

基于 CNN-A-BiLSTM 的无刷直流电机故障诊断方法研究

覃仕明, 马鹏

(广西壮族自治区特种设备检验研究院, 南宁 530200)

摘要: 无刷直流电机是大型设备重要的动力装置之一, 电机的运行状态与设备的运行状态高度一致; 但当前现有的电机故障诊断方法难以在多电机或存在电磁干扰的环境下对电机做出准确的状态判断; 为了实现复杂环境的无刷直流电机状态诊断, 研究融合了卷积神经网络算法和长短期记忆网络算法; 研究通过长短期记忆网络算法的双向传播捕捉复杂环境对电机的影响特征, 从而提高模型的诊断精准度; 实验结果表明, 提出模型在机电设备故障诊断数据集上的平均收敛时间为 8.91 min, 在电机故障数据集上的平均收敛时间为 12.66 min, 收敛时间均低于同组对照模型; 其次提出模型的 F_1 值为 94.17%, 比对照模型分别高出 4.87% 和 7.46%; 此外, 在对电机故障前后电压检测情况对比中, 提出模型对电机故障发生时的检测结果更为详细; 根据实验结果可以得出, 研究提出的电机诊断模型具有优秀的性能, 满足电机诊断行业的精准度需求。

关键词: 卷积神经网络; 无刷直流电机; 长短期记忆网络; 激活函数; 故障诊断

Research on Diagnosis Method of Brushless DC Motor Based on CNN-A-BiLSTM

QIN Shiming, MA Peng

(Guangxi Special Equipment Inspection and Research Institute, Nanning 530200, China)

Abstract: Brushless DC motors are one of important power devices for large equipment, and the operating status of motors is highly consistent with the operating status of equipment. However, current motor fault diagnosis methods are difficult to make accurate state judgments on motors in environments with multiple motors or electromagnetic interference. In order to achieve state diagnosis of brushless DC motors in complex environments, this paper presets the fusion of convolutional neural network (CNN) algorithm and long short-term memory network algorithm. The bidirectional long short-term memory (BiLSTM) propagation network algorithm is adopted to capture the impact of bidirectional propagation environments on the characteristics of the motors, thereby improving the diagnostic accuracy of the model. Experimental results show that the average convergence time of the proposed model on the mechanical and electrical equipment fault diagnosis dataset is 8.91 minutes, and the average convergence time on the motor fault dataset is 12.66 minutes, both of which are lower than that of the control model in the same group. Secondly, the F_1 value of the proposed model is 94.17%, which is 4.87% and 7.46% higher than that of the control model, respectively. In addition, in the comparison of voltage detection before and after motor faults, the proposed model provides more detailed detection results when motor faults occur. According to experimental results, the proposed motor diagnosis model has excellent performance and meets the requirements of motor fault diagnosis.

Keywords: CNN; brushless DC motor; long short-term memory network; activation function; fault diagnosis

0 引言

无刷直流电机具有高效的动力转化特性和较强的稳定性, 是日常工业生产中常用的一种同步电机。该电机的原理是将电子控制器与同步电机进行结合, 通过驱动器对电机的精确控制, 实现转子转速的灵活调整。与传统的控制器电机相比, 无刷直流电机能够在不同负载和转速下实现最佳的动力输出。无刷直流电机省去了物理换向器和碳刷,

转而采用电子换向技术, 大大提高了电机的效率和可靠性^[1]。无刷直流电机作为现代工业与日常生活中广泛应用的动力设备, 其运行的稳定性和可靠性直接关系到整个系统的性能和安全性。然而, 由于工作环境复杂多变、电机老化等因素, 无刷直流电机在运行过程中难免会出现各种故障, 这些故障如果不及时诊断和处理, 不仅会影响电机的工作性能, 还可能造成严重的安全事故。近年来, 传感器技术、信号处理技术和机器学习算法得到了较大的发展,

收稿日期: 2024-04-01; 修回日期: 2024-04-30。

基金项目: 广西壮族自治区科技计划项目(桂科AB20159008)。

作者简介: 覃仕明(1987-), 男, 大学本科, 高级工程师。

通讯作者: 马鹏(1984-), 男, 硕士, 高级工程师。

引用格式: 覃仕明, 马鹏. 基于 CNN-A-BiLSTM 的无刷直流电机故障诊断方法研究[J]. 计算机测量与控制, 2024, 32(9): 118-124, 148.

