;  $e_1$  为第一次信号分解时信号的期望信噪比;  $E_1(\cdot)$  为计算信号的第 1 个 IMF 的算子。

步骤 2: 计算第一次分解的残差  $r_1$

$$r_1 = [X_1^{(n)} - E_1(X_1^{(n)})] \quad (2)$$

其中:  $[\cdot]$  为计算  $N$  个信号平均的算子。

步骤 3: 计算原始信号的第一阶模态分 IMF<sub>1</sub>

$$IMF_1 = x - r_1 \quad (3)$$

步骤 4: 构造第  $k$  ( $k \geq 2$ ) 组加入高斯白噪声的信号

$$X_k^{(n)} = r_{k-1} + e_k E_k(\omega^{(n)}), (n = 1, 2, \dots, N) \quad (4)$$

其中:  $e_k$  为第  $k$  次信号分解时信号的期望信噪比;  $E_k(\cdot)$  为计算信号的第 1 个 IMF 的算子。

步骤 5: 计算第  $K$  阶残差  $r_k$

$$r_k = [X_k^{(n)} - E_k(X_k^{(n)})] \quad (5)$$

步骤 6: 计算  $K$  阶模态分量

$$IMF_k = r_{k-1} - r_k \quad (6)$$

步骤 7: 迭代终止条件

$$\sigma = \frac{\|IMF_{k+1} - IMF_k\|_2}{\|IMF_k\|_2} \quad (7)$$

其中:  $\sigma$  为相邻两次 IMF 分量之间的标准差。令  $k = k + 1$ , 返回步骤 4 计算下一  $k$  值, 直至残差满足迭代终止条件。本文采用 Cauchy 收敛准则, 即当相邻两次 IMF 分量之间的标准差  $\sigma < 0.2$  时, 迭代终止。

### 1.2 LSTM 神经网络结构

LSTM 是一种特殊的循环神经网络 (RNN), 它很好地弥补了一般 RNN 模型中的梯度爆炸及消失等不足。LSTM 的主要特征是包含 3 个门选择结构和一个记忆存储单元结构, 其中 3 个门选择结构分别是遗忘门、输入门和输出门。LSTM 靠这些“门”结构让输入特征有选择性的影响神经网络每个时刻的状态<sup>[19]</sup>。所谓的“门”结构就是使用一个 sigmoid 作为激活函数的全连接神经网络输出一个  $0 \sim 1$  间的数值。当一个特征向量输入到 LSTM 神经网络中训练时, 可以根据规则来判断是否有用。只有符合算法认证的信息才会留下, 不符的信息则通过遗忘门被遗忘。LSTM 的网络结构如图 1 所示。

遗忘门用于判断记忆单元内容是否保留, 从而实现对记忆内容的筛选, 其输出为:

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (8)$$

式中,  $f_t$  为遗忘门的输出;  $\sigma$  为激活函数 sigmoid;  $w_{xf}$  为输入和遗忘门之间的权重;  $w_{hf}$  为历史输出和遗忘门之间的权重;  $b_f$  为遗忘门偏置;  $x_t$  表示  $t$  时刻的输入向量;  $h_{t-1}$  为前一时刻的输出状态。

输入门用于特征导入并且更新单元状态, 当神经网络的其他部分想要写入存储单元的时候, 必须先通过输入门。若输入门关闭, 则其他神经元就无法把值写入。其输出为:




图 1 LSTM 网络结构图

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (9)$$

式中,  $i_t$  为遗忘门的输出;  $w_{xi}$  为输入和输入门之间的权重;  $w_{hi}$  为历史输出和输入门之间的权重;  $b_i$  为输入门偏置。

另外, 在获得遗忘门的输出和输入门输出之后, 可以得到当前的记忆单元状态为:

$$c_t = f_t c_{t-1} + i_t \hat{c}_t \quad (10)$$

$$\hat{c}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (11)$$

式中,  $\hat{c}_t$  为候选单元状态;  $w_{xc}$  为输入和单元状态之间的权重;  $w_{hc}$  为历史输出和单元状态之间的权重;  $b_c$  为单元状态偏置项。

