



基于 PSO 优化 DSCNN-LSTM-SA 的 有载分接开关挡位识别方法

石延辉¹, 阮彦俊¹, 李良创¹, 张博¹, 夏卯², 骆钊², 袁开文², 黄一超², 鲁思兆^{2**}

(1. 中国南方电网有限责任公司 超高压输电公司广州局, 广东 广州 510000;

2. 昆明理工大学 电力工程学院, 云南 昆明 650500)

摘要:有载分接开关(on-load tap-changer, OLTC)在电力系统中扮演着至关重要的角色,其挡位的准确识别对电网稳定运行、智能运维以及故障诊断具有重要意义.深入分析 OLTC 在正常工况下不同挡位切换所产生的振动信号,提出基于粒子群算法(particle swarm optimization, PSO)、深度可分离卷积(deeply separable convolutional neural network, DSCNN)、长短期记忆(long short-term memory, LSTM)网络与自注意力(self-attention, SA)机制相结合的 OLTC 挡位识别方法.首先,对 OLTC 顶盖的振动信号进行逐点卷积以获取信号跨通道特性,并通过 DSCNN 提取局部特性;然后,构建 LSTM 提取振动信号的时间序列特征,并借助 SA 的权重自适应分配能力筛选出关键特征作为分类依据;最后,利用 PSO 寻找模型最优参数.实验结果表明,所提方法相比于主流分类算法具有更好的抗噪性能和更高的挡位识别准确率.

关键词:有载分接开关;挡位识别;智能运维;卷积神经网络;长短期记忆网络

中图分类号:TP391 **文献标志码:**A **文章编号:**0258-7971(2025)03-0454-11

为适应电网负荷波动、电压变化以及维持电力系统的稳定性和可靠性,需要依赖有载分接开关(on-load tap-changer, OLTC)切换挡位对输出电压进行动态调整^[1-3].研究不同切换动作下振动信号的差异,对于构建基于振动信号的 OLTC 在线监测和故障预警系统具有重要的意义^[4].

目前,国内学者对 OLTC 的奇-偶数挡和偶-奇数挡切换,以及部分挡位切换产生的振动信号进行了初步研究.在文献[4]中,分析了振动信号的有效值、前三阶模态分量的峭度均值、频谱重心、时频矩阵变异系数和持续时间等特征,揭示了同一台 OLTC 在切换和分接选择器操作时不同挡位的局部离群因子(local outlier factor, LOF)存在差异.文献[5]通过功率特征矩阵计算了在相同条件下奇数挡位和偶数挡位切换时振动信号的相似性,得出正向和反向切换过程中存在良好的重复性.文

献[6]采用递归率(recurrence, RR)、层流动性(laminarity, LAM)、确定性(determinism, DET)3个指标判断 OLTC 的3种工况.上述研究大多集中在挡位相关的特征分析,缺乏对全挡位识别的分析研究.

传统的机器学习方法通常首先需要进行监测信号的特征工程处理,然后建立特征与标签之间的关联.这种方法依赖于手动设置特征,OLTC 振动信号具有对初始条件的高度敏感性、确定性,但不可预测性和非线性动力学行为等混沌特性.传统特征提取方法存在的问题主要包括:①传统线性分析无法捕捉到信号中的非线性和复杂动态特性;②难以分离噪声和混沌成分;③混沌系统通常在高维相空间中演化,计算复杂性较高^[7-13].在基于混沌分析的 OLTC 故障诊断方法中,文献[10]利用振动信号的混沌特性,采用相空间重构方法构建高维相轨图,以相点空间分布系数作为特征定量分析

收稿日期:2024-04-28; 接受日期:2024-10-06; 网络出版日期:2024-11-06

基金项目:国家自然科学基金(51907084);云南省应用基础研究计划(202201AT070155);中国南方电网广州超高压有限责任公司科技项目(0101002022030301SB00054).

作者简介:石延辉(1981-),男,广东人,高级工程师,主要研究超高压直流输电. E-mail: shiyanhui@im.chv.csg.

** 通信作者:鲁思兆(1985-),男,云南人,副教授,主要研究电气设备高压试验及故障诊断、模块化多电平变流器、电力电子变压器、高频高效 DC/DC 变换器. E-mail: lusz10@kust.edu.cn.

OLTC 的机械状态, 但该系数没有考虑点分布的矢量性. 文献 [11] 采用 K-means 聚类方法对相空间相点聚类, 以簇中心位置矢量为特征, 但由于 K-means 算法本身的缺陷, 使得计算结果不具备规律性, 从而导致 OLTC 的故障诊断结果不精确. 相比之下, 基于深度学习的分类方法可以实现信号端到端检测, 以卷积神经网络 (convolutional neural network, CNN) 为代表的故障分类方法取得了显著效果. 然而, CNN 存在计算量较大和忽略振动信号时间特征等问题, 深度可分离卷积神经网络 (deeply separable convolutional neural network, DSCNN) 通过并行卷积的方式大大减小了计算量, 长短期记忆 (long short-term memory, LSTM) 网络能够更有效地捕捉数据中的长距离依赖关系, 将 DSCNN 与 LSTM 结合有望提高模型的分类准确率和测试速度.