基于现代技术的电机运行状态诊断技术也取得了显著进步^[2]。但当前主流的诊断方法或模型在面对复杂环境时依然难以做对电机运行状态精准判断。如何构建一个准确稳定的无刷直流电机状态诊断模型依旧是该行业亟须解决的难题。同时国内外专家也进行了大量的研究, 武智超等人利用阵列漏磁信号结合机器学习设计了一种无刷直流电机高阻接触故障的定位和定量分析方法。该方法能够有效提升高阻接触故障的定位精度, 提升了故障检测的可靠性^[3]。方红伟等人利用电机三相绕组的电压矢量检测对单相无刷直流电机传感器转子故障进行检测。结果表明该方法能够减少检测矢量的数量, 并提升检测效率^[4]。Han L 等学者利用有限元分析和卷积神经网络对无刷直流电机的退磁故障进行了诊断。结果表明该方法能够提升故障的诊断性能, 减少诊断耗时^[5]。Vanchinathan K 等人利用蝙蝠算法与鲸鱼优化算法对无刷直流故障进行诊断, 通过两种算法的结合, 新算法大幅提升了无刷直流电机轴承和定子绕组故障检测的性能^[6]。虽然这些研究在一定程度上实现了故障诊断, 但还存在适应性不强等问题。基于此, 将卷积神经网络 (CNN, convolutional neural networks)、双向长短期记忆网络 (BiLSTM, bi-directional long short-term memory) 和蚁群算法 (ACO, ant colony optimization) 用于无刷直流电机的故障诊断。研究首先利用 CNN 对电机故障特征进行提取和识别, 然后在特征提取的基础上利用 ACO 算法对 BiLSTM 网络进行改进优化, 最后利用 CNN-A-BiLSTM 构建融合故障诊断模型。研究的创新点有两点: 第一点, 利用蚁群算法来优化 BiLSTM 在双向传播中局部收敛的缺陷, 以实现 BiLSTM 算法与 CNN 算法收敛速度的匹配, 为两个算法的融合起到促进作用; 第二点, 研究将 CNN 与 BiLSTM 算法进行了融合, 可实现无刷电机的多重故障诊断, 确保故障诊断的准确率。研究提出的融合故障诊断模型能够解决无刷直流电机在复杂环境中故障检测困难的问题, 同时也在一定程度上促进电机运维行业的发展。

1 融合 CNN 与改进 LSTM 的无刷直流电机诊断模型构建

1.1 基于 CNN 算法的电机故障特征识别模型构建

市面上常见的无刷直流电机由电机、控制电机的换相电路以及电机位置和状态检测的传感器组成。为了实现对电机的控制, 换相电路在设计中采用的传感器来代替了传统电机中的换相刷, 使得控制器能更快更准确地获得电机的状态^[7-8]。在电机控制领域, 电机驱动方式的选择决定了电机的工作类型和效率。研究使用的电机采用三相互差 120° 的方波电流, 在计算其反电动势时需要使用平顶宽 120° 的梯形方波来计算。假设在理想情况下, 无刷电机的三相定子电压平衡方程的计算如式 (1) 所示:

$$\begin{cases} u_1 = i_1 R_1 + L_1 \frac{di_1}{dt} + u_n + e_1 \\ u_2 = i_2 R_2 + L_2 \frac{di_2}{dt} + u_n + e_2 \\ u_3 = i_3 R_3 + L_3 \frac{di_3}{dt} + u_n + e_3 \end{cases} \quad (1)$$

式 (1) 中, u_n 表示电机中点的电压, 该点电压主要用于计算每个相的电动势差; i_1, i_2, i_3 分别表示电机的三相电流; u_1, u_2, u_3 分别表示电机的三相电压; 电机的三相电感系数分别为 L_1, L_2, L_3 ; e_1, e_2, e_3 表示电机的转子在三相绕组中的感应电动势; R_1, R_2, R_3 表示电机的 3 个等效电路电阻值。在理想状态下, 通常默认 R_1, R_2, R_3 三个电阻的阻值相等^[9-10]。电机在工作过程中, 仅凭外观很难判断电机是否处于故障状态, 因此需要使用更直观的参数来进行电机状态的判断, 常见的电机状态判断参数包括输出功率、发热功率、电压平衡状态以及电流平衡状态。研究采用无刷电机的三相定子电压平衡情况作为电机状态的判断依据, 并使用先进的机器学习算法进行电机状态智能诊断。

卷积神经网络在特征提取和识别任务中具有优秀的表现, 同时该算法中的卷积运算是实现智能化识别模型的核心计算方法。CNN 能够提取对图像位置不变的特征, 这使得它能够对图像的不同部分进行有效处理, 而不会影响识别能力, 同时 CNN 在大规模图像识别任务中表现也十分出色^[11-12]。鉴于 CNN 的众多优势, 研究尝试采用该算法来实现无刷直流电机故障特征识别模型构建。CNN 算法分为输入、输出、卷积、池化和全连接 5 个模块, 其中输入输出模块结构较为简单, 主要对数据进行简单处理, 如归一化、数据去重等。而卷积、池化和全连接模块则用于对输入数据进行特征提取和特征识别。

在 CNN 算法中, 输入和输出层常用归一化的方式控制输入输出数据的量级, 同时将数据归一化会在输入卷积层可以方便计算卷积核的损失函数, 还能提高模型的收敛速度。数据降维也是输入输出层常用的数据处理方式, 降维可以取消数据维度的相关性, 使目标的不同特征各自独立, 从而简化模型的运算, 提高模型的输出效率。在输入层中, 数据通常还会被去重和合并。由于重复数据的输入会消耗模型的计算资源, 并且在一定程度上增加模型的计算复杂度, 因此重复数据的去除是输入层的重要工作之一。去除重复数据可以使用 UNIQUE 函数进行, 此外 Set 函数也可以根据其输出数列不包含重复数据的特性进行数据去重。CNN 算法中卷积层用于提取目标的特征, 并输出目标不同特征的特征函数。卷积层对特征的提取依靠卷积核的卷积运算, 该运算是一个局部特征提取运算, 在卷积核中某一个卷积通道只关注目标的某一个特征, 因此在卷积层还可以实现特征分离^[13-14]。卷积层的计算表达式如式 (2) 所示:

$$X_l^i = f\left(\sum_{n=1}^N W_i^{(n,l)} \otimes X_{l-1}^n + B_l^i\right) \quad (2)$$