输出门用于控制单元状态的最终输出, 并且决定外界的神经元能否把值从存储单元中读出来。单元输出由输出门输出和当前单元

状态信息相乘并经过  $\tanh$  激活函数得到。故, 输出门和单元输出为:

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (12)$$

$$h_t = o_t \tanh(c_t) \quad (13)$$

式中,  $o_t$  为遗忘门的输出;  $w_{xo}$  为输入和输出门之间的权重;  $w_{ho}$  为历史输出和输出门之间的权重;  $b_o$  为输出门偏置;  $h_t$  为当前时刻的单元输出。

## 2 管道故障诊断流程

本文提出基于 LSTM 深度学习模型对管道缺陷模式的识别方法, 主要分为 3 个部分: 首先, 对管道振动数据进行特征提取; 其次, 建立 LSTM 模型并对其参数进行优化; 最后, 利用 LSTM 模型进行故障识别。具体故障诊断步骤如下:

1) 通过多传感器分别采集孔洞、凹坑、裂纹及正常 4 种不同类型管道在运行状态下的振动信号。

2) 对采集到的信号进行 ICEEMDAN 分解, 并提取近似熵作为表征管道运行状态的特征值特征构造特征向量集合。选取其中的 80% 作为训练样本数据, 把剩余的作为测试样本数据。

3) 基于深度学习理论基础建立 LSTM 深度神经网络模型, 并运用该模型对训练样本数据进行训练, 不断调

整优化模型中的 epoch、batch 等参数使训练准确率保持在较高的区间。

4) 将测试样本数据输入到训练好的 LSTM 深度神经网络模型中, 实现管道故障的识别。

## 3 实验及结果分析

### 3.1 实验平台

为了验证该方法的有效性, 利用实验室的管道故障模拟实验平台, 分别对管道进行锉刀摩擦, 打开泄漏阀, 纱布摩擦来模拟工程实际中凹坑、孔洞、裂纹 3 种管道故障模式以及利用完整的管道来模拟正常模式, 并利用水泵向管道通水, 当管道处于稳定状态时分别采集管道在这 4 种运行状态下的振动信号数据。另外考虑到在实际工业过程中, 因为长输管线的缺陷位置一般不确定, 所以在测试振动信号时传感器的放置位置离缺陷处的位置往往是不确定的, 进而导致传感器在不同测点所采集到的管道振动信号特征也会有所不同。在远离缺陷位置如在管道接头处及管卡固定处, 由于信号在传递过程中会受其影响, 此时所采集到的振动信号特征就会比较微弱。因此, 本次实验充分考虑这些实际因素的影响, 主要在靠近管卡处、离缺陷位置较远处、靠近激励处等位置布置测点, 进行管道振动信号的采集。管道振动信号检测如图 2 所示。如图所示, 实验仪器包括接触式激振器, 扫频发生器, 动态信号采集仪, 压电式加速度传感器、动态信号采集仪及相应的采集软件。首先通过激振器和扫频发生器加强管道运行工况下的振动情况, 然后利用加速度传感器在管道上随机布置测点, 通过动态信号采集仪及操作 PC 端采集软件采集管道振动信号。实验室管道系统及 3 种故障模式如图 3 所示。

