

# 融合知识库和深度学习的电网监报告警事件智能识别

孙国强<sup>1</sup>, 沈培锋<sup>2</sup>, 赵扬<sup>2</sup>, 朱红勤<sup>2</sup>, 丁小柳<sup>1</sup>, 卫志农<sup>1</sup>, 臧海祥<sup>1</sup>

(1. 河海大学 能源与电气学院, 江苏 南京 210098; 2. 国网江苏省电力有限公司南京供电分公司, 江苏 南京 210019)

**摘要:** 电网监报告警信息是监控人员进行监控事件识别的重要数据基础。针对当前人为处理海量监报告警信息效率低的现状和电网智能技术深化应用的需求, 提出一种融合知识库和深度学习的电网监报告警事件自主识别方法。基于自然语言处理技术中的Word2vec模型对监报告警信息进行向量化建模, 基于卷积神经网络建立监报告警事件识别模型, 通过算例对比验证所建模型的有效性和实用性。提出融合知识库与所建模型的应用方法, 实现电网监报告警事件的智能感知和可靠识别。

**关键词:** 电网监控; 告警信息; Word2vec; 卷积神经网络; 事件识别; 知识库; 深度学习

**中图分类号:** TM 73; TP 3

**文献标志码:** A

**DOI:** 10.16081/j.epae.202002023

## 0 引言

随着电力信息化的快速建设以及电网智能化的全面推进, 电力数据呈现体量大、类型多、速度快等发展特点<sup>[1]</sup>。海量文本、音频和图像等数据分布于基建、运行、调控、检修等多个电网资产管理环节, 这些数据中蕴藏着巨大的利用价值<sup>[2-3]</sup>。如电网调控环节中包含了大量的故障信息、调度日志、操作规程等文本化信息, 这些文本信息是电网设备的状态反应和规则经验的归纳总结, 如果能够深度挖掘其中的信息价值, 不仅可以提升电网的运行管理水平, 也能够为社会提供更好的电力服务。

电网监报告警信息作为数据采集与监视控制SCADA(Supervisory Control And Data Acquisition)系统产生的中文文本信息, 是调控人员监视电网运行状态的重要方式。因此, 相关学者对电网监报告警信息的挖掘利用进行了大量的研究工作。一方面, 通过专家告警系统将告警信息与专家经验知识相结合并生成规则存储在知识库中, 当电网告警事件发生时, 将输入的告警信息与专家知识库进行规则匹配以诊断故障事件的类别<sup>[4]</sup>。随着电网各系统业务数据的丰富和技术的发展, 有关学者基于专家知识库进行了相关改进以提高系统知识的完备性<sup>[5-6]</sup>; 另一方面, 通过对文本信息的智能化处理, 实现对监控信息的进一步分析。文献[7]通过关键字匹配算法完成单条监报告警信息的解析, 最终将信息映射到故障诊断模型中。文献[8]则通过正则表达式的既定规则对监报告警信息的关键要素进行匹配识别。由于监报告警信息文本具备多歧义、难切分、多噪声等特点, 文本内容无法充分挖掘<sup>[9]</sup>, 因

此上述方法均主要基于人脑所建立的相关规则和知识库进行推理、匹配、识别, 规则和知识库均需要人工提炼和维护。随着电网结构的日益复杂以及设备的不断增加, 基于知识库的电网信息处理方法已经日趋无法满足当前电网的发展现状, 存在不具备自主学习功能以及在漏报、误报情况下事件的识别率无法得到保证等不足。

以自然语言处理NLP(Natural Language Processing)和深度学习技术为代表的新一代人工智能技术的崛起为海量监报告警信息的智能化识别带来新的解决思路和方法<sup>[10-11]</sup>。NLP技术能够将文本中的经验和语义信息转化成计算机所能使用的数字信息, 实现计算机对人类语言信息的理解和学习, 国内外已有学者将其应用于电力系统领域的电网设备缺陷文本分析与故障预测<sup>[12-13]</sup>; 同时, 深度学习技术作为机器学习的一个发展分支, 相比于传统的机器学习模型, 其可以充分学习监控大数据样本特征, 减少人工知识库建立和故障识别的工作量, 并已广泛应用于暂态稳定评估<sup>[14]</sup>、负荷预测<sup>[15]</sup>、故障诊断<sup>[16]</sup>及用能分析<sup>[17]</sup>等多种场景。

