

8-15-2022

Identification of Switching Operation Based on LSTM and MoE

Xiaoqing Zhang

1. Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190, China; 2. College of Computer, Beijing University of Posts and Telecommunications, Beijing 100876, China;

1074913189@qq.com

Wanfang Xiao

3. State Grid Beijing urban power supply company, Beijing 110102, China;

Yingjie Guo

1. Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190, China;

guoyingjie@ict.ac.cn

Bowen Liu

3. State Grid Beijing urban power supply company, Beijing 110102, China;

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Identification of Switching Operation Based on LSTM and MoE

Abstract

Abstract: Aiming at the individual differences of different personnel in the same operation and differences of the same person in the same operation at different times, a *switching operation recognition model (MoE-LSTM) based on Mixture of experts model (MOE) and long short-term memory network (LSTM) is proposed. Based on MoE, LSTM is integrated to learn the feature distribution of different sources data.* The acceleration data is collected to build the switching operation dataset and the action sequence is segmented and aligned based on sliding window. The action sequence is input to MoE-LSTM, and the temporal dependencies of different actions are independently learned by different LSTMs. The gating network selects the output of LSTM that classifies the current input better as the action recognition result. The result of model learning is that for action data from different time and space, different LSTMs perform better in a certain feature area than other LSTMs. The experiments on the switching operation dataset demonstrate superior performance of the proposed method compared to other existing action recognition algorithms.

Keywords

switching operation, long short-term memory network(LSTM), mixture of experts model (MOE), neural network

Authors

Xiaoqing Zhang, Wanfang Xiao, Yingjie Guo, Bowen Liu, Xuesen Han, Jingwei Ma, Gao Gao, He Huang, and Shihong Xia

Recommended Citation

Xiaoqing Zhang, Wanfang Xiao, Yingjie Guo, Bowen Liu, Xuesen Han, Jingwei Ma, Gao Gao, He Huang, Shihong Xia. Identification of Switching Operation Based on LSTM and MoE[J]. Journal of System Simulation, 2022, 34(8): 1899-1907.

融合 LSTM 和 MoE 的倒闸操作识别

张晓青^{1,2}, 肖万芳³, 郭英杰^{1*}, 刘博文³, 韩学森³,
马经纬³, 高高³, 黄赫³, 夏时洪¹

(1. 中国科学院 计算技术研究所, 北京 100190; 2. 北京邮电大学 计算机学院, 北京 100876; 3. 国网北京城区供电公司, 北京 110102)

摘要: 为解决不同人员相同操作的个体差异以及同一人员不同时间相同操作差异的问题, 提出一种基于混合专家系统(*mixture of experts*, MoE)和长短期记忆神经网络(*long short-term memory*, LSTM)的倒闸操作识别方法 MoE-LSTM。基于 MoE 对 LSTM 进行集成, 学习不同来源数据的特征分布。采集加速度动作数据构建倒闸操作数据集, 基于滑动窗口对动作序列进行切分; 将动作序列输入到 MoE-LSTM 中, 由不同 LSTM 独立学习不同动作的时序依赖; 通过门控网络选择对当前输入分类较好的 LSTM 的输出作为动作识别结果。仿真结果表明: 不同 LSTM 对来自不同时空的动作数据都有擅长分类的特征空间。

关键词: 倒闸操作; 长短期记忆神经网络; 混合专家系统; 神经网络

中图分类号: TP391.9

文献标志码: A

文章编号: 1004-731X(2022)08-1899-09

DOI: 10.16182/j.issn1004731x.joss.21-0288

Identification of Switching Operation Based on LSTM and MoE

Zhang Xiaoqing^{1,2}, Xiao Wanfang³, Guo Yingjie^{1*}, Liu Bowen³, Han Xuesen³,
Ma Jingwei³, Gao Gao³, Huang He³, Xia Shihong¹

(1. Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190, China;

2. College of Computer, Beijing University of Posts and Telecommunications, Beijing 100876, China;

3. State Grid Beijing urban power supply company, Beijing 110102, China)

Abstract: Aiming at the individual differences of different personnel in the same operation and differences of the same person in the same operation at different times, a switching operation recognition model(MoE-LSTM) based on Mixture of experts model (MOE) and long short-term memory network (LSTM) is proposed. Based on MoE, LSTM is integrated to learn the feature distribution of different sources data. The acceleration data is collected to build the switching operation dataset and the action sequence is segmented and aligned based on sliding window. The action sequence is input to MoE-LSTM, and the temporal dependencies of different actions are independently learned by different LSTMs. The gating network selects the output of LSTM that classifies the current input better as the action recognition result. The result of model learning is that for action data from different time and space, different LSTMs perform better in a certain feature area than other LSTMs. The experiments on the switching operation dataset demonstrate superior performance of the proposed method compared to other existing action recognition algorithms.