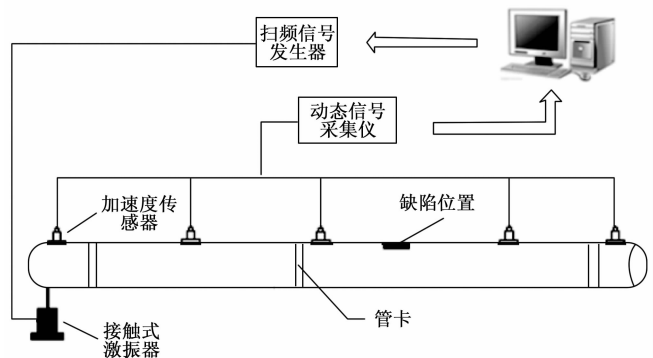


图 2 管道振动信号检测示意图




图 3 实验室管道平台及故障模式

### 3.2 数据处理及特征样本集构造

本次实验采集了凹坑, 孔洞, 裂纹和正常运行 4 种工况下的管道振动信号, 对振动信号进行 ICEEMDAN 分解。以凹坑管道的一组振动信号为例, 如图 4 所示, 为管道振动信号 ICEEMDAN 分解波形图 (前 7 个分量), 从图 4 中可以看出, 将原始振动信号进行 ICEEMDAN 处理后的信号冲击特征明显, 有利于故障特征的提取。




图 4 信号分解结果图

基于 ICEEMDAN 方法对 4 种工况下的管道振动信号进行分解共得到 12 个 IMF 分量和一个余量。但是, 一般在分解过程中得到的 IMF 分量可能会包含不能够表征管道状态的伪分量, 若直接进行特征提取不仅会导致向量集合的维数过多, 而且会影响最终的辨识准确率。因此, 筛选有效的 IMF 分量是特征提取的关键。本文根据峭度准则计算峭度值以此来筛选出最能表征不同工况下管道运行状态的 IMF 分量。如图 5 所示, 为各阶 IMF 分量峭度值变化趋势。一般, 正常平稳运行且噪声干扰小的信号, 其峭度值大于 3。从图 5 中可以看出, 前七阶 IMF 分量的峭度值呈逐渐降低的趋势且数值大小都大于 3, 因此选取 IMF1—IMF7 分量进行后续的特征提取分析。

针对管道缺陷信息的特征提取, 本文遵从时频域特征进行分析处理, 从而构造特征样本集合。信息熵是一种非线性估计方法, 主要通过量化的熵值对非稳态信号的复杂性程度进行衡量。信息熵理论作为特征提取的方法之一, 广泛应用在对有噪声夹杂信号中有效信息的提取。它实际上是一个描述如设备运行的复杂程度、诊断的难易程度等

无法明确量化确定的指标。故本文最终选取信息熵论中的近似熵作为表征 4 种工况下管道状态的特征集合。另外, 本次实验所采集的管道振动信号样本共计 4 个类别, 分别为正常、裂纹、孔洞及凹坑。在样本数据采集过程中, 采样时间设置为 60 s。每种工况下的管道振动信号为 1 000 组, 总样本数为 4 000 组。以每种工况下管道振动信号样本数据中的一组数据为代表, 图 6 分别展示了 4 种工况下管道振动信号的近似熵在空间上的特征分布情况。




图 5 各阶 IMF 峭度值变化趋势




图 6 近似熵特征分布

为了直观地显示特征提取的效果, 选取 ICEEMDAN 分解的前 3 个 IMF 分量来分析特征向量在三维空间上的聚类情况。选取特征近似熵的三维空间特征分布如图 6 所示, 从图中可以看出 4 种工况下管道振动信号的特征分布均呈现云状分布, 其中有部分样本特征发生重叠现象。这是因为近似熵作为信息熵的一种, 主要用来对信号特征的无序性与复杂性进行描述。一般正常运行的管道其在运行过程中受到的冲击较少, 因此正常管道的振动信号的熵值较大, 无序性也较高。当管道中出现诸如孔洞、凹坑、裂纹等缺陷时, 其在运行过程中的冲击特征就会增强, 相应的管道振动信号的无序性就会变低。反应到特征值的空间分布上, 虽然可以初步达到聚类的效果, 但是样本特征重叠较多, 尤其是针对凹坑、裂纹、孔洞管道的样本特征值。因此, 对管道振动信号进行特征提取后, 需要做进一步的深层次的分析处理才能实现对管道状态的有效识别。