式 (2) 中, \otimes 为卷积运算的运算符号; i 表示卷积层层数的索引; l 表示卷积层输出通道的索引; N 表示水数据的总数; n 输入数据的索引; X_l^i 表示第 i 层第 l 个卷积通道输出的特征函数; $W_i^{(n,l)}$ 表示第 n 个数据在第 i 层第 l 个卷积通道计算时的权值矩阵; B_l^i 表示第 i 层第 l 个卷积通道中滤波器的偏

置向量； $f(\cdot)$ 表示卷积层的激活函数。卷积运算是一个复杂的过程，其实质也是数字运算的一种，为了简化 CNN 的计算，可以将卷积映射到矩阵中。矩阵的卷积运算需要先确定卷积核矩阵和被卷积矩阵，卷积核矩阵在进行运算时需要旋转 180° 。旋转卷积核矩阵的目的是纠正剪辑过程中对输入函数的时域反转。平衡状态是非线性变化的，因此模型需要处理非线性数据。研究的应用场景是非线性任务之一，因此选取 *Relu* 函数作为模型全连接层的激活函数。*Relu* 函数的计算表达式如式 (3) 所示：

$$Relu(x) = \max(x, 0) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3)$$

当 $x > 0$ 时，该函数的导数恒为 1，所以不存在梯度衰减问题。虽然 CNN 算法可以在空间维度上较为精准和快速地提取数据的局部特征，但该算法却无法从时间维度上处理数据之间的联系和影响，从而导致无刷直流电机在运行过程中时间特征的丢失问题。因此在诊断无刷直流电机的场景中，CNN 还需要与其他算法进行结合。

1.2 融合蚁群算法改进的 BiLSTM 电机状态诊断模型研究

BiLSTM 算法由 LSTM 算法改进而来，在 BiLSTM 算法中，单个传播模块的结构与 LSTM 算法的结构一致。LSTM 算法是 RNN 的一种改进算法。RNN 也具有一定的短期记忆能力，但该算法无法处理长期依赖的问题，因此 Sepp Hochreiter 教授在对 RNN 算法进行改进后，得到了 LSTM 算法。LSTM 算法实现长期记忆的核心是“门”结构，不同的“门”通过训练后可以保留或忘记指定的信息，从而实现长期记忆的效果^[15-16]。LSTM 算法中存在大量的细胞状态，细胞状态可以作为算法内部信息传输的介质和路径，上述的“门”结构也是由细胞状态构成的，LSTM 算法的结构图如图 1 所示。

虽然 LSTM 算法能够基于时间来判断电机的运动状态，但在信号较为复杂的电机中，LSTM 算法复杂的计算机制难以满足诊断精度的需求。同时无刷直流电机之间也会产生相互影响，但 LSTM 算法无法进行反方向传播，因此在复杂场景下传统的 LSTM 算法无法进行多方面影响信号捕捉，从而导致模型对无刷直流电机的状态诊断存在误差^[17-18]。为了解决传统 LSTM 算法的不足，研究采用了两个反向的 LSTM 模块构建了一个双向的长短记忆算法，

简称 BiLSTM 算法。BiLSTM 算法的正向传播可以实现模型前面时刻的输出对当前时刻的影响，而反方向传播可以识别出不同电机对当前时刻产生的影响^[19]。BiLSTM 算法的前向传播和后向传播的计算表达式如式 (4) 所示：

$$\begin{cases} Rh_t = f^R(\omega_1 x_t + \omega_2 Rh_{t-1}) \\ Lh_t = f^L(\omega_3 x_t + \omega_5 Lh_{t+1}) \end{cases} \quad (4)$$

式 (4) 中， Rh_t 表示前向传播的输出值； Lh_t 表示反向传播的输出值； f^R 表示前向传播的激活函数； f^L 表示反向传播的激活函数，前向传播与反向传播的激活函数与上述 LSTM 个模块采用的激活函数一致； x_t 表示 t 时刻的输入数据； ω_1, ω_2 表示前向传播时遗忘门和选择门的权值矩阵； ω_3, ω_5 反向传播时遗忘门和选择门的权值矩阵； h'_t 表示 t 时刻 BiLSTM 算法的隐藏状态。此时隐藏状态的计算如式 (5) 所示。

$$h_t = \text{Tanh}(\omega_4 Rh_t + \omega_6 Lh_t) \quad (5)$$

式 (5) 中， ω_4, ω_6 表示输入门和输出门的权值矩阵，BiLSTM 算法中前向传播和后向传播时输入门和输出门的结构一致。虽然 BiLSTM 算法可以更全面地提取无刷直流电机的运行状态，并与 CNN 算法提取的各个电机电势平衡状态进行故障的综合判断。但该方法还存在局部收敛的问题，因此研究还需针对这一问题进行改进。

对于 BiLSTM 算法存在的局部收敛问题，研究引入 ACO 算法来解决该问题。ACO 算法是一种模拟自然界中蚁群觅食行为的优化算法，在 ACO 算法中，每只蚂蚁代表一种可能的解决方案，通过不断迭代选取信息素最大的方案作为算法的输出值。而在该研究场景中，ACO 算法通过模拟蚁群觅食路径将整个模型中各个模块的参数和权值联系起来，并通过信息素蒸发情况来判断各个参数或权值对模型整体输出的影响。在该研究中，通过蚁群算法对 BiLSTM 算法的各项参数进行全局寻优，从而提高模型的收敛速度。在蚁群算法中，全局变量的状态转移公式如式 (6) 所示：

$$\tau_{i,j}(t) = (1 - \rho)\tau_{i,j}(t-1) + \sum_{k=1}^m \Delta\tau_{i,j}^k(t-1) \quad (6)$$

