光电技术及应用

DOI: 10.16818/j.issn1001－5868.20241108001

# 电网调度防误人工智能模型的构建与操作分类方法

杜 江[1*]，吴 杨[1]，陈章国[2]，袁 涔[1]，白宏宇[1]，陈 龙[1]

（1. 贵州电网有限责任公司电力调度控制中心，贵阳 550002；2. 南京南瑞信息通信科技有限公司，南京 210000）

**摘 要：** 随着电网规模的逐年扩大与复杂程度的不断提高，电网调度操作日益频繁，任何操作失误都可能导致严重后果。基于此，文章提出一种电网调度防误人工智能模型的构建与操作分类方法。首先，结合卷积神经网络（Convolutional Neural Network，CNN）和长短期记忆网络（Long Short-Term Memory，LSTM）的优点，构建基于CNN-LSTM的电网调度防误模型，以深入挖掘电网调度操作的深层特征和时间序列特性，从而提升误操作识别的准确性，增强电网调度的防误效率。其次，将C4.5决策树算法与布尔公式、贝叶斯公式结合，提出基于C4.5决策树的误操作分类方法，实现误操作的精细化分类。仿真结果表明，相较于对比算法，所提算法将防误成功率分别提高了2.50%和3.29%。

**关键词：** 电网调度；防误操作；卷积神经网络；长短期记忆网络；决策树

**中图分类号：** TP18；TM711 **文章编号：** 1001－5868(2025)03－0550－07

## Construction of an Artificial Intelligence Model for Preventing Misoperations in Power Grid Dispatching and Operation Classification

DU Jiang[1], WU Yang[1], CHEN Zhangguo[2], YUAN Cen[1], BAI Hongyu[1], CHEN Long[1]

(1. Power Dispatching and Control Center of Guizhou Power Grid Co., Ltd., Guiyang 550002, CHN; 2. Nanjing Nanrui Information and Communication Technology Co., Ltd., Nanjing 210000, CHN)

**Abstract:** As the power grid continues to expand and grow more complex each year, the frequency of power grid dispatching operations is increasing. Any misoperation within this process can have serious repercussions. To address these challenges, this study proposes the development of an artificial intelligence model designed to prevent misoperations in power grid dispatching and operation classification. First, we develop a misoperation prevention model based on the combination of convolutional neural networks (CNN) and long short-term memory (LSTM) networks. This CNN-LSTM-based misoperation prevention model for power grid dispatching is designed to explore the deep and temporal characteristics of power grid dispatching operations, achieve more accurate identification of misoperations, and improve the efficiency of power grid dispatching misoperation prevention. Additionally, we propose a refined misoperation classification method that combines the C4.5 decision tree algorithm with Boolean and Bayesian formulas. This approach aims to achieve a more precise classification of misoperations. The simulation results reveal that the proposed algorithm improves the success rate of misoperation prevention by 2.50% to 3.29%, respectively, compared with existing algorithms.

**Key words:** power grid dispatching; misoperation prevention; convolutional neural network; long short-term memory; decision tree

**收稿日期：**2024－11－08.

**基金项目：**中国南方电网有限责任公司科技项目（GZKJXM20220105）.

*通信作者：杜 江

## 0　引言

电网调度是电力系统运行的关键环节，主要负责电力供给和需求的实时平衡，确保电网安全稳定运行。随着电网规模的逐年扩大与复杂程度的逐渐提高，电网调度操作越来越频繁，电网调度涉及发电调度、输电调度、配电调度等多个环节，需要实时监测和控制电网各关键参数，如电压、频率、功率等，电网调度的目标是在满足用户用电需求的前提下，最大限度地提高电力系统的经济性和可靠性[1-3]。电网调度涉及众多关键设备和参数，任何操作失误都可能导致严重后果，如引发设备故障或损坏、造成电力供给中断、影响用户用电等[4]。为降低误操作风险，建立完善的防误操作机制，对误操作进行精细化分类具有重要意义。传统电网调度防误与误操作分类主要依靠人工，然而人工监控效率低下，难以实时发现并纠正操作失误，同时操作分类依赖经验，难以全面覆盖各类操作场景[5-6]。因此，迫切需要开发自动化的电网调度防误操作技术和操作分类方法，以提高电网调度防误操作和操作分类效率，确保电网安全稳定运行。