### 3.3 LSTM 深度神经网络分类模型设计

针对不同缺陷类型管道微弱特征难以识别的问题, 本

文建立了 LSTM 深度神经网络分类模型。整个神经网络由输入层 (Input); 隐含层 (LSTM 层, full connect layer 层) 和输出层 (Loss) 组成。数据由输入层流入, 经过 LSTM 神经网络并使用 Tanh 激活函数非线性化, 再流入全连接层并使用 Sotfmax 函数激活, 最后输出。本文主要按照以下 3 个步骤设计网络结构。

第一步: 构建 LSTM 深度神经网络模型。LSTM 深度神经网络结构设计如图 7 所示, LSTM 层激活函数 (activate function) 选择 Relu 函数, 全连阶层激活函数选取 Sotfmax 函数, 输入层即特征处理的特征向量。

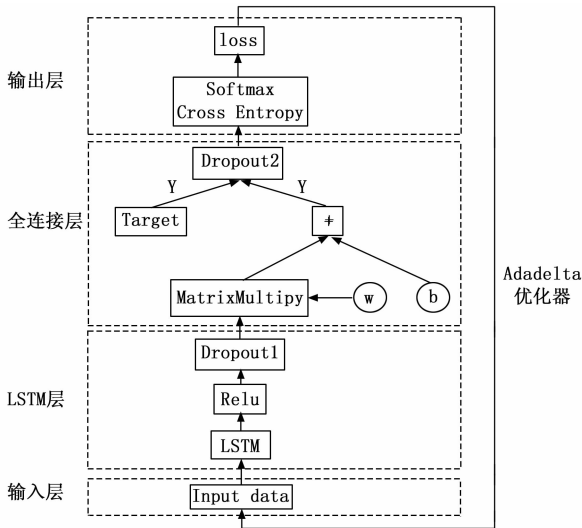


图 7 基于 LSTM 的深度神经网络结构设计

第二步: 计算损失函数 (loss function) 大小。损失函数描述的是神经网络计算结果和实际结果之间的误差, 最终的目标是通过梯度下降使得找到一组合适的权值和偏置值使得损失函数的值最小。常见的损失函数有均方差损失函数和交叉熵损失函数<sup>[20-21]</sup>。本文将会比较均方差损失函数和交叉熵损失函数的训练结果, 最后选择适合管道缺陷深度学习模型的损失函数。

第三步: 寻找一种方法快速确定各个神经元的权值和偏置值, 即通过优化器 (optimiter) 确定合适的参数, 使得整个网络模型得到一个相对满意的结果。在损伤识别过程中, 本文比较了 4 种优化器 (adagrad、adadelata、mini batch gradient descent、momentum) 对于损失函数收敛性和最后识别准确率的影响, 最后选择出合适的优化器。

#### 4 管道特征信号的 LSTM 深度神经网络模式识别

本文针对对凹坑、孔洞、裂纹和正常 4 种状态的管道振动信号各提取了 1 000 组, 共 4 000 组数据。每组数据采样 2 048 个点。训练样本为在每种状态中选取 800 组样本数据, 剩余的 200 组作为测试样本。另外, 比较均方差损失函数与交叉熵损失函数对于训练模型的影响, 最终分析选择交叉熵损失函数。为了防止训练过程中出现过拟合问题加入了 Dropout。其他的具体参数如表 1 所示。

表 1 编程参数

参数名称	参数值
Batch	64
Epochs	100
LSTM 层激活函数	Relu
全连接层激活函数	Softmax
损失函数	Cross Entropy
优化器	Adadelata

图 8 和图 9 分别展示了深度神经网络的识别准确率和损失函数的大小。从图 8 及图 9 中可以看出, 损失函数的值前 20 步迅速下降, 此时模型距离全局最小值较远, 梯度快速下降, 反应到准确率图上就是前 20 步迭代过程准确率迅速提高, 迭代了 20 步左右整个神经网络模型就有一个不错的识别准确率, 损失函数逼近于全局的最小值, 此时梯度下降变缓, 在整个模型的全局最小值附近做一个缓慢的调整, 在准确率识别图上的反应就是迭代多个周期以后准确率才有一个缓慢的提升。当迭代 80 步时整个模型相对稳定趋于全局最小值处, 因此本模型的迭代步数设置为 100。另外, 单独从图 8 中可以看出参数优化过后的神经网络识别准确率达到到了 95%。而且分类的准确率随着训练不断提高的过程中没有出现明显的振荡, 这说明本模型的学习率设置合理。从图 9 中可以看出, 损失函数在快速下降后趋于一个收敛的值, 说明模型结构和参数设置合理。