式 (6) 中， $\tau_{i,j}(t)$ 表示路径 (i, j) 上的信息素； ρ 表示当前信息素的蒸发率； $\Delta\tau_{i,j}^k$ 表示第 k 只蚂蚁在路径 (i, j) 上留下的信息素； m 表示蚁群中所有个体的数目。全局变量的状态转移可以反映出变量在不同取值下对模型输出的影响，通过

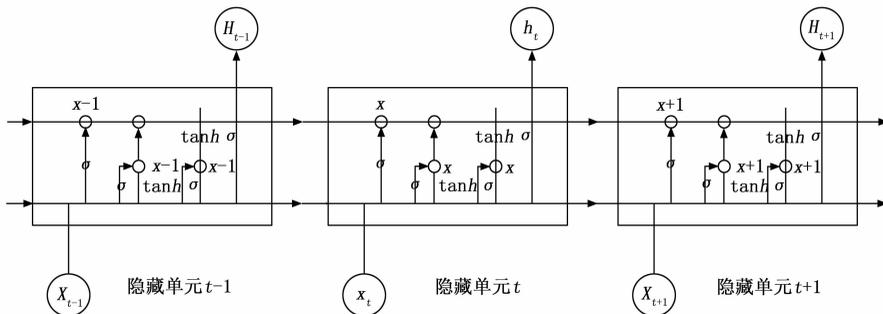


图 1 单向长短记忆网络结构示意图

多次迭代, 选取信息素最大的情况即可确定模型的全局最优参数。研究通过对 BiLSTM 算法进行改进, 解决了该算法全局收敛困难的问题, 此时, BiLSTM 算法的收敛速度基本与 CNN 算法的收敛速度匹配。所以研究将改进后的 BiLSTM 算法的输出作为外部参数添加进 CNN 的全连接层中组成综合全连接层。综合全连接层用于处理 CNN 提取的电机三相定子电压平衡状态和改进 BiLSTM 算法捕获的外部影响因素, 通过综合判断无刷直流电机的三相定子电压平衡和其他影响因素来综合判断电机的运行状态。因此融合模型可以在复杂环境中对无刷直流电机更准确的状态判断。

CNN 算法和基于蚁群算法改进的 BiLSTM 算法融合后的复合模型 (CNN-A-BiLSTM) 由输入层、卷积层、池化层、双向 LSTM 层、综合全连接层和输出层组成。CNN-A-BiLSTM 模型深度共有九层, 具体层数分配和参数配置如表 1 所示。

表 1 具体层数分配和参数配置

模型层数	结构名称	主要参数
第一层	输入层	无刷直流电机三相定子电压平衡数据
第二层	卷积层	卷积核: 1×5 ; 卷积步长: 2
第三层	卷积层	卷积核: 1×5 ; 卷积步长: 2
第四层	激活函数	ReLU 函数
第五层	大池化层	池化方式: 最大池化; 池化步长: 2
第六层	维度转换	一维数据序列
第七层	改进双向 LSTM	神经元数量: 128; 蚁群总数量: 100; 信息素蒸发率: 0.5
第八层	综合全连接层	权重分配
第九层	输出层	激活函数: Softmax 函数

其中卷积层深度为 2, 用于提取数据样本的空间特征, 且卷积层的输出以矩阵的形式发送给池化层。池化层采用最大池化法, 进一步保留数据的突出特征^[20]。为了在双向 LSTM 层中快速提取特征的时间序列, 研究在池化层与双向 LSTM 层之间增加了一个数据组合层, 用于转换数据的维度。但经过融合后复合模型的参数较多, 容易出现梯度爆炸的问题, 因此研究还在 BiLSTM 中引入了正则化方法, 正则化的计算表达式如式 (7) 所示:

$$Y_{l2} = \frac{1}{2} \lambda \|x\|_2^2 \quad (7)$$

式 (7) 中, $\|\cdot\|$ 表示范式运算; λ 表示正则化参数, λ 越大

表明正则化对模型的约束能力越大; x 表示输入的数据; Y_{l2} 表示正则化输出, $l2$ 表示研究采用的正则化方式是 $L2$ 方式。数据进行维度转换后再经过正则化, 可以减轻参数对数据梯度下降的影响, 从而避免梯度爆炸的问题。最后模型的综合全连接层需要处理 BiLSTM 的双向 LSTM 层和 CNN 卷积层输出的数据, 因此综合全连接层的激活函数结构不能太复杂, 经过考虑后研究选取 ReLU 函数作为模型的激活函数。此时基于 CNN 和 BiLSTM 算法的电机状态诊断模型的构建工作已经完成, CNN-A-BiLSTM 模型的结构图如图 2 所示。

为了在复杂环境中准确检测电机的运行状态, 研究在 BiLSTM 算法的基础上引入 ACO 算法进行了改进, 以平衡 BiLSTM 算法的收敛情况, 改进后的算法命名为 A-BiLSTM 算法。同时研究在 CNN 算法的全连接融合 A-BiLSTM 算法, 以此构建了一个综合多重识别机制的无刷直流电机运行状态诊断模型, 旨在促进电机故障检测和电机维护行业的智能化发展。