针对缺少全挡位识别方法、挡位识别应用研究较少、CNN 存在计算量较大和忽略振动信号时间特征等问题, 本文提出一种基于粒子群算法 (particle swarm optimization, PSO)、DSCNN、LSTM 与自注意力 (self-attention, SA) 机制相结合的 OLTC 挡位识别方法. 首先, 采用逐点卷积和 DSCNN 分别捕捉跨通道和局部空间特性, 同时有效压缩数据长度降低模型参数量; 然后, 采用级联 LSTM 对数据进行时间特征提取, 并利用 SA 权重自适应分配能力筛选出关键特征作为分类依据; 最后, 利用 PSO 寻找最优模型参数. 算例分析表明, 相比于主流分类算法, 本文算法具有更好的抗噪性能和更高的挡位识别准确率.

1 振动信号分析

1.1 OLTC 动作原理 UCL 型 OLTC 主要包括电动机构、切换开关和选择开关^[14], 其结构如图 1 所示. 在进行挡位切换时, 遵循先选择后切换的原则. 首先, 选择开关预选挡位, 动作由两个槽轮 (即马氏间歇机构) 交替驱动两个动触头联动轴而完成. 接着, 切换开关动作 (以图 1 中右侧切换至左侧为例), 切换开关动作包含: ①右侧主触头与右侧静触头分离; ②右侧过渡触头与右侧静触头分离; ③左侧过渡触头与左侧静触头接触; ④左侧主触头与左侧静触头接触. 切换开关是四连杆自锁机构, 其触头系统为摆臂式设计, 在进行换挡操作时切换开关为左右摆动, 撞击同一侧时产生的振动信号大致相同. 最后, 选择开关动作. 选择开关的结构包括: ①动触

头安装于选择开关中心轴上, 其动作由选择器中心的驱动轴驱动, 定触头环绕安装于中心轴周围; ②根据调压需求, 动触头会有 1 个、2 个或多个触头臂并联, 每个触头臂又有 1 个、2 个或 4 个触头夹片^[14]. 根据选择开关的结构和动作原理, 不同挡位切换时静触头的位置不同, 传导到顶盖的振动信号也不同, 因此可以利用挡位与振动信号的对应关系来进行挡位识别.




图 1 UCL 型 OLTC 结构
Fig. 1 UCL type OLTC structure

1.2 数据说明 在南网超高压某换流站备用换流变上开展样机测试, 将 4 路型号为 AD100T、灵敏度 100 mV/g、量程 ± 50 g、频率范围 20 Hz ~ 20 kHz 的振动加速度传感器安装在 OLTC 顶部测试切换产生的振动信号, 每个挡位测试 50 组, 振动传感器安装位置如图 2 所示.



图 2 振动传感器安装图
Fig. 2 The installation diagram of vibration sensor

1.3 基于切换时序图的 OLTC 奇、偶挡切换分析

振动传感器接收到的奇、偶挡切换振动信号的快慢与振动传感器安装位置有关. 若振动传感器离奇-偶数侧近则切换时间较短, 反之, 若振动传感器离奇-偶数侧远则切换时间较长. 可以利用这一原则对奇、偶挡进行识别, 将通道 1 采集到的挡位连

续切换时序按照挡位上行和下行分开绘制,如图 3 所示。

利用图 3 时序图计算挡位切换时间,为消除起始采集时间产生的影响,上行剔除/-6/-5 挡,下行剔除 20/19 挡,动作时间为:

$$t_i = (x_{i+1} - x_i) / f, \quad (1)$$

式中: t_i 为 i 次挡位切换的时间, x_{i+1} 和 x_i 分别为后一挡位和前一挡位振动信号最大值的横坐标, f 为数据采集卡频率。

根据式 (1), 计算得到如图 4 所示的挡位状态与切换时间对应关系图。从图 4 中可以看出上行和下行切换时奇-偶数挡动作时间为 6 s 以上, 偶-奇

数挡动作时间为 6 s 以下。说明通道 1 传感器靠近奇数挡位侧, 借此可以区分奇-偶数挡和偶-奇数挡, 符合切换开关左右摆动的工作原理。

1.4 基于波形因子的 OLTC 不同挡位振动信号分析 OLTC 动作持续时间为 40 ~ 52 ms, 将原始振动信号裁剪为 0.2 s 进行分析。波形因子通常定义为一个信号有效值与平均绝对值之比, 用于量化波形偏离正弦波的程度, 计算公式为:

$$X = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}, \quad (2)$$

$$K = X / \frac{1}{N} \sum_{i=1}^N x_i, \quad (3)$$




图 3 挡位切换时序图
Fig. 3 Gear shift timing diagram




图 4 挡位切换时间

Fig. 4 Gear shift time

式中: K 为波形因子, X 为信号均方根值, N 为采样总点数, x_i 为振动信号。

基于波形因子对 3 组振动信号提取时域特征, 每组振动信号包括 26 个挡位的上行和下行操作, 利用式 (2) 和 (3) 计算出 3 组振动信号的波形因子, 如图 5 所示。图 5 中, 横坐标 1, 2, $\dots$, 26 分布代表挡位切换动作 $-6/-5(20/19)$, $-5/-4(19/18)$, $\dots$, $19/20(-5/-6)$; (a)、(b)、(c) 分别表示 3 组信号的波形因子。

由图 5 中 3 组样本的波形因子分布, 可知:

- (1) 上行挡位变换产生的振动信号的波形因子普遍低于下行变换时的波形因子;
- (2) 通过比较图 5 中 (a)、(b)、(c) 3 个图, 可

以评估 3 组振动信号之间的相似性, 无论是上行还是下行, 它们都遵循着相似的变化趋势;

(3) 通过比较 3 组不同的数据样本, 同一挡位的波形因子之间的差异很小, 每个切换动作的振动特性是稳定的, 这表明不同的测试或观测集合在相同挡位的振动特性上有着一致的波形因子响应。

综上, 挡位上行和下行的振动信号的波形因子不同, 但这种差异表现在不同样本是相似的, 这一相同的变化趋势为区分挡位的变化提供了可靠的依据。然而, 依赖基于时域图的奇、偶挡识别和基于波形因子的上、下行识别只能将振动信号大致归类到某一个挡位范围, 无法识别出具体的挡位。由于同一挡位振动信号的波形因子变化很小, 这表




图 5 不同挡位振动信号的波形因子

Fig. 5 Differential vibration signal waveform factors

明相同挡位切换动作之间可能存在某种内在联系,可借助深度学习算法,通过分析大量的数据样本,挖掘出不同挡位之间更深层次的关系。

2 模型设计

2.1 空间特征提取模块 分组卷积是一种卷积神经网络的操作方法,旨在降低计算量和参数量,同时保持模型的识别准确率。该方法将输入特征图分成多个组,并在每个组内单独进行卷积运算。与标准卷积不同,标准卷积中的每个卷积核对输入特征图的所有通道进行操作,而分组卷积则将输入特征图分成多个组,对每个卷积组独立进行卷积操作。图 6 为常规卷积与分组卷积的对比,分组卷积可减少参数量,若分成 N 组,则参数量减少为原来的 $1/N$,当划分的组数与通道数相同时卷积操作最高效,即 DSCNN。

2.2 时间特征提取模块 LSTM 在序列数据处理、自然语言处理、时间序列分析和语音识别等领域




图 6 标准卷积与分组卷积

Fig. 6 Standard convolution and group convolution

得到广泛运用,其网络基本单元如图 7 所示,图中 f_t 、 i_t 、 o_t 是遗忘门、输入门和输出门, c_{t-1} 为上一阶段状态, h_{t-1} 为上一时刻输出, x_t 为当前状态, S 为 sigmoid 函数, $\tilde{c}_{t-1}$ 为输入门筛选的候选值, c_t 为下一阶段状态, h_t 为当前时刻的输出。遗忘门决定何时丢弃先前的状态,受前一个时间输出 h_{t-1} 、当前输入 x_t 和遗忘权重矩阵的影响,主要通过 sigmoid 函数输出一个介于 0 和 1 之间的值来确定哪些信息应被舍弃。输入门则负责筛选新信息,通过 sigmoid 函数和 tanh 函数处理当前输入 x_t 和前一个状态 h_{t-1} 以确定哪些信息将添加到网络。状态本身也会根据遗忘门和输入门的输出进行相应的更新,从而在记忆单元中维护长期的有用信息。最后,输出门负责控制记忆单元的输出,它根据当前输入 x_t 和状态调整生成 LSTM 的最终输出。这 3 个门控单元协同工作,确保 LSTM 能够捕捉长期的依赖关系并有效地控制信息的流动^[15-17]。




图 7 LSTM 网络基本单元

Fig. 7 The basic unit of LSTM network

LSTM 每个输出的计算方法为:

$$\begin{cases} f_t = s(\omega_f[h_{t-1}, x_t] + b_0), \\ i_t = s(\omega_i[h_{t-1}, x_t] + b_1), \\ \tilde{c}_{t-1} = \tanh(\omega_c[h_{t-1}, x_t] + b_2), \\ c_t = f_t \times c_{t-1} + i_t \times \tilde{c}_{t-1}, \\ o_t = s(\omega_o[h_{t-1}, x_t] + b_3) \\ h_t = o_t \times \tanh(c_t), \\ y_t = s(\omega_t h_t), \end{cases} \quad (4)$$