图 8 LSTM 深度学习模型准确率




图 9 LSTM 深度学习模型损失函数

将特征样本集输入 LSTM 深度神经网络分类模型中, 得到如图 10 所示的分类结果图, 其中 1、2、3、4 分别代表孔洞、凹坑、裂纹、正常 4 类标签。从图 10 可以看出, 训练集、测试集及验证集对 4 种不同缺陷类型的管道识别准

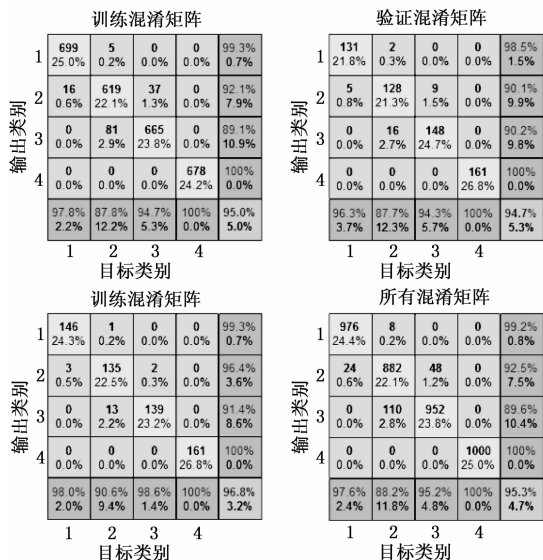


图 10 训练集、测试集和验证集混淆矩阵

准确率基本达到了 95% 左右。而且该模型总的分类效果从图 10 中所有混淆矩阵中可以看出达到了 95.3%，其中对于标签 4 即正常管道运行状态的辨识准确率达到 100%，标签 1 的识别率达到了 99.2%，因此本模型的误差主要集中在标签 2（识别准确率为 92.5%）和标签 3（识别准确率为 89.6%）的分类识别上。

该方法很好地克服了管道振动信号在分解过程中产生虚假分量和模态混叠的问题，对复杂的振动信号具有很好的分解效果。然后根据峭度准则选取前 7 阶 IMF 分量并且构造近似熵特征向量集合。最后根据 LSTM 深度学习理论构造 LSTM 分类模型并对该模型中的参数进行优化，将特征向量集合导入 LSTM 深度神经网络中进行模式识别。实验结果表明：基于 LSTM 的深度神经网络模型能够较好的应用于管道故障检测领域，而且故障识别准确率可达 95%，显著提高了对不同工况下管道故障检测的辨识准确率。

参考文献:

[1] 王建顺. 国内管道工程的 EPC 项目物资供应风险识别 [J]. 交通企业管理, 2017 (3): 90-92.

[2] 杨永会. 石油化工工程中工艺管道安装施工存在的问题与对策 [J]. 中国石化化工标准质量, 2012, 33 (11): 231-231.

[3] 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 Mathematical Physical & Engineering Sciences, 1998, 454 (1971): 903-995.

[4] 周小勇, 叶银忠. 小波分析在故障诊断中的应用 [J]. 控制工程, 2006, 13 (1): 70-73.

[5] 程军圣, 张 亢, 杨 宇. 机械故障振动信号的局部均值分解方法 [M]. 长沙: 湖南大学出版社, 2013.

[6] 李学军, 李 平, 蒋玲莉. 类均值核主元分析法及在故障诊断中的应用 [J]. 机械工程学报, 2014, 50 (3): 123-129.

[7] WU Z H, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in adaptive data analysis, 2009, 1 (1): 1-41.