2 基于 CNN-A-BiLSTM 电机状态诊断模型性能测试与分析

2.1 电机状态诊断模型数据处理性能分析

为了验证研究提出模型的可行性和先进性, 研究采用对照实验的方式与其他电机状态诊断模型进行对比。实验所用的设备为一台 CPU 为 Intel 酷睿 i9 14 900 K, 运行内存为 16 GB, 显卡为 RTX 4 090 的电脑, 系统环境为 Windows 10, 开发软件为 Java, JDK 版本为 5.6。实验所用的开源数据集包括机电设备故障诊断数据集和电机故障数据集, 其中机电设备故障诊断数据集是为各种大型时间序列, 包含了数千台设备的动力装置数据。而电机故障数据集中包含了振动数据和电流数据, 其中的故障类别有匝间短路、转子断条、轴承磨损等常规故障。两个数据集包含的数据基本涵盖了生产中常见的故障, 因此可以满足研究的训练和测试需求。实验选取的对照模型有基于混合特征提取和粒子群算法的电机故障诊断模型 (Motor Fault Diagnosis Model Based on Mixed Features and Particle Swarm Optimization) 简称 PSO-ELM 模型和基于多尺度核卷积神经网络的同步电机故障诊断模型 (A Fault Diagnosis Model for Synchronous Motor Based on Multi scale Kernel Convolutional Neural Network), 简称 MSK-CNN 模型。为了加快

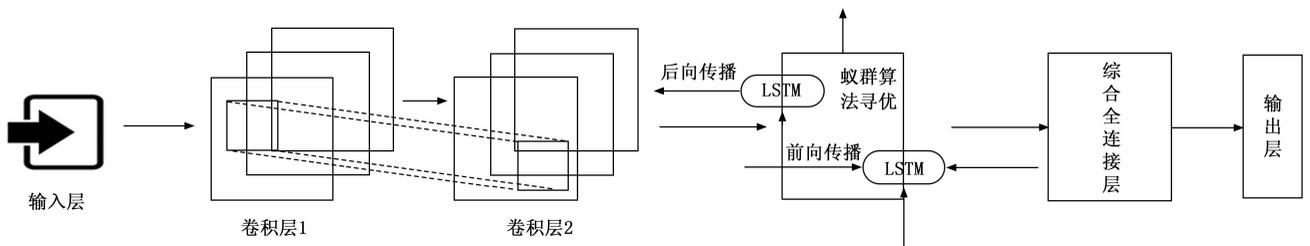


图 2 CNN-A-BiLSTM 无刷电机状态诊断模型结构示意图

实验进度, 研究对所有实验模型均进行了预训练, 预训练采用的数据集由机电设备故障诊断数据集和电机故障数据集中的部分数据组合而成。其他预训练的参数详情如表 2 所示。

表 2 预训练模型参数详情表

备注	参数详情
硬件设备	CPU: Intel 酷睿 i9 14 900 K; 显卡: RTX 4 090; 运行内存: 16 GB
系统环境	Windows 10
开发软件	Java
卷积核参数	卷积核: 1 * 5; 卷积步长: 2
池化方法	最大池化
隐藏状态维度	一维
布尔值	True
LSTM 双向布尔值	True
实验模型	PSO-ELM 模型、MSK-CNN 模型、 CNN-A-BiLSTM 模型
预训练数据集	机电设备故障诊断数据集和电机故障 数据集构成的混合数据集
训练次数	1 次
蚁群算法参数	种群总数量: 100; 信息素蒸发率: 0.5

不同模型在两个测试数据集上的收敛速度比较情况如图 3 所示, 为了避免偶然因素的影响, 研究对所有模型均进行了三次实验。图 3 (a) 表示两个模型在机电设备故障诊断数据集上的收敛情况, CNN-A-BiLSTM 模型的收敛时间是 3 个模型中最低的, 该模型的平均收敛时间为 8.91 min; PSO-ELM 模型的平均收敛时间为 13.69 min; MSK-CNN 模型的平均收敛时间为 11.54 min。图 3 (b) 表示 3 个模型在电机故障数据集上的收敛时间, 从图 3 (b) 中可以看出, CNN-A-BiLSTM 模型的平均收敛时间为 12.66 min; PSO-ELM 模型的平均收敛时间为 16.95 min; MSK-CNN 模型的平均收敛时间为 15.77 min。其中, 图 3 (b) 中第二次实验 MSK-CNN 模型数据与其余两次实验偏差较大, 因此该项实验结果不计入平均值计算中。但根据图 3 (a) 和图 3 (b) 的结果可以得出, 研究提出的 CNN-A-BiLSTM 模型在收敛速度上具有一定的优势, 说明 CNN-A-BiLSTM 模型中输入输出层对数据的预处理和归一化对模型收敛具有一定促进作用。此外, 3 个模型在电机故障数据集上的收敛时间较长的原因是该数据集中数据样本量多于机电设备故障诊断数据集。

PR 曲线是指用横轴表示召回率, 纵轴表示精确率, 将数据绘制成图表的形式所得到的曲线。PR 曲线可以反映出模型在处理不同难度的样本时的性能, 特别是在处理不平衡数据集时非常有用。图 4 表示 PSO-ELM、MSK-CNN、CNN-A-BiLSTM 三个模型的 PR 曲线对比情况。从图 4 中可以看出, 3 个模型 PR 曲线的终点最靠近右下角的是 CNN-A-BiLSTM 模型, 其次是模型, 最后是 PSO-ELM 模型, 说明 CNN-A-BiLSTM 模型在处理较为困难的数据集时