式中: ω_f 、 ω_i 、 ω_o 、 ω_c 、 ω_t 为对应门和输入单元权重, b_0 、 b_1 、 b_2 、 b_3 为对应门和输入单元偏置。

2.3 SA 机制 SA 是深度学习中的一种技术, 广泛应用于自然语言处理和图像处理任务中. 它通过计算输入序列中每个元素与其他元素之间的相关性来捕捉远距离依赖关系, 从而增强模型的代表能力, 图 8 为 SA 基本单元^[18-19].




图 8 自注意力机制网络基本单元

Fig. 8 Self-attention mechanism network basic unit

SA 的核心步骤主要包括: ①计算查询向量 q 、匹配向量 k 、输出向量 v ; ②使用 q 和 k 计算注意力得分 $a_{1,j}$, 并利用 softmax 函数进行归一化, 得到注意力权重 $a'_{1,j}$; ③加权求和得到输出 b^i 。

2.4 PSO 算法 PSO 算法通过在搜索空间中初始化一群随机粒子, 每个粒子代表一个潜在解. 每个粒子在空间中有一个位置和速度, 位置代表当前解, 速度决定粒子的移动方向和距离. 粒子根据自身的经历(个体最佳位置)和群体的经历(全局最佳位置)不断调整速度和位置, 从而逐步逼近最优解^[20]. 具

体计算公式为:

$$v_i(t+1) = \omega \cdot v_i(t) + c_1 \cdot r_1 \cdot (p_i - x_i(t)) + c_2 \cdot r_2 \cdot (g - x_i(t)), \quad (5)$$

$$x_i(t+1) = x_i(t) + v_i(t+1), \quad (6)$$

式中: v_i 、 x_i 分别为粒子 i 的速度位置, w 为惯性权重, c_1 和 c_2 为学习因子, r_1 和 r_2 为在 0 到 1 之间的随机数, p_i 为粒子 i 的个体最佳位置, g 为所有粒子全局最佳位置。

2.5 辅助智能运维 实际运行中 OLTC 的切换挡指令均有记录, 利用 PSO-DSCNN-LSTM-SA 模型进行挡位识别是从数据方面确定挡位并与实际挡位指令进行比较, 从而达到辅助运维的目的, 其流程如图 9 所示. 首先, 获取传感器实时 OLTC 振动数据, 并对数据进行裁剪和降噪处理. 为了提高数据处理效率, 对振动数据进行了挡位上行和下行分类, 将数据与挡位上下行状态关联起来. 接着将初次分类的振动信号进行还原, 并将其输入到相应的挡位识别模型. 最后, 将识别出的挡位与实际操作指令对比, 若存在差异, 系统将发出预警信息。




图 9 辅助智能运维

Fig. 9 Assisted intelligent maintenance

2.6 PSO-DSCNN-LSTM-SA 识别流程 基于 PSO-DSCNN-LSTM-SA 的挡位识别网络结构如图 10 所




图 10 PSO-DSCNN-LSTM-SA 网络结构

Fig. 10 The PSO-DSCNN-LSTM-SA network structure

示. 首先, 通过数据处理获得目标样本, 接着利用序列折叠层保留信号的时间特性, 并将处理后的信号输入到提取空间特性的卷积模块. 卷积模块通过逐点卷积对 4 个传感器的数据进行跨通道特征提取, 以增强信号的空间全局特征. 为了加快模型的识别速度和减少参数量, 采用 DSCNN 进行并行卷积操作, 并对特征进行融合. 在此基础上, 通过级联 LSTM 提取信号的时间特性, 并增加 SA 注意力机制, 使模型能够筛选出关键特征作为分类依据. 最后, 利用 PSO 算法对模型的学习率和隐藏层数进行寻优. 相比于更复杂的深度学习网络, 该模型的分层结构更为简单, 速度更快, 能够及时、准确地实现挡位识别.

3 实验及结果分析

3.1 数据预处理 为减小特征提取造成振动信号特征的丢失并提高挡位识别的效率, 对裁剪后保留的 0.2 s 振动信号进行两个阶段的分类. 第一阶段将数据划分为挡位上行和下行两种, 每个挡位利用 3 次测试的数据(3×26 个挡, 3×26 个挡)进行分析, 共有 156 个样本和 2 个标签, 上行标签为 1, 下行标签为 2. 在初次分类后建立挡位上行(下行)具体挡位识别模型, 挡位上行和下行分别有 1 300 个样本(50×26)和 26 个标签(26 个挡位), 表 1 为挡位上行(下行)具体挡位与标签的对应关系.