因此, 为了进一步探索适应性强、智能化程度高的电网监报告警信息挖掘方法, 本文以智能告警为应用背景, 提出一种基于深度学习的电网监报告警事件智能识别方法, 并在此基础上融合了传统知识库方法以提高系统的可靠性。

## 1 基于 Word2vec 的监报告警信息向量化模型

海量监报告警信息为NLP在电网监控领域的应用提供了天然语料, 要想使计算机能够理解文本信息中蕴含的深层语义, 就必须将监报告警信息等文本信息转换为数字信息。因此, 本文采用NLP中的Word2vec模型对监报告警信息进行向量化建模, 为后续事件的识别模型提供输入基础。

收稿日期: 2019-06-18; 修回日期: 2019-12-25

基金项目: 国家电网公司科技项目(SGJSNJ00FCJS1800810)

Project supported by the Science and Technology Program of State Grid Corporation of China(SGJSNJ00FCJS1800810)

### 1.1 Word2vec 模型

Word2vec 模型是 Google 于 2013 年推出的一款用于训练词向量的工具,提供了一种使用分布式向量表示文本的方法<sup>[18]</sup>,是一种无监督模型。与传统的词向量空间模型相比,其使用 Word2vec 表示词向量可以解决传统模型的高维稀疏特征问题,还可以将上下文语义特征引入模型中,有助于短文本的分类。Word2vec 模型主要分为 CBOW(Continuous Bag-Of-Words)模型和 Skip-gram 模型 2 种,模型的结构详见文献[19]。

2 种模型均包含输入层、投影层和输出层。CBOW 模型的输入是周围词的词向量,输出是当前词的词向量,即通过周围词来预测当前词。如学习已经预处理的监控告警信息“xx 变 244 限时速断保护动作”,当模型的输出为“速断”时,则以其前后词的 one-hot 编码表示为输入,以“速断”的 one-hot 编码表示为输出进行训练迭代,最终得到每个词的分布式词向量表示。Skip-gram 模型则与 CBOW 模型相反,其输入是当前词的词向量,输出是周围词的词向量,即通过当前词预测周围词。由于 CBOW 模型的训练效率更加高效,本文主要使用基于 CBOW 模型的训练框架<sup>[20]</sup>。

### 1.2 监控告警信息中词向量的表达效果

Word2vec 训练的词向量在语义特征上具有很好的表达效果,为了直观地感受词向量的效果,以大量的历史监控告警信息为语料库进行训练得到每个词的词向量表示,向量维度可以自定义,每一维度的数值没有具体含义,仅代表系统自动学习到的一个特征表达。表 1 展示了词向量在余弦相似度上较高的部分词。由表可以看出,词的相似度越高,往往在语义也是相似或者相关的。因此,Word2vec 训练得到的模型可以很好地表达监控告警信息中词语的语义信息。

表 1 语义相似或相关的部分词语

Table 1 Some words with similar or related semantics

词组 1	词组 2	相似度	词组 1	词组 2	相似度
监视系统	视频	0.9853	联锁	防误	0.8963
闪变	波动	0.9670	加热	照明	0.8952
过程层	交换机	0.9680	轻瓦斯	油温高	0.8331
青岛	拉萨	0.9083	非全相	三相不一致	0.7477
网关	数据通信	0.9178	过电流	速断	0.7476

### 1.3 基于 Word2vec 模型的监控告警信息向量化建模处理流程

对监控告警信息的向量化过程主要分为以下 4 个部分。

(1)分词。通过资料查阅收集专业电力词库并将从历史监控告警信息中导出的线路名称导入词库构成电力词典。采用 jieba 分词工具的精确模式进

行初始分词,生成按时间排序的由一系列中文词组组成的监控告警信息。

(2)去停用词。剔除停用词表中无意义的字符,实现数据清洗以提高后期的训练效果。

(3)向量化建模。利用 Word2vec 模型对监控告警信息进行无监督训练,生成蕴含语义特征的高维词向量。

(4)平均化处理。参考文献[21]中的短文本特征表达方式,将单条监控告警信息中的所有词向量求平均值,得到监控告警信息句向量,这种方法在一定程度上可以表达信息语义。