性能最好。

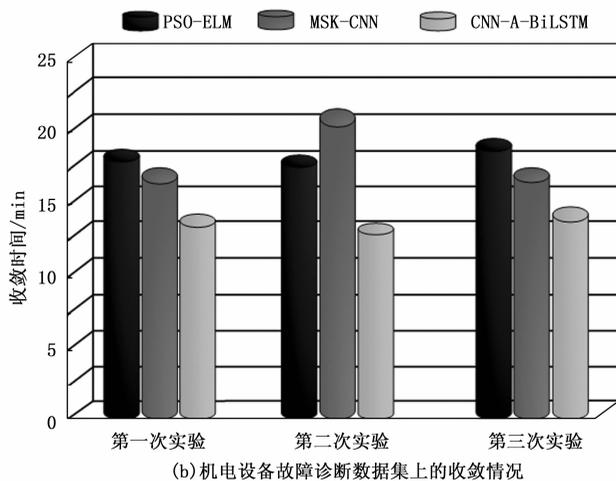
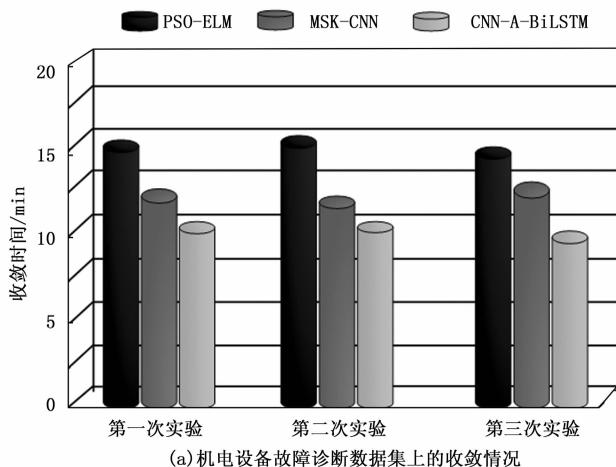


图 3 各模型收敛速度对比分析

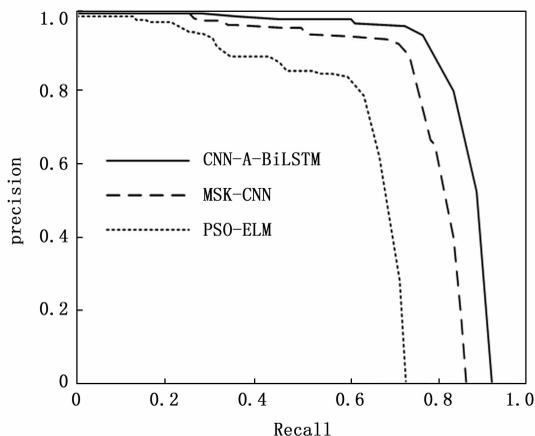
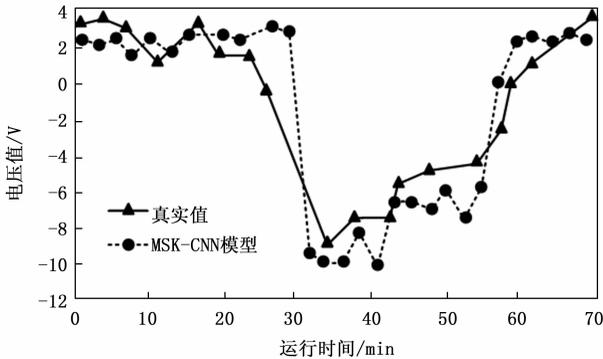


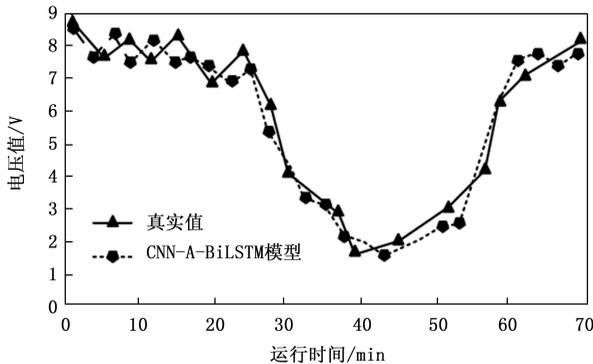
图 4 各模型的 PR 曲线对比情况

图 5 表示 CNN-A-BiLSTM 模型和 MSK-CNN 模型检测出的无刷直流电机故障前后的电压值变化情况。图 5 (a) 表示 MSK-CNN 模型检测出的电机故障前后的电压变化状态; 图 5 (b) 表示 CNN-A-BiLSTM 模型检测出的电机故障前后的电压变化状态。从 MSK-CNN 模型的输出结果可

以看出电机故障时的电压发生了突变, 与真实值的曲线走势存在较大的差异, 且出现了负电压。出现负电压表明该模型在故障诊断时的稳定性较差, 这会影响诊断的准确性。而 CNN-A-BiLSTM 模型的输出结果与真实值曲线走势大致相同, 虽然在部分值上存在一定的差异, 但能够更详细地反映电机故障前后的电压值变化情况。同时 CNN-A-BiLSTM 模型对电机故障时的检测电压为出现负电压的情况。这说明研究提出的模型能够提升故障诊断的可靠性和稳定性, 因此该模型更符合此次研究的应用场景。