在电网防误操作方面，文献[7]提出基于分层有限状态机（Finite State Machine，FSM）的操作防误方法，避免因误操作导致的电网隐患，保障电网运行的可靠性和安全性。文献[8]提出一种误操作感知和自适应纠正方法，实现开关异动误操作感知，避免线路长时间合环造成的电网运行隐患，提升电网安全管控水平。文献[9]提出一种基于FSM的电网实时调度防误控制技术，在不同的调度操作信息中能够准确找到错误信息，使防误性能大大提高。然而，上述方法均难以挖掘电网调度操作的深度特征，同时忽略了电网调度操作的时序性。

长短期记忆网络（Long Short-Term Memory，LSTM）可以挖掘时序特性，卷积神经网络（Convolutional Neural Network，CNN）具有提取深层特征的能力，是构建电网防误人工智能模型的关键技术。文献[10]提出基于深度迁移学习和LSTM的电网故障检测方法，能高效检测不同结构电网中各种类型的故障，检测精度高。文献[11]针对直流电网故障检测正确率低，提出一种基于CNN与深度卷积对抗生成网络（Deep Convolutional Generative Adversarial Networks，DCGAN）的电网故障检测方法，检测精度较高。然而，上述研究没有有效结合CNN和LSTM各自的优势。

在操作分类方面，文献[12]通过门控循环单元根据各种操作对电网的影响作用情况开展分类，建立了电网操作分类模型。文献[13]针对当前数字电网误操作智能检测数据稀少、准确率低的问题，提出一种基于注意力-双向长短期记忆网络的数字电网误操作分类方法，将可能的误操作当成分类任务来处理，实现电网设备误操作的分类。然而，上述分类方法分类效率较低，且难以计算逻辑防误分类概率。

决策树算法通过树形结构进行分类，适用于开展电网调度操作分类。文献[14]提出一种基于决策树-关联规则的停复电故障溯源方法，采用决策树算法将不同类型的数据进行分类，依此建立属性特征表，计算故障特征的信息增益率，进行决策划分，得到故障原因数据集。文献[15]使用主元分析法设定电力用户行为数据观测变量，结合决策树技术构建电力用户特征分类模型，完成行为特征分类。

针对上述问题，本文提出一种电网调度防误人工智能模型的构建与操作分类方法。首先，结合CNN和LSTM的优点，构建基于CNN-LSTM的电网调度防误模型，以深入挖掘电网调度操作的深层特征和时间序列特性，提升误操作识别的精准度，增强电网调度的防误效率。其次，将决策树算法与布尔公式、贝叶斯公式结合，提出基于C4.5决策树的误操作分类方法，实现精细化的误操作分类。最后，通过仿真实验验证所提方法的有效性。

## 1　基于CNN-LSTM的电网调度防误模型

由于LSTM的分类效果依赖输入特征的明显程度，而CNN能够对输入的特征向量进行精准的特征提取，充分挖掘数据深层特征。因此，结合CNN和LSTM的优势，构建基于CNN-LSTM的电网调度防误模型，如图1所示。CNN由输入层、输出层和多个隐藏层构成，其中，隐藏层包括卷积层、池化层和激活函数。卷积层的作用是降低参数数量，提高模型提取操作特征的能力。CNN可以自动提取误操作信号中的局部特征，无需人工干预。卷积层利用多个具有共享权重的滤波器对输入数据进行滑动提取，在固定窗口作用下完成局部特征捕捉，并通过激活函数生成对应输出。该过程不仅有

效降低了参数维度，还提升了模型对关键特征的表达能力，同时支持在随机梯度优化下实现快速收敛。常用的激活函数为ReLU，用于增强网络的非线性建模能力，卷积计算公式表示为：

$$x_i^k=f(\omega_i^k * X^{k-1}+b_i^k) \tag{1}$$

式中，$x_i^k$表示第$k$层输出的第$i$个特征；$f(\cdot)$表示激活函数，$\omega_i^k$表示第$k$层的第$i$个卷积核的权重系数；$*$表示卷积运算；$X^{k-1}$为第$k-1$层的输出；$b_i^k$为偏置。