Keywords: switching operation; long short-term memory network(LSTM); mixture of experts model (MOE); neural network

收稿日期: 2021-04-03

修回日期: 2021-05-08

基金项目: 国家重点研发计划(2020YFF0304701); 北京市电力公司科技项目(202021900T7)

第一作者: 张晓青(1997-), 女, 硕士生, 研究方向为运动仿真。E-mail: 1074913189@qq.com

通讯作者: 郭英杰(1990-), 男, 硕士, 研究方向为人体运动仿真建模。E-mail: guoyingjie@ict.ac.cn

引言

随着人工智能和传感器技术的快速发展,基于传感器的动作识别研究成果越来越多地应用在各个领域。在电力运维领域,生命财产安全是重中之重,虽然电力安全设备不断更新迭代,但是电力安全问题一直存在。根据国家能源局公布的安全生产报告^[1],2014—2018年,全国电力行业累计发生人身伤亡事故238起,其中违规违章操作引发的事故有183起,占比76.89%,是导致电力安全事故发生的首要原因。为了提高倒闸操作的监测力度,降低误操作发生的风险,刘培贞等^[2]提出了一种面向电力运维作业的长短期记忆神经网络(long short-term memory, LSTM)动作识别方法;张晓青等^[3]将混合专家系统(mixture of experts, MoE)与卷积神经网络(convolutional neural network, CNN)融合进行倒闸操作识别。为了进一步提高倒闸操作的识别精度和泛化能力,本文将MoE与LSTM进行融合,针对不同人员执行操作的差异,使用MoE模型构建多个专家(Expert)网络处理不同来源的动作数据,提高模型对于未知人员动作识别的效果。针对同一动作不同时间段之间的时序关系,使用LSTM学习动作片段的上下文关系。倒闸操作智能监测过程包括2个阶段:特征学习和实时监测。特征学习过程使用构建的标准倒闸操作数据集进行模型训练;实时监测过程借助手持设备和腕式传感器对操作人员的动作进行识别判断,从而对错误动作进行实时预警。

1 相关研究

随着移动设备中传感器的嵌入越来越普遍,基于传感器来描述人体动作变化进行动作识别成为可能。相比基于视频图像的动作识别,传感器数据如加速度、角速度、位置信息等,能够更为精准有效地刻画某一时刻的动作运动趋势,被广泛用于动作识别研究。现有的传感器类型可分为可穿戴传感器、物体传感器、环境传感器,以及

混合传感器^[4]。根据研究目的不同可以选择不同类型的传感器进行用户行为分析。Gong等^[5]基于可穿戴医疗保健监控传感器网络系统获取被监护人员的脉搏信息,并结合中医脉诊理论实现了对高血压、冠心病、肝硬化和妊娠4种生理状况的监测;Incel等^[6]基于加速度计对手机携带位置进行研究,提取了相关的运动、方向和旋转特征,实现了口袋、腰带、手腕和手臂4个位置的准确检测,为更好地提供手机服务提供依据;徐川龙等^[7]将加速度传感器固定在右前臀,通过对站立、走、跑、上楼、下楼5个日常行为进行数据采集与分析,实现了98%的识别准确率。

传统的机器学习算法虽然复杂度较低,计算效率较高,在多数场景下取得了较好的动作识别效果^[8-11],但是也存在很多的局限性。如需要基于专家经验提取特征、忽略了样本之间的相关性、难以适应大规模数据集等。而深度学习能够基于原始数据或浅层特征表示提取易于区分的高级抽象特征,捕获样本之间的关联关系,并且可以使用GPU对训练过程进行加速。无论是基于视频图像的动作识别还是基于传感器数据的动作识别,深度学习算法相比于传统机器学习算法都更具有优势,尤其是对于大规模的数据集。Murad等^[12]采用深度递归神经网络来捕获人类活动可变长度输入序列中的长期相关性,并在4个人体动作识别基准数据集上进行实验,证明了该模型优于传统的机器学习算法和无时序特征的DBN、CNN等网络模型;刘培贞等^[2]基于三维加速度数据和三维磁场数据使用两层LSTM对倒闸操作过程中的6种动作进行识别,实现了91.32%的准确率;Xia等^[13]提出了一种融合卷积层和LSTM的动作识别模型,在保持高识别率的情况下大大降低了模型的参数,加快了模型收敛速度;Moya等^[14]基于卷积神经网络设计多个并行处理分支,对来自不同身体部位佩戴的多个传感器数据进行特征学习。现有动作识别方法主要存在以下问题:①采取加速度、角速度等多种数据类型进行学习,数据传输、处理、