为改善模型的训练效果并加速收敛, 将数据从原始范围映射到 [0, 1] 范围, 文中选用离散标准化公式, 计算方法为:

$$Y_{\text{normalized}} = \frac{Y - Y_{\min}}{Y_{\max} - Y_{\min}}, \quad (7)$$

式中: Y 为原始数据, $Y_{\min}$ 和 $Y_{\max}$ 分别为数据的最小值和最大值, $Y_{\text{normalized}}$ 为归一化后的值.

表 1 具体挡位变化对应的标签

Tab. 1 The label corresponding to the specific gear change

上(下)行挡位变化	标签	上(下)行挡位变化	标签
-6/-5(20/19)	1	7/8(7/6)	14
-5/-4(19/18)	2	8/9(6/5)	15
-4/-3(18/17)	3	9/10(5/4)	16
-3/-2(17/16)	4	10/11(4/3)	17
-2/-1(16/15)	5	11/12(3/2)	18
-1/0(15/14)	6	12/13(2/1)	19
0/1(14/13)	7	13/14(1/0)	20
1/2(13/12)	8	14/15(0/-1)	21
/3(12/11)	9	15/16(-1/-2)	22
3/4(11/10)	10	16/17(2/-3)	23
4/5(10/9)	11	17/18(-3/-4)	24
5/6(9/8)	12	18/19(-4/-5)	25
6/7(8/7)	13	19/20(-5/-6)	26

3.2 评价指标 在 Matlab 中搭建深度学习模型, 选取准确率和损失函数作为判断模型的指标, 计算方法为:

$$\begin{cases} A = \frac{T_P + T_N}{T_P + T_N + F_P + F_N}, \\ L = -\frac{1}{N} \sum_{i=1}^N L_i \log(\hat{L}_i), \end{cases} \quad (8)$$

式中: A 为准确率, L 为损失值, T_P 为真正例, T_N 为真负例, F_P 为假正例, F_N 为假负例, $\hat{L}_i$ 为样本 i 的真实标签, N 为样本数.

3.3 PSO 对各模型的寻优结果 利用 PSO 分别对模型的学习率和隐藏层个数进行寻优, 有助于找出最优模型参数, 提高模型的挡位识别准确率. 经多次迭代, 初步确定学习率寻优范围为 [0.000 1, 0.000 9], LSTM 层寻优范围为 [10, 200], 迭代 20 次找出模型最优参数, 结果如表 2 所示. 表 2 中参数分别表示

表 2 各模型参数的寻优结果

Tab. 2 Optimization results of each model parameter

模型	学习率	隐藏层数	测试时间/s
DSCNN-LSTM-SA	0.000 9/0.000 64/0.000 65	77/145/145	0.079/0.243 0/0.243
CNN-LSTM-SA	0.000 5/0.000 63/0.000 53	77/126/117	0.089/0.320 0/0.311
DSCNN-LSTM	0.000 89/0.000 86/0.000 86	72/170/170	0.069/0.217 0/0.217
DSCNN	0.000 64/0.000 18/0.000 17		0.048/0.038 0/0.038
CNN-LSTM	0.000 9/0.000 159/0.000 16	130/126/120	0.095/0.341 7/0.357
CNN	0.000 618/0.000 68/0.000 40		0.12/0.370 0/0.370
LSTM	0.000 75/0.000 42/0.000 50	182/53/60	0.035/0.095 0/0.096

挡位上下行分类, 上行具体挡位和下行具体挡位分类的模型参数, 粗体为文中所提模型“DSCNN-LSTM-SA”的参数, 空白表示不存在的参数. 由表 2 可知, 采用 DSCNN 并行卷积操作的模型相比于采用 CNN 的模型, 其测试时间显著缩短, 因此 DSCNN、DSCNN-LSTM 和 DSCNN-LSTM-SA 测试时间低于 CNN. 需要指出的是 DSCNN-LSTM-SA 由于加入 LSTM 和 SA 自注意力机制, 其测试时间高于 LSTM、DSCNN-LSTM 和 DSCNN, 但是仿真实验结果表明 DSCNN-LSTM-SA 模型的识别准确率显著高于 LSTM、DSCNN-LSTM 和 DSCNN (表 3).

3.4 抗噪性分析 OLTC 时刻运行在含有噪声干扰的环境中, 为符合实际情况, 本节利用 Matlab 中

的 `awgn` 函数在采集的振动信号中加入 40、30、20 dB 的随机噪声, 并在不同噪声干扰条件下测试模型的性能. 限于篇幅, 仅展示 DSCNN-LSTM-SA 对挡位上下行和上行具体挡位的识别情况. 图 11(a) 和(b)分别为 DSCNN-LSTM-SA 在加入 20 dB 噪声干扰条件下的挡位识别情况. 从图 11 中可看出即使是在加入 20 dB 噪声的情况下, 文中所提方法仍具有较高的挡位识别准确率.