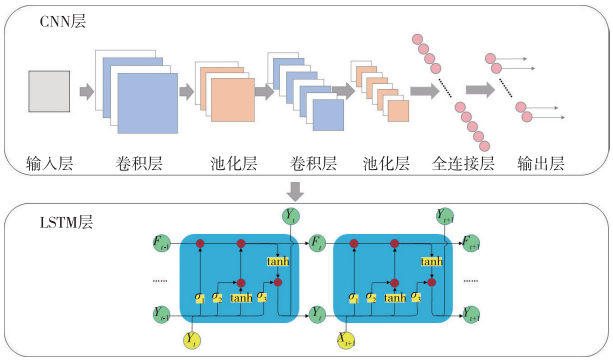



图1 基于CNN-LSTM的电网调度防误模型

为了在准确提取误操作特征的同时减少数据维度和模型参数，卷积层之后引入了池化操作。为增强异常特征的表达，避免平均池化带来的特征弱化问题，本文选用最大池化，对卷积结果进行处理，通过固定大小的滑动窗口提取每个区域的最大值，其计算方式为：

$$\xi_i^{m+1}(j)=\max x_i^j(k), k\in Q_j \tag{2}$$

式中，$\xi_i^{m+1}(j)$表示在第$j$个池化范围内第$m+1$层对第$i$个特征的最大池化结果；$x_i^j(k)$表示卷积层第$k$层输出的第$i$个特征在第$j$个池化范围内的数据；$Q_j$表示第$j$个池化范围。

多次卷积、池化与激活函数处理后，逐步提取出误操作的深层特征。为了实现从输入到输出的端到端映射，需要将这些特征映射到具体的标签空间。全连接层通过激活函数整合上一层所有节点信息，其具体计算表达如下：

$$S_i=\frac{\exp(a_i)}{\sum_{j=1}^{k}\exp(a_j)} \tag{3}$$

式中，$S_i$为第$i$类的概率；$a_i$为全连接层输出的第$i$个结果。

为挖掘电网调度操作的时序特性，将CNN提取到的电网调度操作的深层特征传输给LSTM网络，LSTM是对循环神经网络的改进，旨在解决循环神经网络在序列处理中的梯度消失和记忆限制问题。与只使用一个Tanh激活函数的循环神经网络不同，LSTM拥有四层网络结构。LSTM网络在记忆细胞单元作用下，能够较好地提取时间序列信息。在时间步$t$，单个神经元内部主要包含以下组成部分：输入门$I_t$、输出门$F_t$和遗忘门$S_t$这三个控制门，一个输入调制门$M_t$，一个记忆细胞单元$O_t$，一个隐藏层单元$Y_t$。

LSTM通过遗忘门、输入门和输出门来调节单元状态，从而实现对序列特征的自适应学习，保留重要信息并去除无关内容。CNN提取特征后传入LSTM，遗忘门利用Sigmoid函数控制单元状态的更新；输入门决定哪些信息被存储或更新，通过激活值$S_t$和候选状态$M_t$来判断；输出门则决定哪些信息能被输出，依据激活值$F_t$和记忆单元的输出值$Y_t$来执行。

LSTM计算原理可表示为：

$$I_t=\sigma(\omega_{IY}Y_{t-1}+\omega_{IX}X_t+B_I) \tag{4}$$

$$S_t=\sigma(\omega_{FY}Y_{t-1}+\omega_{FX}X_t+B_S) \tag{5}$$

$$M_t=\tanh(\omega_{MY}Y_{t-1}+\omega_{MX}X_t+B_M) \tag{6}$$

$$O_t=F_t\otimes O_{t-1}+I_t\otimes M_t \tag{7}$$

$$F_t=\sigma(\omega_{FY}Y_{t-1}+\omega_{FX}X_t+B_F) \tag{8}$$

$$Y_t=\tanh(F_t)\otimes O_t \tag{9}$$

式中，$X_t$表示$t$时间步该神经元的输入，$Y_{t-1}$表示$t$-1时间步上一神经元的输出；$\omega_{IY}$，$\omega_{FY}$，$\omega_{MY}$和$\omega_{FY}$分别表示输入门$I_t$、遗忘门$S_t$、输入调制门$M_t$和输出门$F_t$关于上一神经元输出$Y_{t-1}$的权重；$\omega_{IX}$，$\omega_{FX}$，$\omega_{MX}$和$\omega_{FX}$分别表示输入门$I_t$、遗忘门$S_t$、输入调制门$M_t$和输出门$F_t$关于神经元输入$X_t$的权重；$B_I$，$B_S$，$B_M$和$B_F$表示上述各门的各项偏差；tanh(·)为双曲正切激活函数；$\sigma(\cdot)$为Sigmoid激活函数，其输出值为0或1。