存储要求高; ②采用单个模型进行动作识别, 无法解决多数据来源的问题, 如来自不同人员的同一类型动作数据、来自同一人员不同时间的同一类型动作数据等; ③佩戴多个传感器会使监测人员感到不适, 影响动作识别效果。针对以上问题, 本文采用加速度数据作为数据来源, 采用MoE集成解决多数据来源的问题, 使用单个腕式传感器进行数据采集。

集成学习通过组合多个弱分类器来提高识别效果, 集成学习的一般思路包括2个过程: 首先使用多个弱分类器得到多个结果; 然后以投票的方式产生最终结果^[15]。常见的集成方法有 Bagging、Boosting。Bagging 通过选取多个样本子集训练多个基础模型; Boosting 通过在训练过程中不断调整样本权重训练多个基础模型。2种方法最终都是通过组合多个模型的结果得到最终结果。与 Bagging 和 Boosting 方法不同的是, MoE 方法中每个基础模型的权重是在模型训练过程中由门控网络基于输入数据学习得到的, 通过权重调节选择有利于样本分类的模型组合, 对于基础模型输出结果的组合更加灵活。MoE 方法提出^[16]后出现了很多改进方案, 也取得了理想的实验效果。俞斌峰等^[17]基于贝叶斯方法和 probit 分类方法提出了稀疏混合专家模型 (sparse bayesian mixture of experts, SME), 该模型使用全贝叶斯的稀疏线性回归模型作为专家模型, 使用稀疏 probit 分类方法对门控网络进行建模, 取得了较好的结果。文献[3]将卷积神经网络与 MoE 模型结合, 每个 Expert 网络使用卷积操作进行数据处理, 解决了针对不同来源动作数据进行模型选择的问题, 但是无法学习动作片段之间的时序关系, 而且对于不平衡数据集选择的评估指标不够合理, 因此, 本文对文献[3]进行进一步的优化, 结合 LSTM 在处理具有时序关系问题方面的优势, 将 LSTM 与 MoE 模型进行结合, 提出 MoE-LSTM 动作识别方法, 并扩充了数据集, 设置了合理的评估指标。

2 预备知识

2.1 混合专家系统 MoE

MoE 模型通过集成多个基础模型来提高分类准确率, 如图1所示。在实际的场景中, 数据集中数据的来源可能有多个, 如动作识别中采集不同人员的动作数据构建数据集, 不同来源的数据在分布上存在一定的差异, 单个的模型往往善于处理其中一部分数据, 不善于处理另一部分数据。MoE 模型针对该现象, 使用多个基础模型 (Expert) 处理不同来源的数据, 每个 Expert 网络都有一个擅长分类的数据区域, 在该数据区域上的分类效果比其他 Expert 网络好, 并通过门控模块 (Gating) 判断一个输入应该交给哪一个 Expert 网络处理。与其他集成学习方法如 Bagging、Boosting 不同的是, MoE 模型对于集成的基础模型的输出结果使用门控网络进行筛选, 多个基础模型可以并行处理数据, 而且随着数据集的增大, 该模型的性能表现会有明显提高。

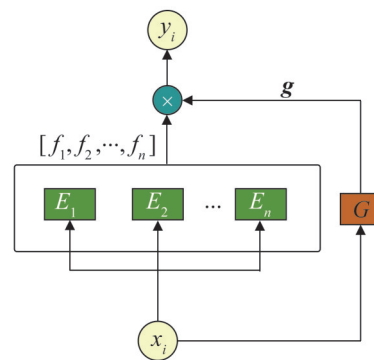


图1 MoE模型结构

Fig. 1 MoE model structure

MoE 模型有2种架构, competitive MoE 和 cooperative MoE。competitive MoE 中数据的局部区域被强制集中在数据的各离散空间, 而 cooperative MoE 没有进行强制限制, 数据区域不受约束, 可能会重叠。由于在数据采集过程中, 不同采集人员执行的动作类型相同且标准, 数据来源没有非常明显的区分边界, 因此本文采用的