处理方法的流程图如图 1 所示。

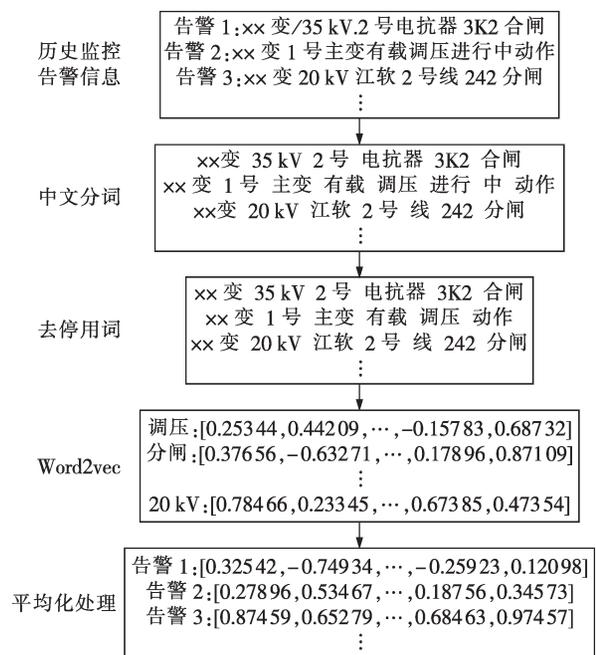


图 1 监控告警信息向量化过程

Fig.1 Vectorization process of monitoring alarm messages

## 2 基于 NLP 和卷积神经网络模型的监控告警事件识别

电网事件所触发的监控告警信息是在短时间内连续发生的,即从语义而言,局部信息间是有“上下文”联系的,相邻的特定信息中具有推出事件结果的重要特征,卷积神经网络 CNN(Convolutional Neural Network)模型具有优异的局部特征提取性能,可以挖掘相邻监控告警信息间的关联性特征,从而识别告警事件的类型。因此本文基于深度学习中的 CNN 模型构建事件识别模型。

### 2.1 CNN 模型

CNN 模型是一种带有卷积结构的前馈神经网络,相比于传统的神经网络,其具有局部连接和权重共享等特点,可以大幅降低网络的参数量并缓解模

型的过拟合问题。CNN模型最初是因在图像处理领域的应用而提出的<sup>[22]</sup>,但随着NLP的发展,近年来已逐渐运用于文本处理领域。CNN模型一般包括输入层、卷积层、池化层和全连接层,本文采用文献[23]中的网络结构,如图2所示。

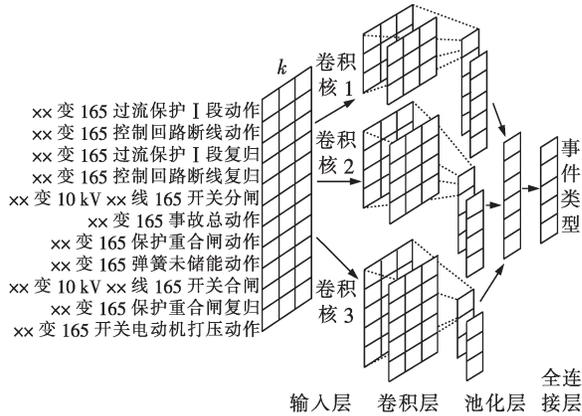


图2 CNN结构

Fig.2 Structure of CNN

第1层(输入层):输入为包含多条监控告警信息的一个待分类告警事件对应的矩阵 $H \in \mathbf{R}^{n \times k}$ ,其中 $n$ 为监控告警信息的数量(图2中 $n=11$ ), $k$ 为每条监控告警信息的向量维度。以“线路瞬时故障”事件识别为例,输入为该事件触发的11条监控告警信息,每条监控告警信息在向量表示阶段已经表示为 $k$ 维向量,所构成的矩阵 $H$ 作为输入层。在训练过程中,句向量一般会使用随机梯度下降SGD(Stochastic Gradient Descent)进行调整以满足更高的分类精度。