## 2 基于C4.5决策树的误操作分类方法

为实现对电网调度误操作的精细化分类，提出基于C4.5决策树的误操作分类方法，如图2所示。

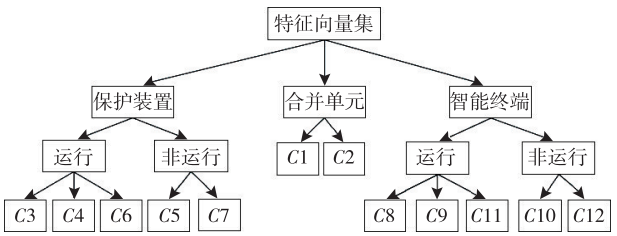



图2 基于C4.5决策树的误操作分类方法

本文采用C4.5决策树模型，其特征在于构建决策树时分类节点选择具有最大信息增益率的属性。C4.5决策树经由对训练样本的训练，构建决策树或规则，实现数据的精准分类。其结构包含一个根节点、多个内部节点和叶子节点，内部节点映射测试属性，分支对应属性值，叶子节点表示类别标签。在学习阶段，通过使用训练数据的属性作为输入，采用自顶向下的递归方法，依据信息增益率选择最佳属性作为节点并进行分支划分，直至满足终止条件形成完整决策树。分类阶段则以测试集为输入，以根节点为起点逐层验证属性值，直至到达叶子节点，获取唯一类标。其优势在于：无需假设数据分布，能处理电网调度数据中的畸变和复杂性；通过逐层属性测试快速定位叶子节点，实现高效分类；结合布尔公式和贝叶斯公式，决策树不仅提供分类结果，还能估算误操作概率，为电网调度提供决策支持。具体原理如下：

设电网调度操作时产生的数据集为$G$，设数据集$G$的目标属性有$L$个类别，可用$C=\{C_1,\cdots,C_l,\cdots,C_L\}$进行表示，$G$中$C_l$出现的概率为$p_l$，则数据集$G$的信息熵为：

$$H(G)=H(p_1,\cdots,p_l,\cdots,p_L)=-\sum_{l=1}^{L}p_l\log_2 p_l \quad (10)$$

信息熵$H(G)$度量电网调度操作数据集$G$的不确定性。在电网调度误操作分类场景中，数据集$G$包含多种调度操作记录，目标属性（如误操作类型）有$L$个类别（如开关误动、参数设置错误等），每个类别$C_l$的出现概率为$p_l$。信息熵表示数据集的混乱程度，熵越大，数据分类的不确定性越高。C4.5决策树通过最小化熵来选择最优属性，减少分类的不确定性。

设属性$C_l$有$N$个不同取值。由此，可将数据集$G$分割为$N$个子集$\{G_1,\cdots,G_n,\cdots,G_N\}$，则属性$C_l$对数据集$G$的信息熵为：

$$H_{C_l}(G)=\sum_{n=1}^{N}\frac{|G_n|}{|G|}H(G_n) \quad (11)$$

式中，$|G_n|$表示第$n$个子集的个数，$|G|$表示数据集总个数。此公式计算属性$C_l$对数据集$G$进行划分后的加权平均熵。在电网调度场景中，属性$C_l$可能代表调度操作的某个特征（如操作时间、设备类型），其有$N$个不同取值（如上午/下午、变压器/断路器）。划分后，数据集$G$被分割为$N$个子集$G_n$，每个子集的熵$H(G_n)$根据其类别分布计算，加权因子$\frac{|G_n|}{|G|}$反映子集样本数占总样本数的比例。加权熵表示划分后子集的总体不确定性。C4.5决策树通过比较不同属性的加权熵，选择能够最大程度降低整体不确定性的属性作为分裂节点。这种选择确保决策树在电网调度数据中优先处理对误操作分类贡献最大的特征。