[8] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise [C] // IEEE International Conference on Acoustics, Speech and Signal Processing, IEEE, 2011: 4144-4147.

[9] 李 卫. 深度学习在图像识别中的研究及应用 [D]. 武汉: 武汉理工大学.

[10] 侯一民, 周慧琼, 王政一. 深度学习在语音识别中的研究进展综述 [J]. 计算机应用研究, 2017, 34 (8): 2241-2246.

[11] 吴 魁, 王仙勇, 孙 洁, 等. 基于深度学习的故障检测方法 [J]. 计算机测量与控制, 2017, 25 (10): 43-47.

[12] 刘 飞, 张俊然, 杨 豪. 基于深度学习的医学图像识别研究进展 [J]. 中国生物医学工程学报, 2018, 37 (1): 86-94.

[13] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural computation, 1997, 9 (8): 1735-1780.

[14] 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.

[15] 王 鑫, 吴 际, 刘 超, 等. 基于 LSTM 循环神经网络的故障时间序列预测 [J]. 北京航空航天大学学报, 2018, 44 (4): 772-784.




图 11 误差分析

本模型的误差的区间为  $[-1, 1]$ ，将误差区间均分为 20 份，作出模型的数据误差直方图，如图 11 所示。图中展示了模型训练完后样本训练集、样本测试集和样本验证集的误差。从图 11 中可以看出误差主要分布在  $[-0.05, 0.05]$ ，这说明了该神经网络模型对于分类识别处于一个较小的误差水平，同时也进一步表明所提出模型的结构稳定且对不同工况下管道故障检测具有很好的识别效果。

5 结束语

针对管道振动信号特征微弱难以提取的问题，本文提出了一种基于 LSTM 的深度学习神经网络模式识别方法。首先利用 ICEEMDAN 信号分解方法分解管道振动信号，

[16] 陈伟, 陈锦雄, 江永全, 等. 基于 RS-LSTM 的滚动轴承故障识别 [J]. 中国科技论文, 2018, 13 (10): 1134-1141.

[17] 王维锋, 邱雪欢, 孙剑桥, 等. 基于双层长短时记忆网络的齿轮故障诊断方法 [J]. 装甲兵工程学院学报, 2018, 32 (2): 81-85.

[18] COLOMINAS M A, SCHLOTTHAUER G, TORRES M E. Improved complete ensemble EMD: a suitable tool for biomedical signal processing [J]. Biomedical Signal Processing & Control, 2014, 14 (1): 19-29.

[19] 庄雨璇, 李奇, 杨冰如, 等. 基于 LSTM 的轴承故障诊断

端到端方法 [J]. 噪声与振动控制, 2019, 39 (6): 187-193.

[20] KORDING K P, WOLPERT D M. The loss function of sensorimotor learning [J]. Proceedings of the National Academy of Sciences of the United States of America, 2004, 101 (26): 9839-9842.

[21] RUDOY G I. On modification of the mean squared error loss function for solving nonlinear heteroscedastic errors-in-variables problems [J]. Moscow Institute of Physics & Technology, 2017, 55 (12): 74-84.

(上接第 203 页)

电力系统调度政策, 对调度量化指标和提高机组运转效率方面作进一步研究。

### 6 结束语

本文提出一种基于改进天牛须搜索算法的 IBAS-BP 组合模型, 并将其应用于热电厂短期电力负荷预测中。通过引入精英策略, 改进 BAS 算法更新步长, 增加了搜索过程的多样性和随机性。结果表明, IBAS-BP 优化模型具有良好的预测性能。调度中心根据负荷预测结果, 综合考虑电网政策、机组本身的调节性能、效率、煤耗等因素, 对热电厂机组进行负荷优化分配, 降低机组煤耗率, 保证每台机组安全、稳定、经济运行, 研究具有工程应用价值。

### 参考文献:

[1] 严慧峰, 黄定疆, 谢垚, 等. 短期电力负荷预测模型的研究 [J]. 中国科学技术大学学报, 2019, 49 (2): 119-124.