第2层(卷积层):对于输入层矩阵 $H \in \mathbf{R}^{n \times k}$ ,采用行数为 $h$ 、列数与 $H$ 相同的卷积矩阵 $W \in \mathbf{R}^{h \times k}$ 与输入层矩阵 $H$ 中相同大小的子矩阵进行卷积操作,从上往下依次移动卷积矩阵 $W$ 并重复进行相同的卷积操作,从而得到卷积结果:

$$r_i = W \otimes H_{i:i+h-1} \quad (1)$$

其中, $i = 1, 2, \dots, n - h + 1$ ;  $H_{i:i+h-1}$ 为由矩阵 $H$ 的第 $i$ 行至第 $i+h-1$ 行组成的子矩阵;运算符号“ $\otimes$ ”表示卷积操作,即将2个矩阵相同位置的元素相乘然后求和。每次得到的卷积结果经过非线性操作后的结果为:

$$c_i = \text{ReLU}(r_i + b_i) \quad (2)$$

其中,ReLU为激活函数,其计算公式为 $f(x) = \max(0, x)$ ;  $b_i$ 为偏置项。经过 $n - h + 1$ 次操作后将所有结果依次排列堆积得到卷积层的特征向量 $c \in \mathbf{R}^{n-h+1}$ 。由于事件发生时只有部分信息对事件的识别结果起主要作用,其他信息则为干扰性伴随信号。如“线路瞬时故障”事件中,“重合闸动作”信号和“开关合闸”信号触发则隐含说明“重合成功”这

一特征,但如图2所示,这2个主要信息之间夹带了“弹簧未储能”这一伴随信号,如果卷积矩阵 $W$ 的行数 $h=2$ ,则无法提取到这一主要特征。因此,通过改变卷积矩阵的行数 $h$ 形成不同类别的矩阵窗口,可以更加充分地提取局部监控告警信息间的关联特征,图2中标注了3种不同类别的卷积矩阵。同时,每类矩阵窗口也有多个,类内不同卷积矩阵的元素值各不相同,能够形成更加完整的特征表达。

第3层(池化层):池化层通过一定的下采样规则对特征向量进行降维,常见的2种方法为最大池化法和平均池化法,本文采用最大池化法。取每个经卷积层操作得到的特征向量 $c$ 中的最大值作为特征值,即:

$$c_{\max} = \max\{c\} \quad (3)$$

将所有不同的特征向量经池化操作提取的特征值拼接形成池化层输出向量 $p \in \mathbf{R}^t$ ,其中 $t = ab$ , $a$ 为卷积矩阵的类别数, $b$ 为不同类别的卷积矩阵数量。池化操作大幅降低了特征维度,提高了模型的训练效率。

第4层(全连接层):池化层和输出层之间为全连接网络,池化层向量 $p$ 经全连接层并经softmax函数输出属于每个事件类别的概率,选取概率最大的事件类别作为该段输入监控告警信息的事件化识别结果,如式(4)所示。

$$q = \text{softmax}(W_0 p + b_0) \quad (4)$$

其中, $q$ 为事件的类别概率; $W_0$ 为池化层向量 $p$ 的权重; $b_0$ 为池化层向量 $p$ 的偏置项。

最终,在大量的样本训练过程中,通过CNN挖掘得到事件的局部隐含特征,并将其转化为网络权值和矩阵参数的迭代更新,构建事件识别模型。

## 2.2 基于NLP和CNN模型的监控告警事件识别流程

为了摆脱专家知识库基于规则推理的局限,实现计算机对故障事件的自主判别,提高监控告警事件识别的容错能力和判别效率,本文利用CNN模型对监控告警事件进行自主识别,其主要步骤如下。