按属性$C_l$划分$G$的信息增益$I_{\text{gain}}(G,C_l)$可表示为：

$$I_{\text{gain}}(G,C_l)=H(G)-H_{C_L}(G) \quad (12)$$

信息增益$I_{\text{gain}}(G,C_l)$表示通过属性$C_l$划分数据集$G$后信息熵的减少量，即分类不确定性的降低程度。在电网调度误操作分类中，信息增益衡量某个属性（如操作人员经验水平）对区分误操作类型的贡献，增益越大则说明该属性对分类的帮助越大。信息增益是决策树选择分裂属性的初步指标，但由于其倾向取值较多的属性，C4.5引入信息增益率进行改进，以确保更公平的属性选择。

属性$C_l$的分裂信息$E(C_l)$可表示为：

$$E(C_l)=-\sum_{n=1}^{N}\frac{|G_n|}{|G|}\log_2\frac{|G_n|}{|G|} \quad (13)$$

分裂信息$E(C_l)$度量属性$C_l$划分数据集$G$后子集分布的均匀性，反映属性的取值分布特性。在电网调度场景中，若某属性（如设备状态）取值分布不均（如大部分样本集中在“正常”状态），分裂信息值较高，可能导致信息增益被高估。分裂信息用于归一化信息增益，消除属性取值数量的影响。通过分裂信息调整信息增益，计算信息增益率，避免偏向取值较多的属性，从而在电网调度数据中选择更具代表性的分裂属性。

则信息增益率$Z(C_l)$可表示为：

$$Z(C_l)=I_{\text{gain}}(G,C_l)/E(C_l) \quad (14)$$

信息增益率$Z(C_l)$是C4.5决策树的核心指标，通过将信息增益除以分裂信息，平衡属性的分类能力和取值分布的影响。信息增益率取得最大值的属性即为分类属性，确保决策树优先利用对误操作分类最有效的特征（如操作时间、设备类型），从而构建高效的分类模型。决策树建立完成后，即可分析出可能发生事件的概率。

利用布尔公式和贝叶斯公式计算各个误操作的发生概率，分别如公式（15）和（16）所示：

$$\begin{cases} A+\dot{A}=1 \\ A\cdot\dot{A}=0 \\ A+A=A \\ A\cdot A=A \\ (\dot{A})'=A \\ A(A+A)=A \\ A+A\cdot B=A \end{cases} \tag{15}$$

$$P(B/A)=P(A/B)\cdot P(B)/P(A) \tag{16}$$

式中，$A$ 和 $B$ 表示不同的误操作。布尔公式用于描述电网调度误操作的逻辑关系。变量 $A$ 和 $\dot{A}$ 表示某类误操作（如开关误动）及其补集（如非开关误动）。此公式定义了误操作类别的逻辑运算规则，如互斥 $A\cdot\dot{A}=0$、完备性 $A+\dot{A}=1$ 等。在决策树分类中，布尔公式帮助明确类别之间的逻辑约束，确保分类结果的唯一性和准确性。贝叶斯公式用于计算电网调度中不同误操作的条件概率。例如，$A$ 和 $B$ 表示两类误操作（如开关误动和参数错误），公式（16）计算在已知 $A$ 发生的情况下 $B$ 发生的概率。结合决策树，分类结果可进一步通过贝叶斯公式估算误操作的概率分布，为电网调度提供风险评估依据。

C4.5决策树通过信息熵、信息增益和信息增益率等公式，系统性地选择最优属性构建分类模型，适用于电网调度误操作的精细化分类。在构建过程中，C4.5算法从根节点开始，递归选择信息增益率最高的属性（如操作时间、设备状态），生成分支，直至形成叶子节点表示的误操作类别。在分类阶段，测试数据从根节点逐层匹配属性值，最终到达叶子节点获得分类结果。布尔公式确保分类的逻辑一致性，贝叶斯公式进一步支持概率分析，使C4.5决策树在电网调度误操作分类中兼具准确性和实用性。

## 3 实验仿真

基于人工智能算法分类效果依赖于数据集的质量，本文采用真实操作数据集进行仿真，数据集包含50组样本，所提算法的参数设置如表1所示。此外，为验证所提算法的仿真性能，引入两种对比算法进行比较，对比算法1采用支持向量机（Support Vector Machines，SVM）算法[16]，对比算法2采用传统LSTM算法[17]。图3展示了不同算法防误成功率随操作分类数量的变化。