(a) MSK-CNN模型检测的故障前后电压变化情况



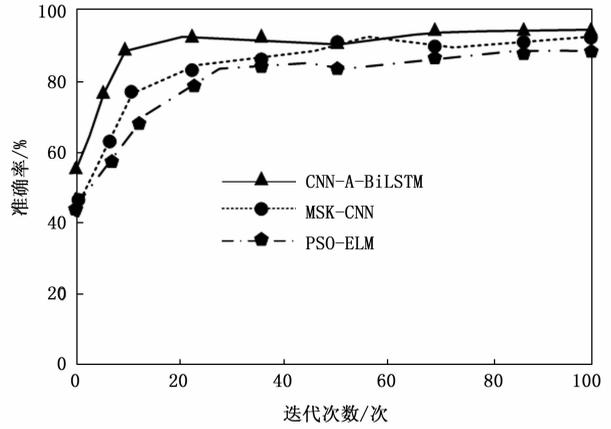
(b) CNN-A-BiLSTM模型检测的故障前后电压变化情况

图 5 故障前后不同模型对电压检测情况的输出对比图

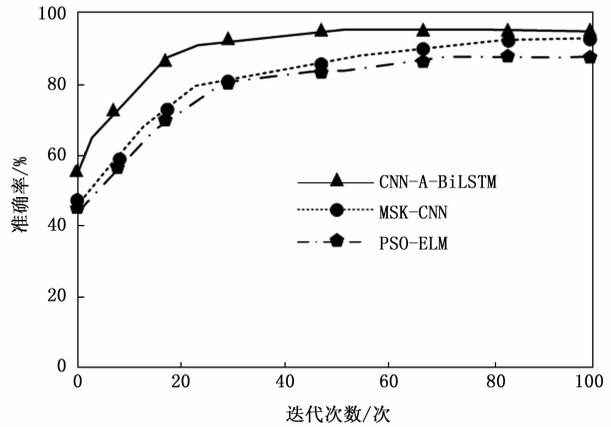
2.2 电机状态诊断模型应用性能分析

F_1 值的基于模型的准确率和召回率计算而来的指标, 它可以反映出模型准确率和召回率的平衡状态, 适用于评价模型的识别或分类效果。 PSO-ELM、MSK-CNN、CNN-A-BiLSTM 三个模型在不同数据集上的 F_1 值对比如图 6 所示。图 6 (a) 表示 3 个模型在机电设备故障诊断数据集上的 F_1 值对比情况; 图 6 (b) 表示 3 个模型在电机故障数据集上的 F_1 值对比情况。从图 6 (a) 中可以看出 3 个模型的 F_1 值曲线均在 15~20 次迭代后趋于平缓, 但 3 个模型 F_1 值曲线完全平缓的迭代次数有所差异。 CNN-A-BiLSTM 模型在 60 次迭代后变化情况基本稳定, 而 MSK-CNN 模型曲线趋于稳定是在第 70 次迭代附近, PSO-ELM 模型则在 80 次迭代后才趋于稳定。此外曲线稳定后 CNN-A-BiLSTM 模型 F_1 值为 94.17%; MSK-CNN 模型 F_1 值为 89.30%;

PSO-ELM 模型 F_1 值为 86.71%。而图 6 (b) 中, 3 个模型的 F_1 值曲线变化更加平缓, 曲线稳定后模型 F_1 值有效到达依次为 CNN-A-BiLSTM 模型、MSK-CNN 模型、PSO-ELM 模型, 与图 6 (a) 结果一致。



(a) 机电设备故障诊断数据集



(b) 电机故障数据集

图 6 不同模型 F_1 值对比示意图

为了验证提出模型的先进性, 研究对模型的各项性能进行了测试。通过与当前较为先进的电机故障诊断模型的对比, 得出了 CNN-A-BiLSTM 模型在收敛速度、 F_1 值等方面均具有更优的性能, 由此得出, CNN-A-BiLSTM 模型具有先进性。为了验证电机状态诊断模型的分类效果, 研究在电机设备故障诊断数据集上进行分类效果对比实验。如图 7 所示为 3 种模型的诊断数据分类效果对比结果。从图 7 可以看出, CNN-A-BiLSTM 模型、MSK-CNN 模型和 PSO-ELM 模型的 AUC 值分别为 0.905、0.861 和 0.837。

通过 AUC 值对比可知, CNN-A-BiLSTM 模型在电机状态诊断中的分类效果优于 MSK-CNN 模型和 PSO-ELM 模型。这可能是由于 CNN-A-BiLSTM 模型结合了卷积神经网络和双向长短时记忆网络的优势, 既能够提取空间特征, 又能够处理时序信息, 从而更准确地识别电机状态的变化。此外, 注意力机制的引入可能也进一步提高了模型对关键特征的捕捉能力, 从而提升了分类性能。研究为了进一步