3.5 消融试验 为验证文中所提模型对直流换流变 OLTC 挡位识别的有效性, 将 DSCNN-LSTM-SA 与 DSCNN-LSTM、DSCNN、CNN-LSTM 等模型的验证集迭代曲线进行对比, 如图 12 所示. 图 12(a) 是 7 种模型挡位下行具体挡位识别的验证集准确率, 图 12(b) 是各模型验证集的损失值. 从图 12(a)

表 3 不同噪声干扰情况下各模型的准确率对比

Tab. 3 Comparison of the accuracy of different models under various noise interference conditions

%

识别方法	噪声											
	无噪声			40 dB			30 dB			20 dB		
	上下行	上行具体挡位	下行具体挡位	上下行	上行具体挡位	下行具体挡位	上下行	上行具体挡位	下行具体挡位	上下行	上行具体挡位	下行具体挡位
LSTM	91.320	92.308	92.405	90.488	92.175	92.095	90.460	91.795	90.433	87.760	89.076	86.576
CNN	86.960	96.154	96.141	86.154	95.617	95.142	92.180	94.130	95.158	94.540	94.826	93.025
DSCNN	96.834	96.154	96.225	95.132	95.418	95.297	93.157	94.365	95.407	91.220	92.821	91.770
CNN-LSTM	97.834	97.612	97.950	97.834	96.166	95.496	94.980	96.410	96.033	95.780	93.077	94.069
CNN-LSTM-SA	99.834	98.096	98.122	98.765	97.516	97.057	97.833	97.179	96.504	96.070	95.652	95.164
DSCNN-LSTM	99.834	98.944	98.174	98.651	98.315	98.450	96.167	96.154	95.317	95.340	94.308	93.076
DSCNN-LSTM-SA	99.834	99.487	99.295	99.106	99.742	99.612	98.290	98.483	98.734	97.500	97.650	97.583




图 11 20 dB 噪声干扰下 DSCNN-LSTM-SA 分类结果

Fig. 11 Classification results of DSCNN-LSTM-SA under 20 dB noise interference




图 12 20 dB 噪声干扰下各模型的验证集迭代曲线

Fig. 12 Validation set iteration curves of each model under 20 dB noise interference

可以看出,所有模型在迭代开始时验证集的准确度都在增加,迭代 15 次后文中所提方法 DSCNN-LSTM-SA 准确率达到 90% 以上,迭代 20 次后 CNN-LSTM-SA 准确率达到 90% 以上,迭代 60 次后 DSCNN-LSTM 趋于稳定,迭代 80 次后 CNN-DSCNN 和 LSTM 趋于稳定,迭代 90 次后 CNN 趋于稳定,文中所提方法最先达到 90% 以上准确率。从图 12(b) 可以看出 DSCNN-LSTM-SA 和 CNN-LSTM-SA 损失值最低,且 DSCNN-LSTM-SA 最先达到稳定值。

为减小实验偶然性,选取 20 次仿真实验中测试集平均准确率作为最终模型的识别准确率,结果如表 3 所示。由表 3 可知,在 4 种噪声干扰情况下 LSTM 的准确率最低;CNN 准确率低于 DSCNN,表明在加入逐点卷积进行跨通道特征提取后准确率得到提升,DSCNN 通过并行卷积操作减小了模型的计算量,从而提高了模型的测试速度;CNN-LSTM 混合模型结合了 CNN 空间特征提取能力和 LSTM 时间特征提取能力,表现优于 CNN、LSTM 和 DSCNN;DSCNN-LSTM 由于加入逐点卷积模块,能充分获取各传感器的关联关系,准确率略优于 CNN-LSTM。值得注意的是,DSCNN-LSTM-SA 在 4 种噪声干扰下的挡位上下行识别模型和挡位上行(下行)具体挡位识别模型的平均分类准确率达到 97% 以上,准确率最高,表明了 DSCNN-LSTM-SA 能充分获取时间和空间特性,SA 能利用自适应权重抑制无效特征,加入逐点卷积的 DSCNN 模块对通道的特征提取能力更强。

4 结论

本文针对正常工况下 OLTC 全挡位识别研究

较少、不同挡位振动信号时频域特征不明显、实际系统中挡位指令缺乏反馈验证的问题,对振动信号进行深入分析提出了基于 PSO 优化 DSCNN-LSTM 的 OLTC 挡位识别方法,通过实验及结果分析得出以下结论:

(1)可分别利用挡位切换时序图和波形因子判断奇、偶挡和挡位上下行。

(2)对不同挡位振动信号差异性进行分析,提出了利用深度学习对 OLTC 正常工况下挡位状态进行识别的方法,与操作指令相互补充,夯实智能运维。

(3)为保留振动信号丰富的时空特性,将 DSCNN 模块、LSTM 和 SA 结合,建立 PSO 优化 DSCNN-LSTM-SA 混合模型,对 OLTC 挡位进行两个阶段的分类,分别训练了挡位上下行识别模型和挡位上行(下行)具体挡位识别模型。实验结果表明,DSCNN-LSTM-SA 模型在两阶段分类中准确率最高,在保证挡位识别准确率的前提下测试速度最快,并且在不同噪声干扰条件下仍能保持 97% 以上准确率,具有良好的抗噪性能。