是 cooperate 架构。MoE 模型对于数据集中第 i 个输入样本 \mathbf{x}_i 的处理过程为

$$y(\mathbf{x}_i) = \sum_{e=1}^n g(\mathbf{x}_i)_e f_e(\mathbf{x}_i) \quad (1)$$

式中: $f_e(\mathbf{x}_i)$ 为输出结果; $g(\mathbf{x}_i)_e$ 为对应的权重。

2.2 长短期记忆神经网络 LSTM

LSTM 模型通过 3 种“门”结构进行信息的传递, 在 RNN(recurrent neural network) 的基础上通过增加细胞状态实现了长期状态信息的记录, 对于具有长期依赖关系的样本数据具有较好的分类效果。LSTM 的数据处理过程如图 2 所示。细胞状态 C 是实现长期记忆传送的关键, 每次 LSTM 单元会对细胞状态进行更新并产生本阶段的输出结果, 作为下一时刻 LSTM 单元输入的一部分。




图 2 LSTM 模型结构

Fig. 2 LSTM model structure

每个 LSTM 单元包括遗忘门、输入门和输出门 3 种门结构, 计算公式为

$$\mathbf{f}_t = \sigma(\mathbf{W}_f \cdot [\mathbf{h}_{t-1}, \mathbf{X}_t] + \mathbf{b}_f) \quad (2)$$

$$\mathbf{i}_t = \sigma(\mathbf{W}_i \cdot [\mathbf{h}_{t-1}, \mathbf{X}_t] + \mathbf{b}_i) \quad (3)$$

$$\tilde{\mathbf{C}}_t = \tanh(\mathbf{W}_c \cdot [\mathbf{h}_{t-1}, \mathbf{X}_t] + \mathbf{b}_c) \quad (4)$$

$$\mathbf{C}_t = \mathbf{f}_t \cdot \mathbf{C}_{t-1} + \mathbf{i}_t \cdot \tilde{\mathbf{C}}_t \quad (5)$$

$$\mathbf{O}_t = \sigma(\mathbf{W}_o \cdot [\mathbf{h}_{t-1}, \mathbf{X}_t] + \mathbf{b}_o) \quad (6)$$

$$\mathbf{h}_t = \mathbf{O}_t \cdot \tanh(\mathbf{C}_t) \quad (7)$$

式中: \mathbf{W} 和 \mathbf{b} 分别为权重矩阵和偏置向量; \mathbf{h}_{t-1} 为上一单元输出向量; \mathbf{C}_{t-1} 为上一单元细胞状态, \mathbf{X}_t 为本单元输入向量; \mathbf{f}_t 为遗忘门激活向量;

\mathbf{i}_t 为输入门激活向量; \mathbf{o}_t 为输出门激活向量; \mathbf{h}_t 为本单元输出向量; $\tilde{\mathbf{C}}_t$ 为候选细胞状态; \mathbf{C}_t 为细胞状态向量; σ 为 sigmoid 函数。

遗忘门根据上一单元的输出和本单元的输入数据控制对上一单元细胞状态的遗忘程度。输入门根据新输入的信息对细胞状态进行更新, 将更新后的细胞状态传送到下一单元。输出门根据输入数据对细胞状态进行过滤, 产生本阶段的输出结果。

3 MoE-LSTM 动作识别模型

3.1 数据集构建

为了更好地对倒闸操作过程进行识别, 提高模型的泛化能力, 本文在原来数据集的基础上又采集了 3 位操作人员的倒闸操作数据, 包含 11 种动作类型。数据采集过程中要求操作人员动作标准无误, 每种动作采集 2 次。采集方法、动作类型、涉及的传感器与配电柜型号与文献[3]相同。数据集扩充前后各个动作类型的分布情况如表 1 所示, 每个数据样本表示某一时刻动作的三维加速度。

表 1 数据集变化对比

Table 1 Comparison of data set changes

动作类型	原数据集 ^[3]	扩充数据集
合闸接地	1 608	2 243
分闸接地	1 829	2 533
关柜门	13 254	14 258
开柜门	10 732	11 565
合闸	7 404	7 815
分闸	7 164	7 596
远方	6 197	6 552
就地	6 375	6 756
打开五防编码锁	10 670	11 438
关闭五防编码锁	7 933	8 423
摇动断路器	27 333	38 623
合计	100 499	117 802

3.2 预处理

采集的原始操作数据中每个动作由一系列的三维加速度数据构成, 由于不同动作持续时间不

同, 对应的三维加速度数据点的长度也有较大差异, 而且单个三维加速度数据点难以描述整个动作过程, 因此本文通过移动滑动窗口截取动作片段进行动作表示。假设窗口大小为 w , 移动步长为 s , 其包含 n 个三维加速度数据点的动作, 经过滑动窗口截取后得到 $[(n-w)/s]+1$ 个动作样本, 特征维度为 $3w$ 。对于滑动窗口大小和滑动步长的选择, 考虑到动作数据本身的特点本文采用与之前工作相同的策略, 滑动窗口大小为25, 滑动步长为1, 因此加窗后样本维度变为75, 如图3所示。