**表1 仿真参数**

| 网络层 | 输出尺寸 | 通道数 | 卷积核大小 |
|---|---|---|---|
| 输入层－1D | 1×1 024 | 3 | |
| LSTM1 | 1×1 024 | 3 | |
| LSTM2 | 1×1 024 | 3 | |
| 拼接 | 1×1 024 | 3 | |
| 输入层－2D | 32×32 | 3 | |
| 卷积1 | 32×32 | 24 | 3×3 |
| 池化1 | 16×16 | 48 | |
| 卷积2 | 8×8 | 96 | 3×3 |
| 池化2 | 4×4 | 192 | |
| 展平 | 1×128 | 3 | |
| 全连接1 | 1×4 | 3 | |

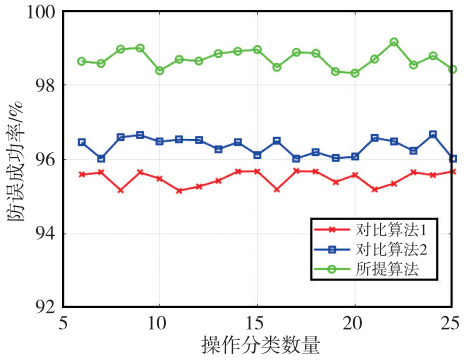



图3 不同算法防误成功率随操作分类数量的变化

可以看出，在不同的操作分类数下，所提算法都有高于98%的防误成功率，而对比算法的防误成功率都低于97%。当操作分类数量为25时，所提算法的防误成功率相比两种对比算法分别提高了2.50%和3.29%。这是因为所提算法利用CNN提取了数据的空间特征，并利用卷积层和池化层减少了参数数量，降低了模型复杂度，从而向LSTM层输入更简单有效的特征信息，LSTM层进而提取这些特征信息的时序信息，提升了电网调度防误成功率。

图4展示了不同算法误操作率随迭代次数的变化曲线。

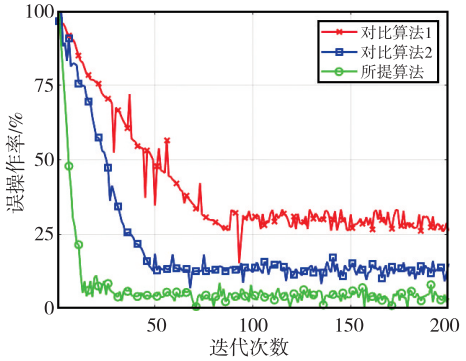
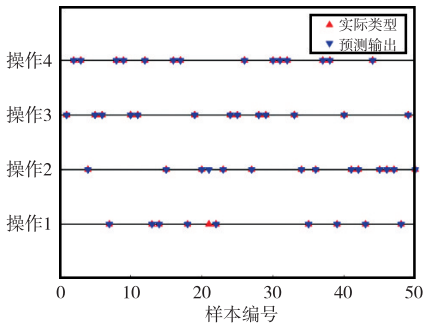


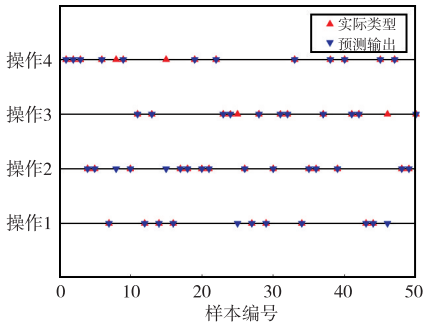

图4 不同算法误操作率随迭代次数的变化

可以看出，三种算法下的电网调度误操作率在最初都很高，随着迭代的进行迅速下降，而后趋于稳定。这是因为在最初这三种算法都在通过数据学习特征并对学习到的结果进行微调，直到趋于稳定后，从而较为准确高效地实现电网调度防误。所提算法仅迭代26次就获得了较为平稳的误操作率，这是因为其利用CNN高效地提取出输入数据的深层特征，并传给LSTM层，使算法可以通过关键特征快速地学习到重要信息，从而加速收敛过程。此外，相较于对比算法，所提算法可以同时捕捉数据中的时间特征和空间特征，从而形成更准确的误操作识别结果，稳定后的误操作率更低。