参考文献:

- [1] Zhu T X, Tso S K, Lo K L. An investigation into the OLTC effects on voltage collapse[J]. *IEEE Transactions on Power Systems*, 2000, 15(2): 515-521. DOI: 10.1109/59.867134.
- [2] 丁国成, 杨海涛, 李博宇, 等. 有载分接开关瓦斯继电器动作特性试验研究 [J]. *高压电器*, 2023, 59(4): 156-161.
- Ding G C, Yang H T, Li B Y, et al. Experimental study on action characteristics of on-load tap-changer gas relay[J]. *High Voltage Apparatus*, 2023, 59(4): 156-161.

- [3] 汪可, 王若溪, 李刚, 等. 有载分接开关高效切换试验技术研究 [J]. 中国电机工程学报, 2023, 43(24): 9 752-9 763.
Wang K, Wang R X, Li G, et al. Research on high-efficiency switching test technology of on-load tap changer [J]. Proceedings of the CSEE, 2023, 43(24): 9 752-9 763.
- [4] 张知先. 变压器有载分接开关振动信号分析与状态诊断方法研究 [D]. 重庆: 重庆大学, 2019.
Zhang Z X. Research on vibration signal analysis and status diagnosis method of transformer on load tap changer[D]. Chongqing: Chongqing University, 2019.
- [5] 段若晨. 基于多特征分析的换流变用有载分接开关机械状态评估研究 [D]. 上海: 上海交通大学, 2016.
Duan R C. Research on mechanical state evaluation of on-load tap-changer for commutation based on multi-feature analysis[D]. Shanghai: Shanghai Jiaotong University, 2016.
- [6] 樊家昊, 王丰华, 郑一鸣, 等. 基于递归定量分析的有载分接开关机械状态监测 [J]. 高压电器, 2019, 55(11): 197-203.
Fan J H, Wang F H, Zheng Y M, et al. Mechanical condition monitoring of on-load tap-changer based on recursive quantitative analysis[J]. High Voltage Apparatus, 2019, 55(11): 197-203.
- [7] 郑尚直. 基于多源数据融合的有载分接开关状态评估系统研究 [D]. 南京: 东南大学, 2022.
Zheng S Z. Research on on-load tap-changer state evaluation system based on multi-source data fusion[D]. Nanjing: Southeast University, 2022.
- [8] 赵彤. 有载分接开关机械状态的在线监测与故障诊断技术研究 [D]. 济南: 山东大学, 2008.
Zhao T. Research on on-line monitoring and fault diagnosis technology of mechanical state of on-load tap-changer[D]. Jinan: Shandong University, 2008.
- [9] 吴晓欣, 何怡刚, 段嘉珺, 等. 考虑复杂时序关联特性的 Bi-LSTM 变压器 DGA 故障诊断方法 [J]. 电力自动化设备, 2020, 40(8): 184-193.
Wu X X, He Y G, Duan J J, et al. DGA fault diagnosis method of Bi-LSTM transformer considering complex timing correlation characteristics[J]. Electric Power Automation Equipment, 2020, 40(8): 184-193.
- [10] 赵彤, 李庆民, 陈平. OLTC 振动信号特征提取的动力学分析方法 [J]. 电工技术学报, 2007(1): 41-46. DOI: 10.3321/j.issn:1000-6753.2007.01.008.
Zhao T, Li Q M, Chen P. A dynamic analysis method for feature extraction of OLTC vibration signals[J]. Transactions of China Electrotechnical Society, 2007 (1): 41-46.
- [11] 马旭聪, 唐文虎, 牛哲文, 等. 非均衡数据集下基于孪生卷积网络的变压器绕组变形故障识别方法 [J]. 高压电器, 2023, 59(10): 120-128.
Ma X C, Tang W H, Niu Z W, et al. Fault identification method of transformer winding deformation based on twin convolutional network under non-equilibrium dataset[J]. High Voltage Apparatus, 2023, 59(10): 120-128.
- [12] 杨洪苏, 马宏忠, 薛健侗. 基于混沌理论与麻雀优化 K-means 算法的变压器铁心松动缺陷分析方法 [J]. 科学技术与工程, 2024, 24(25): 10 798-10 807.
Yang H S, Ma H Z, Xue J T. Analysis method of transformer core loosening defect based on chaos theory and sparrow optimization K-means algorithm[J]. Science Technology and Engineering, 2024, 24(25): 10 798-10 807.
- [13] 郭雄雄. 正交面齿轮传动系统非线性动力学特性 [J]. 内燃机与配件, 2024(21): 31-34.
Guo X X. Nonlinear dynamic characteristics of orthogonal gear transmission system[J]. Internal Combustion Engine and Accessories, 2024(21): 31-34.
- [14] Hitachi Energy Publisher. T-Sync™ UC 型分接开关技术指南 [EB/OL]. (2022-10-04) [2024-10-16]. <https://publisher.hitachienergy.com/preview?DocumentID=1ZSC000562-AAW&LanguageCode=zh&Document-PartId=&Action=launch&DocumentRevisionId=C>.
- [15] 刘占磊, 祝令瑜, 占草, 等. 基于 CNN-Bi LSTM 的铁氧体磁芯损耗精确模型和小样本迁移学习预测方法 [J]. 高电压技术, 2024, 50(10): 4 487-4 498.
Liu Z L, Zhu L Y, Zhan C, et al. Accurate model of ferrite core loss based on CNN-Bi LSTM and small-sample transfer learning prediction method[J]. High Voltage Technology, 2024, 50(10): 4 487-4 498.
- [16] 李虹, 韩雨萌. 基于 LSTM-CGAN 的多微网数据驱动分布鲁棒协同优化运行策略 [J]. 电力系统保护与控制, 2024, 52(18): 133-148.
Li H, Han Y M. Data-driven distributionally robust collaborative optimization operation strategy for a multi-microgrid based on LSTM-CGAN[J]. Power System Protection and Control, 2024, 52(18): 133-148.
- [17] 张宇华, 时鑫洋, 颜楠楠, 等. 逆向云灰色关联相似日的 EEMD-RL-GWO-LSTM 区域风光功率短期预测 [J]. 太阳能学报, 2024, 45(10): 144-152.
Zhang Y H, Shi X Y, Yan N N, et al. Short-term prediction of wind and solar power in EEMD-RL-GWO-LSTM region on similar days with grey correlation of inverse clouds[J]. Acta Solarica Sinica, 2024, 45(10): 144-152.
- [18] 刘晓倩, 崔焕勇, 刘海宁, 等. 融合多特征选择和自注