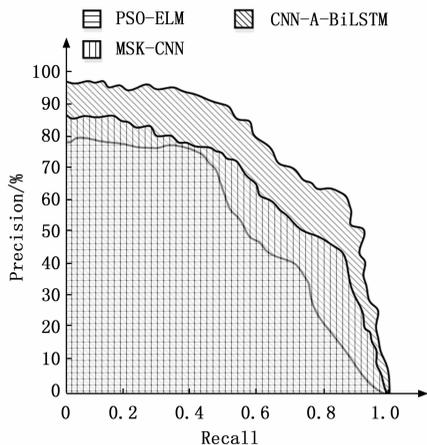


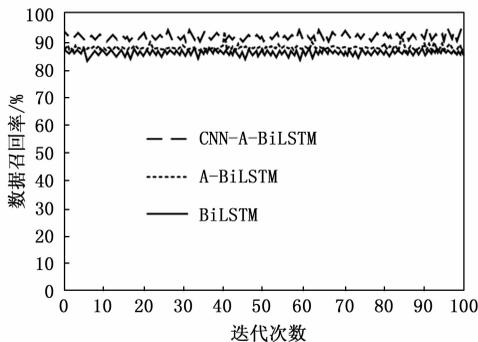
图 7 3 种模型的诊断数据分类效果对比结果

验证利用 CNN-A-BiLSTM 算法构建的电机故障诊断模型的性能, 将 BiLSTM 算法 A-BiLSTM 算法与 CNN-A-BiLSTM 算法进行对比。将故障诊断过程中数据处理的召回率和故障诊断准确率作为对比指标, 进行消融实验。如图 8 所示为 3 种方法在电机故障诊断中数据处理召回率和诊断准确率对比结果。由图 8 (a) 可知, 在故障诊断数据处理过程中, 3 种方法的数据召回率存在一定的差异。其中 CNN-A-BiLSTM、A-BiLSTM、BiLSTM 三种方法的数据召回率分别为 95.63%、90.08% 和 88.95%。CNN-A-BiLSTM 的数据召回率比 A-BiLSTM、BiLSTM 分别高出 5.55%、6.68%。由图 8 (b) 可知, 在电机故障诊断准确率对比中, CNN-A-BiLSTM、A-BiLSTM、BiLSTM 三种方法的准确率平均值分别为 96.73%、90.18% 和 89.66%。CNN-A-BiLSTM 的故障诊断准确率比 A-BiLSTM、BiLSTM 分别高出 6.55%、7.07%。

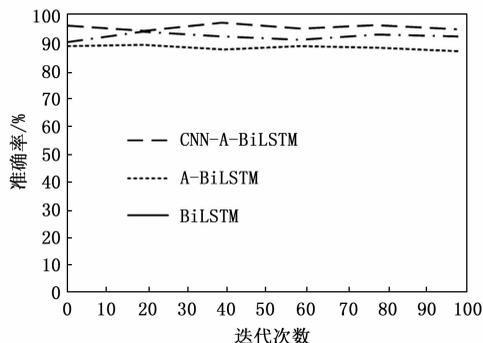
通过消融实验的对比发现, 3 种方法中 CNN-A-BiLSTM 的诊断性能最稳定, 在数据召回率和故障诊断准确率的对比中均优于对比方法。这说明研究利用 CNN-A-BiLSTM 构建故障诊断模型是可行的, 且诊断性能得到了显著提升。

3 结束语

随着科技的不断进步, 无刷直流电机已成为现代工业生产中重要动力装置之一, 由于其应用场景多为结构复杂的电机组, 因此存在检修困难的问题。电机组中复杂的电流会产生一定的电磁干扰, 从而影响无刷直流电机的正常运转, 因此对电机进行运作状态诊断是一个十分重要的工作。而传统的电机诊断模型多针对单一影响, 无法在复杂环境中准确判断电机是否处于异常状态。由于传统电机诊断模型存在明显缺陷, 研究采用 CNN 算法和基于 ACO 算法改进的 BiLSTM 算法构建了一个可以在复杂环境中实现电机运作状态准确判定的诊断模型。改进的 BiLSTM 算法可以帮助模型捕捉到电机运行时更详细的信息, 而 CNN 算法的全连接层具有强大的特征融合能力, 因此两种算法进行融合后可以精确地分析出无刷直流电机的运行状态,



(a) 三种方法的数据处理中召回率对比结果



(b) 三种方法的故障诊断准确率对比结果

图 8 3 种方法在电机故障诊断中召回率与准确率对比结果

从而提高模型的诊断准确率。经实验得出, CNN-A-BiLSTM 模型在机电设备故障诊断数据集上的平均收敛时间为 8.91 min, 比 PSO-ELM 模型低 4.78 min; 比 MSK-CNN 模型低 2.63 min。而在电机故障数据集上 CNN-A-BiLSTM 模型的平均收敛时间为 12.66 min; PSO-ELM 模型的平均收敛时间为 16.95 min; MSK-CNN 模型的平均收敛时间为 15.77 min, CNN-A-BiLSTM 模型的平均收敛时间依然最低。此外, CNN-A-BiLSTM 模型的 F_1 值为 84.17%, 明显高于 MSK-CNN 模型的 83.30% 和 PSO-ELM 模型的 79.09%。研究还进行了 PR 曲线、故障前后电压检测情况的输出对比, 实验结果均显示 CNN-A-BiLSTM 模型比对照模型具有更优的性能, 因此得出 CNN-A-BiLSTM 模型具有较高的先进性。但在研究中也发现了 CNN-A-BiLSTM 模型存在的不足之处, CNN-A-BiLSTM 模型在训练过程中易出现依赖训练样本的情况, 因此后续研究可针对简化模型训练和优化训练数据集做进一步讨论, 从而构建一个更完善的电机状态诊断识别模型。

参考文献:

- [1] 康鹏, 金健, 严伟. 基于改进 GWO-PID 无刷直流电机控制策略 [J]. 制造业自动化, 2023, 45 (8): 147-152.
- [2] 田双文, 刘雪松, 刘佳, 等. 基于无刷直流电机控制器设计 [J]. 计算机测量与控制, 2023, 31 (5): 132-138.

(下转第 148 页)