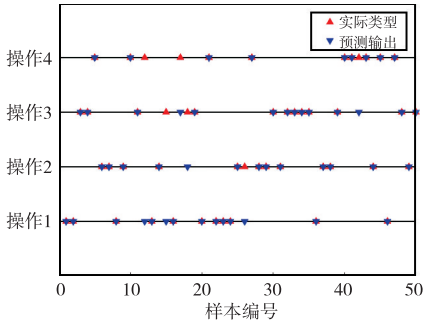
图5展示了不同算法的操作分类结果。




（a）所提算法




（b）对比算法1




（c）对比算法2

图5　不同算法的操作分类结果

由图可知所提算法的预测输出与实际操作类型基本重合，而对比算法有较多样本未正确对操作进行分类，所提算法的分类准确率相较于两种算法分别提高了1%和1.2%。这是由于所提算法采用C4.5决策树分类，选取了具有最大信息增益率的属性，能够有效识别出对分类最具区分力的属性，保证决策树每一层都尽可能减少数据的不确定性，从而提高分类的准确性。

## 4　结束语

为解决现有的电网调度操作防误方法存在的忽略电网调度操作的深度特征和时序特性，导致电网调度操作防误和误操作分类精准性较差与效率较低的问题，本文提出一种电网调度防误人工智能模型的构建与操作分类方法。首先，结合CNN和LSTM的优点，构建基于CNN-LSTM的电网调度防误模型，以深入挖掘电网调度操作的深层特征和时间序列特性，提升误操作识别的精准度，增强电网调度的防误效率。其次，将决策树算法与布尔公式、贝叶斯公式结合，提出基于C4.5决策树的误操作分类方法，实现精细化的误操作分类。仿真结果表明，相比于对比算法，所提算法将防误成功率分别提高了2.50%和3.29%。未来，将进一步探索如何通过用户行为画像提高电网调度操作防误的效率。

**参考文献：**

[1] 齐冬莲，闫玮丹，闫云凤，等. 面向电力调度的事件知识图谱研究现状及发展[J]. 电子与信息学报，2024，46(9)：3456-3466.
Qi Donglian，Yan Weidan，Yan Yunfeng，et al. A review of research methods on event knowledge graph for power dispatching [J]. Journal of Electronics & Information Technology，2024，46(9)：3456-3466.

[2] 徐家慧，张　明，白静洁，等. 基于双向LSTM的电网调度日志分类[J]. 计算机应用与软件，2019，36(1)：142-146.
Xu Jiahui，Zhang Ming，Bai Jingjie，et al. Classification of dispatching log of power grid based on bidirectional LSTM[J]. Computer Applications and Software，2019，36(1)：142-146.

[3] 张　炜，贾　伟，刘路登，等. 基于决策树算法的电网调度频繁数据挖掘系统设计[J]. 电子设计工程，2020，28(19)：189-193.
Zhang Wei，Jia Wei，Liu Ludeng，et al. Design of frequent data mining system for power grid dispatching based on decision tree algorithm [J]. Electronic Design Engineering，2020，28(19)：189-193.

[4] 刘路登，贾　伟，陈天宇，等. 智能化电力调度指令操作系统研究与应用[J]. 电子器件，2021，44(5)：1204-1209.

Liu Ludeng, Jia Wei, Chen Tianyu, et al. Research and application of intelligent power dispatching order operating system[J]. Chinese Journal of Electron Devices, 2021, 44(5): 1204-1209.

[5] 吕 顺, 陶永峰. 智能变电站中的继电保护防误技术分析[J]. 集成电路应用, 2024, 41(8): 330-331.
Lyu Shun, Tao Yongfeng. Analysis of relay protection error prevention technology in intelligent substations[J]. Application of IC, 2024, 41(8): 330-331.

[6] 李 晋, 高宜凡, 张杰明, 等. 基于电网调度运行的智能防误方法研究[J]. 微型电脑应用, 2024, 40(5): 112-115.
Li Jin, Gao Yifan, Zhang Jieming, et al. Research on intelligent error prevention method based on power grid dispatching operation[J]. Microcomputer Applications, 2024, 40(5): 112-115.

[7] 桂前进, 姚 昕, 汪李来, 等. 基于分层有限状态机的检修工作票智能防误技术[J]. 合肥工业大学学报(自然科学版), 2021, 44(4): 458-463.
Gui Qianjin, Yao Xin, Wang Lilai, et al. An intelligent anti-misoperation technique for maintenance work orders based on hierarchical finite state machine[J]. Journal of Hefei University of Technology (Natural Science), 2021, 44(4): 458-463.