- 意力机制的 LSTM 燃料电池退化预测方法 [J]. 电子测量与仪器学报, 2024, 38(5): 219-228.
- Liu X Q, Cui H Y, Liu H N, et al. LSTM fuel cell degradation prediction method based on multi-feature selection and self-attention mechanism[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(5): 219-228.
- [19] 李婷, 赵尔敦, 杨军. 基于自注意力与双向特征融合的道路障碍物检测方法 [J]. 计算机科学, 2024, 51(S2): 287-291.
- Li T, Zhao E D, Yang J. Road obstacle detection method based on self-attention and two-way feature fusion [J]. Computer Science, 2024, 51(S2): 287-291.
- [20] 郭艺潭, 贾洪岩, 宋炎侃, 等. 基于 GMM-PSO 混合算法的电磁暂态模型参数校正方法 [J]. 电网技术, 2022, 46(8): 3 240-3 247.
- Guo Y T, Jia H Y, Song Y K, et al. Parameter correction method for electromagnetic transient model based on GMM-PSO hybrid algorithm[J]. Power System Technology, 2022, 46(8): 3 240-3 247.

On-load tap changer switch position recognition method based on PSO optimized DSCNN-LSTM-SA

SHI Yanhui¹, RUAN Yanjun¹, LI Liangchuang¹, ZHANG Bo¹, XIA Mao², LUO Zhao²,
YUAN Kaiwen², HUANG Yichao², LU Sizhao^{2**}

(1. Guangzhou Bureau of EHV Power Transmission Company, China Southern Power Grid Co. Ltd.,

Guangzhou 510000, Guangdong, China;

2. Faculty of Electric Power Engineering, Kunming University of Science and Technology,

Kunming 650500, Yunnan, China)

Abstract: On-load tap changer (OLTC) plays a crucial role in power systems, and accurately identifying its tap positions is important for the stable operation of the power grid, intelligent maintenance, and fault diagnosis. This paper deeply analyzes the vibration signals generated by OLTC under normal operating conditions during different tap position changes and proposes an OLTC tap position identification method that combines particle swarm optimization (PSO), deeply separable convolutional neural network (DSCNN), long short-term memory (LSTM), and self-attention (SA) mechanisms. The vibration signals from the OLTC top cover are first convolved point-by-point to capture cross-channel characteristics, and local features are extracted using DSCNN. LSTM is then used to extract the time-series features of the vibration signals, with the adaptive weighting capability of SA to select key features for classification. Finally, PSO is employed to find the optimal model parameters. The results demonstrate that the proposed method provides better noise resistance and higher tap position identification accuracy compared to mainstream classification algorithms.

Key words: on-load tap changer; gear identification; intelligent operation and maintenance; convolutional neural networks; long short-term memory network