图3 加窗处理
Fig. 3 Window processing

为了降低数据采集过程中手部轻微晃动带来的干扰噪声以及传感器本身带来的延迟、误差等噪声, 本文将采集的原始数据通过截止频率为5 Hz的低通滤波器, 过滤掉原始数据中的高频噪声, 平滑动作曲线。

为了满足模型计算损失函数的需要, 本文将原始的中文样本标签经过one_hot编码转变为由0、1组成的向量。

为了缓解不同维度数值范围相差较大的情况, 本文使用线性归一化的方法将不同维度特征的数值归一化到0~1之间。

3.3 动作识别模型

为了提高LSTM模型对于不同来源数据的学习能力, 本文使用MoE思想对多个基础LSTM模型进行集成, 构建了MoE-LSTM模型, 如图4所示。将 $t+1$ 时刻的样本数据 \mathbf{x}_{t+1} 输入到 n 个不同的LSTM模型中进行学习, 每个LSTM模型通过将

上一时刻 t 的输出作为当前时刻输入的一部分实现时序信息的传递。Gating网络负责根据输入样本动态地选择LSTM, 将输入映射为权重向量 $\mathbf{g}=[g_1, g_2, \dots, g_n]$, \mathbf{g} 中第 i 个元素 g_i 表示第 i 个LSTM网络的输出结果在最后的输出结果中所占权重, 最终模型的输出结果为所有LSTM模型的输出向量矩阵 $\mathbf{F}=[f_1, f_2, \dots, f_n]$ 和权重向量 \mathbf{g} 的乘积, 每一个LSTM模型的学习结果可表示为一个概率分布 \hat{p}_i , MoE-LSTM模型对于给定的输入 \mathbf{x}_{t+1} 和上一时刻的输出 y_t 预测得到的输出为

$$y_{t+1} = \arg \max_y \sum_{i=1}^n \hat{p}_i(y|\mathbf{x}_{t+1}, y_t) \quad (8)$$

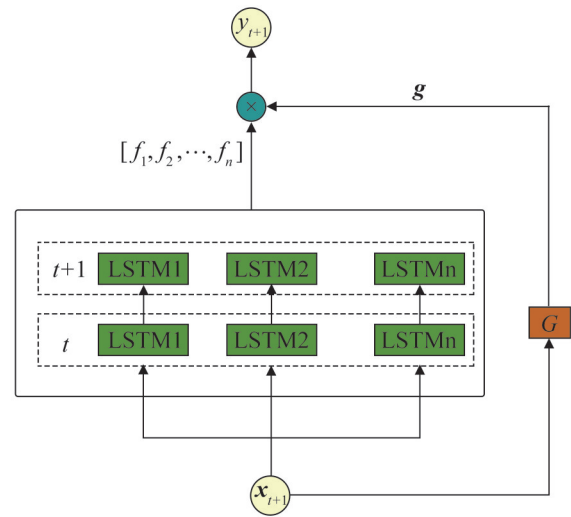


图4 MoE-LSTM模型结构
Fig. 4 MoE-LSTM model structure

模型训练的目标是最小化所有LSTM模型的预测偏差加权和, 目标函数为

$$L = \sum_i g_i (y - f_i)^2 \quad (9)$$

式中: y 为输入样本 \mathbf{x}_i 对应的真实标签; f_i 为第 i 个LSTM模型的输出; g_i 为第 i 个LSTM模型对应的权重。

在反向传播过程中通过式(10)、(11)来指导模型对不同来源数据进行建模与学习:

$$\frac{\partial L}{\partial f_i} = g_i (y - f_i) \quad (10)$$

$$\frac{\partial L}{\partial x_i} = g_i((y - f_i)^2 - L) \quad (11)$$

式(10)得到的梯度表示一个 LSTM 模型应做的修正, 如果该专家的可靠度 g_i 较小, 那么该梯度值也就很小, 也就意味着该 LSTM 模型只需要做一个很小的调整。式(11)得到的梯度用来修正专家的可靠度, 如果一个 LSTM 模型犯的错误比平均错误 L 小, 说明该 LSTM 模型对输入数据的学习比其他 LSTM 模型好, 就要增大其可靠度。