[8] 蔡建逸, 林裕新, 吴泽鑫, 等. 配电网联络开关异动感知及自适应纠正的防误方法[J]. 电气技术, 2022, 23(3): 92-97.
Cai Jianyi, Lin Yuxin, Wu Zexin, et al. Anti-misoperation method of misoperation sensing and adaptive correction for loop switch in distribution network [J]. Electrical Engineering, 2022, 23(3): 92-97.

[9] 杨 子, 贾 伟, 徐博文, 等. 基于有限状态机的电力实时调度防误控制方法[J]. 电工技术, 2023(12): 176-178, 182.
Yang Zi, Jia Wei, Xu Bowen, et al. Error proof control method for real-time power dispatching based on finite state machine[J]. Electric Engineering, 2023(12): 176-178, 182.

[10] 吴忠强, 卢雪琴. 基于深度迁移学习和LSTM网络的微电网故障诊断[J]. 计量学报, 2023, 44(4): 582-590.
Wu Zhongqiang, Lu Xueqin. Microgrid fault diagnosis based on deep transfer learning and LSTM network [J]. Acta Metrologica Sinica, 2023, 44(4): 582-590.

[11] 韦延方, 吴郑磊, 王 鹏, 等. 基于CNN与DCGAN的柔性直流配电网故障检测[J]. 煤炭学报, 2021, 46(S2): 1201-1208.
Wei Yanfang, Wu Zhenglei, Wang Peng, et al. Fault detection of VSC based DC distribution network based on CNN and DCGAN[J]. Journal of China Coal Society, 2021, 46(S2): 1201-1208.

[12] 徐家慧, 张 昊, 肖林朋, 等. 基于GRU神经网络的电网告警信息分类研究[J]. 计算机与数字工程, 2019, 47(6): 1405-1408, 1538.
Xu Jiahui, Zhang Hao, Xiao Linpeng, et al. Model of power grid alarm information classification based on the GRU neural network[J]. Computer & Digital Engineering, 2019, 47(6): 1405-1408, 1538.

[13] 田 园, 马 文. 基于Attention-BiLSTM的电网设备故障文本分类[J]. 计算机应用, 2020, 40(S2): 24-29.
Tian Yuan, Ma Wen. Attention-BiLSTM-based fault text classification for power grid equipment [J]. Journal of Computer Applications, 2020, 40(S2): 24-29.

[14] 崔超奕, 任 伟, 王博欣, 等. 基于分类决策树——关联规则的远程停复电故障溯源[J]. 电网与清洁能源, 2024, 40(5): 19-25.
Cui Chaoyi, Ren Wei, Wang Boxin, et al. Remote power outage and restoration fault tracing based on classification decision tree-association rules[J]. Power System and Clean Energy, 2024, 40(5): 19-25.

[15] 费 飞, 翁利国, 寿 挺, 等. 基于数据挖掘的电力用户行为特征分类研究[J]. 自动化技术与应用, 2023, 42(11): 101-104, 117.
Fei Fei, Weng Liguo, Shou Ting, et al. Research on classification of power user behavior characteristics based on data mining[J]. Techniques of Automation and Applications, 2023, 42(11): 101-104, 117.

[16] 白晋川, 李肖博, 姚 浩, 等. 基于FIMD和SVM的高压输电线路保护方案[J]. 电测与仪表, 2024, 61(9): 107-112.
Bai Jinchuan, Li Xiaobo, Yao Hao, et al. Protection scheme of high voltage transmission line based on FIMD and SVM [J]. Electrical Measurement & Instrumentation, 2024, 61(9): 107-112.

[17] 张 帆, 杨晓忠, 王树波. 基于LSTM神经网络的地震事件分类[J]. 计算机应用与软件, 2023, 40(4): 75-79.
Zhang Fan, Yang Xiaozhong, Wang Shubo. Seismic event classification based on LSTM neural network[J]. Computer Applications and Software, 2023, 40(4): 75-79.

## 作者简介:

**杜 江**(1991—),男,贵州省遵义市人,高级工程师,主要研究方向为电网调度运行与管理、新型电力系统与智能电网。