[2] 陈玮, 林言泰, 丁军策, 等. 国外区域电力市场对南方区域电力市场建设的启示 [J]. 南方电网技术, 2018, 12 (12): 3-8.

[3] 王世杰, 周丽华, 孔兵, 等. 基于 LDA-Deep Hawkes 模型的信息级联预测 [J]. 计算机科学与探索, 2020, 14 (3): 410-425.

[4] 易灵芝, 常峰, 龙谷宗, 等. 基于进化深度学习短期负荷预测的应用研究 [J]. 电力系统及其自动化学报, 2020, 32 (3): 1-13.

[5] 白书华, 况明星. 基于 PSO-GA-BP 神经网络的林火预测设计与研究 [J]. 系统仿真学报, 2018, 30 (5): 1739-1748.

[6] 许鹏, 孙毅, 张健, 等. 基于人工智能代理的负荷态势感知及调控方法 [J]. 电力系统自动化, 2019, 43 (3): 178-186.

[7] 魏骛, 茅大钧, 韩万里, 等. 基于 EMD 和长短期记忆网络的短期电力负荷预测研究 [J]. 热能动力工程, 2020, 35 (4): 204-209.

[8] 邹京希, 曹敏, 董立军, 等. 基于总体测辨和人工神经网络的负荷建模及预测方法 [J]. 电力系统及其自动化学报,

2018, 30 (8): 108-112.

[9] 霍娟, 孙晓伟, 张明杰. 电力负荷预测算法比较—随机森林与支持向量机 [J]. 电力系统及其自动化学报, 2019, 31 (7): 129-134.

[10] 闫重熙, 陈皓. 基于改进天牛须搜索算法优化 LSSVM 短期电力负荷预测方法研究 [J]. 电测与仪表, 2020, 53 (6): 6-11.

[11] 贾永会, 杜建桥, 汪海洋, 等. 基于 BP 神经网络的燃煤锅炉温度分布预测 [J]. 热能动力工程, 2020, 35 (7): 131-138.

[12] 孟子超, 杜文娟, 王海风. 基于迁移学习深度卷积神经网络的配电网故障区域定位 [J]. 南方电网技术, 2019, 13 (7): 25-33.

[13] 刘倩颖, 阮应君, 时翔, 等. 基于 kmeans 聚类与 BP 神经网络算法的办公建筑逐时电负荷预测 [J]. 热能动力工程, 2018, 33 (3): 139-144.

[14] 郭彩杏, 郭晓金, 柏林江. 改进遗传模拟退火算法优化 BP 算法研究 [J]. 小型微型计算机系统, 2019, 40 (10): 2063-2067.

[15] 王宇星, 黄俊, 潘英杰. GA-BP 神经网络在老人负性情绪预测中的应用 [J]. 小型微型计算机系统, 2020, 41 (8): 1702-1706.

[16] 罗权. 基于自适应卡尔曼滤波在气象影响下负荷预测 [J]. 计算机测量与控制, 2020, 28 (1): 156-159, 165.

[17] 王雪微, 程若发, 杨宏超, 等. 基于相似日的支持向量机短期负荷预测 [J]. 计算机测量与控制, 2018, 26 (1): 47-50, 83.

[18] 刘爱军, 尹明. 基于 GA-LM-BP 神经网络的锂离子电池预测研究 [J]. 计算机测量与控制, 2018, 26 (7): 44-47, 108.

[19] 王林, 万小雨, 万建超. 一种基于选择策略的差分混合蛙跳算法 [J]. 计算机工程与科学, 2018, 40 (1): 121-127.

[20] 彭元, 娄素华, 范越, 等. 考虑火电机组储热改造的电力系统低碳经济调度 [J]. 电网技术, 2020, 44 (9): 3340-3345.

[21] 牛洪海, 李兵, 陈俊. 火电厂厂级负荷优化控制系统研制及应用 [J]. 中国电力, 2016, 49 (12): 96-100.