4 实验验证与分析

为了验证 MoE-LSTM 模型的有效性, 本文基于构建的倒闸操作数据集对模型的性能进行评估, 并与 LSTM 模型^[2]、改进的 MoE 模型^[3]、KNN、RF、SVM 进行对比实验, 对实验结果进行分析。

实验用到的深度学习框架为 Tensorflow 2.4.0, 编程语言为 Python3.7.9, 操作系统为 Windows 10, 处理器为 AMD Ryzen 7。

4.1 数据集的使用

本文将整个倒闸操作数据集分为 3 部分: 训练集、验证集和测试集。训练集用于模型训练过程, 模型将基于训练集进行特征学习, 使模型能够拟合原始数据分布; 验证集用于对训练过程中模型的性能进行评估, 根据模型在验证集上的性能表现调整模型的超参数; 测试集用于对训练好的模型进行评估, 可用于评估不同模型的性能优劣。在本文的实验中, 训练集大小为 85 787, 验证集大小为 21 447, 测试集大小为 10 569。其中训练集和验证集的比例为 4:1, 测试集为一名工作人员的采集数据, 训练集和验证集中不包含该名工作人员的动作数据, 以便通过测试集上的识别效果来评估模型的泛化能力。

4.2 识别性能评估指标

为了评估不同模型的识别效果以及模型对于不同动作的识别效果, 本文使用准确率、精确率、召回率以及 F_1 分数作为模型的性能评估指标。以

二分类任务为例, 各个性能指标:

$$Acc = \frac{TP + TN}{TP + FP + FN + TN} \quad (12)$$

$$Pre = \frac{TP}{TP + FP} \quad (13)$$

$$Recall = \frac{TP}{TP + FN} \quad (14)$$

$$F_1_score = \frac{2 \times Pre \times Recall}{Pre + Recall} \quad (15)$$

式中: TP 为将正类预测为正类的样本数; FN 为将正类预测为负类的样本数; FP 为将负类预测为正类的样本数; TN 为将负类预测为负类的样本数。

对于多分类任务, 在计算某一类别的性能指标时, 可将该类别的数据视为正类, 其他类别的数据视为负类。由于不同动作持续时间具有较大差异, 数据集中不同类别数据的比例并不平衡, 而实际的场景中, 不同动作的识别重要性相同, 因此本文用各个类别动作性能指标的均值对比评估不同模型的性能。

4.3 实验细节

本节将基于构建的 MoE-LSTM 模型在倒闸操作数据集上进行实验, 对模型在各个动作类别上的识别效果进行分析, 并与另外 5 种动作识别方法进行对比分析。

4.3.1 实验设置

为了合理对比不同模型的整体性能, 需要统一各个模型的实验环境和数据集。基于训练集对 MoE-LSTM、改进的 MoE^[3]、LSTM 模型^[2], 以及基础分类模型 KNN、RF、SVM 进行训练, 并根据模型在验证集上的准确率来选择各个模型的超参数, 最后基于测试集计算模型的整体性能。

根据 MoE-LSTM 和改进的 MoE 模型^[3]在验证集上表现确定 Expert 网络的数目。实验结果如表 2 所示, 当 Expert 网络数目分别设置为 8 和 5 时, 改进的 MoE 模型和 MoE-LSTM 模型在验证集上的准确率最高。此外, MoE-LSTM 模型和改进的 MoE 模型的结构都是由输入层、MoE 层、dropout 层和输出层构成, 2 个模型每个 Expert 网络分别是一个

LSTM网络和一个卷积网络, LSTM模型结构由输入层、LSTM层、dropout层和输出层组成。根据训练过程损失函数的收敛程度将迭代次数统一设置为150, 神经元数目统一设置为32。

表2 不同Expert网络数目对应的验证集准确率
Table 2 Verification set accuracy corresponding to different number of expert networks

Expert网络数目	验证集准确率/%	
	改进的MoE模型	MoE-LSTM模型
2	89.89	94.62
3	91.36	94.77
4	91.61	95.46
5	90.69	95.75
6	91.04	95.50
7	91.69	95.44
8	92.86	95.68
9	92.06	95.58

4.3.2 模型性能评估

本节将从MoE-LSTM模型对于倒闸操作具体过程的识别效果以及不同模型在测试集上的整体性能指标进行分析。从而验证模型对于倒闸操作过程识别的有效性和与其他模型相比的识别优势。