(1)收集本文所需的基本数据,如电网监控告警历史信息、变电站及线路名称统计信息,建立电力词典、停用词表等。

(2)对原始监控告警信息进行预处理,包括分词、去停用词等,并利用NLP技术对其进行向量化表示。

(3)从历史信息中提取带标签的事件样本。具体以带分词关键词的信息为标志,提取该信息前后一段时间窗内的离散告警信息集合;当满足一定的规则后,构成各类标签化监控告警事件,并对照调度日志进行校核。最终构建可供模型学习的事件样

本库。

(4)搭建训练模型结构,设置各类超参数,建立目标函数并选取优化算法。

(5)划分训练集和测试集,训练模型并在测试集上对模型的识别效果进行测试。

(6)构建混淆矩阵,并使用准确率、精确率、召回率和 $F_1$ 值(具体公式见下一节)等评估指标对模型识别效果进行评价,观察识别正确率是否满足应用要求。

(7)在线应用验证模型识别效果,并与基于知识库方法的专家系统的判断结果结合使用。若自动推送识别结果,则直接加入样本库进行训练学习;若无法自动推送结果,则由调度员进行人工判断并将修改成正确标签后的事件样本加入样本库,供模型进行训练学习。随着样本量和样本类型的不断增加,模型的识别正确率和鲁棒性会逐渐提升。

### 3 算例分析

#### 3.1 数据选择与处理

本文以某市供电公司2017年约600万条历史监控股警信息为语料测试本文所建模型的应用效果。首先,使用分词工具对所有监控股警信息进行分词处理,将监控股警信息转换成分布式句向量;然后,对照调度日志采用半自动半人工的方式从历史信息中提取5类事故跳闸事件,分别为线路瞬时故障(重合成功)、线路永久故障(重合失败)、线路永久故障(重合未动)、容抗器故障和所变/接地变故障,所提取的事件包含了事故发生时某一固定时间窗内的所有监控股警信息,因此会夹带少数非本事件所触发的信息。深度学习网络具有强鲁棒性,因此对冗余信息具有一定的容错能力。所提取的各类告警事件类型及样本数量如表2所示。由于母线故障、主变类故障事件的样本数量整体偏少,因此本文没有将其纳入训练与测试。

表2 样本分类统计

Table 2 Sample classification statistics

故障类型	样本量
线路瞬时故障(重合成功)	1130
线路永久故障(重合失败)	918
线路永久故障(重合未动)	910
容抗器故障	459
所变/接地变故障	86
合计	3503

#### 3.2 CNN模型参数设置

CNN模型为4层神经网络,输入层为 $m \times n$ 阶矩阵,其中 $m=104$ 为输入监控股警信息的最大条数, $n=300$ 为单条监控股警信息的向量维度;输出节点数取5,输出为one-hot编码表示的事件类别向量,其中对模型性能影响甚微的部分参数,本文通过多次实

验并通过网格搜索寻优确定了最终的参数:监控股警信息的向量维度为300,每类卷积核个数为100,丢弃率为0.5,批处理尺寸为50,迭代代数数为10。

为了使模型达到最好的分类性能、提高模型识别准确率,本文设计了几组对照试验,分别改变模型初始输入向量的生成方式(对比模型A)、卷积窗口尺寸(对比模型B)、模型训练中告警向量是否更新(对比模型C)等主要影响参数,将其与本文所构建的模型进行对比分析。各模型参数设置如表3所示。

表3 各模型的参数设置

Table 3 Parameter setting of each model

模型	卷积窗口 尺寸1	卷积窗口 尺寸2	卷积窗口 尺寸3	输入向量 是否随机	输入向量 是否更新
本文模型	3	4	5	是	是
对比模型A	3	4	5	否	是
对比模型B	4	4	4	是	是
对比模型C	3	4	5	是	否

此外,为了将本文所提基于CNN的识别模型分类效果与传统模型进行比较,选取了几种典型的传统机器学习模型进行对比验证。传统模型的文本表示主要采用词频-逆文件频率TF-IDF(Term Frequency-Inverse Document Frequency)方法<sup>[24]</sup>和每个事件样本内所有采用Word2vec表示的词向量平均化方法<sup>[25]</sup>,即将提取得到的事件样本所包含的所有监控股警信息类比为一篇文章;传统模型主要选取了人工神经网络(ANN)、支持向量机(SVM)分类和随机森林等经典机器学习模型,其中ANN同样采用4层神经网络。