基于训练好的模型对测试集中各个动作类别的识别效果进行评估, 评估指标有召回率、精确率和 F_1 分数, 如表3所示。从实验结果可以看出MoE-LSTM模型对于“合闸接地”和“就地”2种倒闸操作过程的精确率指标最低, 但是这2种动作的召回率指标却较高, 说明模型对于2种动作本身能够分类正确, 但会把其他动作误分类为“合闸接地”和“就地”。

为了分析误分类的具体动作类型, 本文绘制了模型对于各个动作识别结果的混淆矩阵, 如图5所示。每个单元格的数字表示样本数量, 从混淆矩阵的结果可以看出“分闸接地”和“摇动断路器”容易误分类为“合闸接地”, 其中“分闸接地”最多, “打开五防编码锁”容易误分类为“就地”。此外测试集中“合闸接地”和“就地”2种动作本身数量较少也是导致精确率较低的原因。

表3 MoE-LSTM模型对于具体动作的识别效果

Table 3 Recognition effect of MoE-LSTM model for specific actions %

动作类别	精确率	召回率	F_1 分数
关柜门	95.26	93.50	94.37
关闭五防编码锁	94.58	92.58	93.57
分闸	87.59	99.22	93.04
分闸接地	92.51	88.20	90.30
合闸	100	100	100
合闸接地	78.23	77.60	77.91
就地	74.77	91.95	82.47
远方	99.00	100	99.50
开柜门	91.05	93.90	92.45
打开五防编码锁	98.50	94.13	96.27
摇动断路器	93.89	96.51	95.18




图5 MoE-LSTM模型对于各个动作识别的混淆矩阵
Fig. 5 Confusion matrix of MoE-LSTM model for each action recognition

为了分析MoE-LSTM模型相对其他倒闸操作模型的优势, 本文将MoE-LSTM模型与基础分类方法(KNN、RF、SVM)以及动作识别方法改进的MoE^[3]、LSTM模型^[2]进行对比实验。评估指标包括整体准确率、平均召回率、平均精确率和平均 F_1 分数, 如表4所示。可以看出MoE-LSTM模型和改进的MoE模型的整体准确率差不多, 但都比基础分类模型和LSTM模型高, 说明基于MoE进行集成具有一定的优势。此外MoE-LSTM模型比

改进的MoE模型效果更好,说明在MoE模型中融合LSTM比融合卷积操作更具有优势,能够提取原始数据中隐含的时序特征,该特征对于倒闸操作的识别具有积极的影响。通过与之前的实验结果进行对比,可以看出随着数据集的增大,MoE集成的效果越好。

表4 不同模型在测试集上的性能结果对比
Table 4 Performance comparison of different models

性能指标	on test set			%
	整体 准确率	平均 召回率	平均 精确率	平均 F_1 值
MoE-LSTM	93.49	93.42	91.40	92.28
改进的MoE	93.11	92.09	90.44	91.08
LSTM	91.45	90.88	88.82	89.70
KNN	86.74	86.07	83.06	84.01
RF	91.02	92.24	89.33	90.46
SVM	92.49	91.19	89.69	89.79

为了检测模型的鲁棒性和泛化能力,本文在测试集上添加高斯噪声进行实验,实验结果如图6所示。通过调节方差的大小控制噪声的强度,使用平均召回率作为观测指标,可以看出,随着噪声强度的增大,各个模型的平均召回率都会有所下降,其中RF和SVM下降最快,而MoE-LSTM模型的平均召回率比其他模型都要高,下降速度较为缓慢,鲁棒性更强。




图6 模型平均召回率随高斯噪声强度变化

Fig. 6 Average recall rate of model varies with intensity of Gaussian noise

5 结论

本文构建了更为完备的倒闸操作数据集,包

含7名人员的11种动作数据。为了提高对不同来源数据的学习能力,本文基于MoE对LSTM进行集成,提出了一种有效的倒闸操作识别方法MoE-LSTM,提高了模型对于不同样本子空间的时序学习效果。通过在构建的倒闸操作数据集上与其他倒闸操作识别方法进行对比实验,证明了MoE-LSTM模型对于倒闸操作识别效果更好,抗噪声干扰能力更强。此外,由于个别动作样本数量较少、模型学习不充分导致出现误分类的情况,后续可考虑扩充倒闸操作数据集,使用网格、随机搜索等自动化调参算法优化模型参数,提高模型的泛化能力和识别准确率。

参考文献:

- [1] 杜洋. 2014-2018年电力安全事故总量统计与分析[EB/OL]. [2021-03-14]. <http://news.bjx.com.cn/html/20190611/985454.shtml>.
Du Yang. Statistics and Analysis of the Total Number of Power Safety Accidents from 2014 to 2018[EB/OL]. [2021-03-14]. <http://news.bjx.com.cn/html/20190611/985454.shtml>.
- [2] 刘培贞,贾玉祥,夏时洪. 一种面向电力运维作业的LSTM动作识别方法[J]. 系统仿真学报, 2019, 31(12): 2837-2844.
Liu Peizhen, Jia Yuxiang, Xia Shihong. An LSTM-Based Motion Recognition Method for Power Operation and Maintenance[J]. Journal of System Simulation, 2019, 31(12): 2837-2844.
- [3] 张晓青,贾玉祥,夏时洪. 基于MoE的倒闸操作过程识别研究[C]//2020中国仿真大会. 北京: 中国仿真学会, 2020: 30-38.
Zhang Xiaoqing, Jia Yuxiang, Xia Shihong. Research on Recognition of Switching Operation Based on MoE[C]// 2020 China Simulation Conference. Beijing: China Simulation Federation, 2020: 30-38.
- [4] Dang L M, Min K, Wang H, et al. Sensor-Based and Vision-Based Human Activity Recognition: A Comprehensive Survey[J]. Pattern Recognition(S0031-3203), 2020, 108: 107561.
- [5] Gong J, Cui L, Xiao K, et al. MPD-Model: A Distributed Multipreference-Driven Data Fusion Model and its Application in a WSNs-Based Healthcare Monitoring System[J]. International Journal of Distributed Sensor Networks(S1550-1477), 2012, 8(12): 602358.
- [6] Incel O D. Analysis of Movement, Orientation and

- Rotation-Based Sensing for Phone Placement Recognition [J]. *Sensors*(S1424-8220), 2015, 15(10): 25474-25506.
- [7] 徐川龙, 顾勤龙, 姚明海. 一种基于三维加速度传感器的人体行为识别方法[J]. *计算机系统应用*, 2013, 22(6): 132-135.
Xu Chuanlong, Gu Qinlong, Yao Minghai. Activity Recognition Method Based on Three-Dimensional Accelerometer[J]. *Computer System Application*, 2013, 22(6): 132-135.
- [8] Xiao Q, Song R. Action Recognition Based on Hierarchical Dynamic Bayesian Network[J]. *Multimedia Tools and Applications*(S1380-7501), 2018, 77(6): 6955-6968.
- [9] Sok P, Xiao T, Azeze Y, et al. Activity Recognition for Incomplete Spinal Cord Injury Subjects Using Hidden Markov Models[J]. *IEEE Sensors Journal*(S1530-437X), 2018, 18(15): 6369-6374.
- [10] Abidine B M, Fergani L, Fergani B, et al. The Joint Use of Sequence Features Combination and Modified Weighted SVM for Improving Daily Activity Recognition[J]. *Pattern Analysis and Applications*(S1433-7541), 2018, 21(1): 119-138.
- [11] Chen Z, Wang Y. Infrared-Ultrasonic Sensor Fusion for Support Vector Machine-Based Fall Detection[J]. *Journal of Intelligent Material Systems and Structures* (S1045-389X), 2018, 29(9): 2027-2039.
- [12] Murad A, Pyun J Y. Deep Recurrent Neural Networks for Human Activity Recognition[J]. *Sensors*(S1424-8220), 2017, 17(11): 2556.
- [13] Xia K, Huang J, Wang H. LSTM-CNN Architecture for Human Activity Recognition[J]. *IEEE Access*(S2169-3536), 2020, 8: 56855-56866.
- [14] Moya Rueda F, Grzeszick R, Fink G A, et al. Convolutional Neural Networks for Human Activity Recognition Using Body-Worn Sensors[J]. *Informatics* (S2227-9709), 2018, 5(2): 26.
- [15] Dong X, Yu Z, Cao W, et al. A Survey on Ensemble Learning[J]. *Frontiers of Computer Science*(S2095-2228), 2020, 14(2): 241-258.
- [16] Jacobs R A, Jordan M I, Nowlan S J, et al. Adaptive Mixtures of Local Experts[J]. *Neural Computation* (S0899-7667), 1991, 3(1): 79-87.
- [17] 俞斌峰, 季海波. 稀疏贝叶斯混合专家模型及其在光谱数据标定中的应用[J]. *自动化学报*, 2016, 42(4): 566-579.
Yu Binfeng, Ji Haibo. Sparse Bayesian Mixture of Experts and Its Application to Spectral Multivariate Calibration[J]. *Acta Automatica Sinica*, 2016, 42(4): 566-579.