#### 3.3 评估标准

为了验证事件识别模型分类效果,实验采用准确率、精确率、召回率、 $F_1$ 值作为事件识别准确性的评估指标。二分类混淆矩阵如表4所示。

表4 事件识别中的混淆矩阵

Table 4 Confusion matrix of event recognition

实际归属	识别归属	
	识别为该事件	识别为其他事件
实际为该事件	TP	FN
实际为其他事件	FP	TN

混淆矩阵将所有事件按照其实际归属和识别归属分为TP(True Positive)、FN(False Negative)、FP(False Positive)、TN(True Negative)4类,定义准确率 $A_c$ 、精确率 $P_r$ 、召回率 $R_e$ 、 $F_1$ 值4个指标来衡量模型的识别效果,计算式分别见式(5)~(8)。

$$A_c = (l_{TP} + l_{TN}) / (l_{TP} + l_{FN} + l_{FP} + l_{TN}) \quad (5)$$

$$P_r = l_{TP} / (l_{TP} + l_{FP}) \quad (6)$$

$$R_e = l_{TP} / (l_{TP} + l_{FN}) \quad (7)$$

$$F_1 = 2P_r R_e / (P_r + R_e) \quad (8)$$

其中, $l_{TP}$ 、 $l_{FN}$ 、 $l_{FP}$ 、 $l_{TN}$ 分别为TP、FN、FP、TN类事件的

数量。准确率 $A_c$ 表示识别正确的事件占全部事件的比例;精确率 $P_r$ 表示被模型识别为该类事件的样本中实际为该类事件的比例;召回率 $R_c$ 表示实际为该类事件的样本中识别为该类事件的比例; $F_1$ 值则是对精确率和召回率的综合平均。四者的取值范围都为 $[0, 1]$ ,取值越接近于1说明模型的识别效果越好。

### 3.4 实验结果分析

#### 3.4.1 模型识别效果分析

本文模型优化采用Adam优化算法,采用10折交叉验证,并取10次实验结果的平均值作为参考标准。通过多次试验和参数调节,可以得到各模型的识别结果如表5所示,本文模型的具体指标如表6所示,本文模型与传统机器学习模型的结果比较如表7所示。

表5 各模型的识别结果

Table 5 Recognition results of each model

模型	准确率/%	训练时间/s	测试时间/s
本文模型	95.14	760.13	7.71
对比模型A	93.93	315.52	4.63
对比模型B	93.25	746.00	4.51
对比模型C	93.62	624.45	4.78

表6 基于本文模型各类事件的识别结果

Table 6 Recognition results of various events based on proposed model

事件类型	精确率/%	召回率/%	$F_1$ /%	样本量
线路瞬时故障 (重合成功)	95.13	95.12	95.15	122
线路永久故障 (重合失败)	91.41	93.44	92.47	91
线路永久故障 (重合未动)	96.21	97.43	96.86	78
容抗器故障	100	98.13	99.05	52
所变/接地变故障	100	66.74	80.07	6
加权平均值	95.21	95.15	95.15	—

表7 本文模型与传统模型的识别结果比较

Table 7 Comparison of recognition result among proposed model and traditional models

模型	准确率/%	训练时间/s	测试时间/s
本文模型	95.14	760.13	7.71
TF-IDF+ANN	86.87	53.98	0.06
Word2vec+ANN	89.57	19.49	0.13
TF-IDF+SVM	88.52	14.62	0.91
Word2vec+SVM	90.83	8.07	0.11
TF-IDF+随机森林	90.36	3.91	0.03
Word2vec+随机森林	92.24	6.84	0.04

分析表5—7所示结果可以得到如下结论。

(1)由表5中对比模型A的结果可以看出,相比于随机生成模型初始化输入,利用语料库进行提前训练生成监控告警信息向量可以显著提高模型的准

确率,虽然前期对词向量的训练会花费一定量的时间,但是大样本量的模型训练一般为提前的离线训练,并不占用在线测试时间,因此在实际工程应用中应当提前使用相应的语料库进行监控告警信息向量生成。

(2)由表5中对比模型B的结果可以看出,改变卷积窗口尺寸的大小,可以有效改变对发生事件所触发的一系列时序性监控告警信息的局部特征的提取效果,最大限度地实现局部特征与事件类别的匹配,从而提高事件的识别准确率。

(3)由表5中对比模型C的结果可以看出,相比于初始输入向量在训练过程中固定不变的训练模式,对输入向量的不断更新迭代微调可以在一定程度上提高模型的识别准确率。

(4)由表6所示结果可以看出,本文模型对简单事件的识别准确率比较高,但是对复杂性事件如线路永久故障(重合失败)的识别准确率则相对有所降低。

(5)由表7所示本文模型与传统机器学习模型的对比结果可以看出,本文所提模型的识别准确率明显高于其他传统模型,传统模型中识别准确率最高的为Word2vec+随机森林模型,达到92.24%,而本文模型的准确率达到更高的95.14%;在文本表示方面,由于Word2vec模型能够挖掘监控告警信息中的语义特征,而TF-IDF表示是基于单纯词频统计而忽略词语语义,因此也有助于提升本文模型的识别准确率;在模型训练时间方面,由于本文模型一方面需要学习信息语义,另一方面CNN模型的结构复杂,参数较多,因此训练时间较长,但是基于较长时间离线训练换取测试准确率的方式具有实际的工程应用效益,349个告警事件的测试时间约为8s,相比于人工判断,效率得到了显著的提升。

#### 3.4.2 模型容错性分析

为了测试模型的容错能力,设置了4种测试集,分别为正常测试集(测试集1)、漏报带“分闸”信息的测试集(测试集2)、在每个测试样本的随机位置误报了1条随机信息(测试集3)、在每个测试样本的随机位置误报了2条随机信息(测试集4),然后对模型在不同测试集上的识别准确率进行对比分析,结果如图3所示。

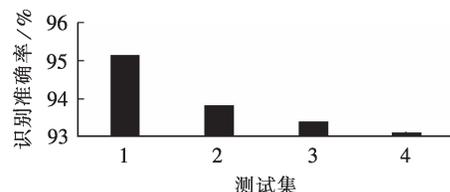


图3 本文模型在不同测试集下的识别准确率

Fig.3 Recognition accuracy rate of proposed model under different test sets

由图3可知,本文模型在出现漏报重要信息、误报干扰信息等情况下的识别准确率均有所降低,但仍能保持较高的识别准确率。因此,在实际调控系统的监控窗口中,可以将本文所提方法与专家知识库方法进行结合使用后推送事件识别结果,将事件触发的监控告警信息进行归并折叠,当调控人员需要对必要事件进行机理分析时可自行展开查看,从而提高监控系统的智能性与监视效率。

### 3.5 工程应用

为了测试本文所提方法的应用效果,以2018年8月17日“温比亚”台风过境当天所截取的某信息密集时段(13:27—13:31)内所触发的监控告警事件作为应用对象,从该时段内的4146条监控告警信息中提取出6个适用于本文模型的监控告警事件,经模型最终识别全部正确,识别时间为0.5 s。虽然在线应用的样本量较少,但是本文模型在实际应用中的事件识别准确率已经达到较高的程度,具有良好的实际工程应用价值。典型应用事件的识别结果如附录中表A1所示。

### 3.6 融合知识库与本文模型的应用分析

当前D5000监控系统中成熟应用的综合智能告警系统的核心是基于知识库的故障判别方法,但是由于其知识构成相对固定且严格,容错性较差,当信息缺失或错误时,则会出现误判漏判;而基于深度学习的神经网络方法具有较强的鲁棒性和学习能力。因此,本文提出将传统专家知识库方法和本文模型结合使用的思路,以降低在线应用的误判和漏判率。流程图如图4所示。

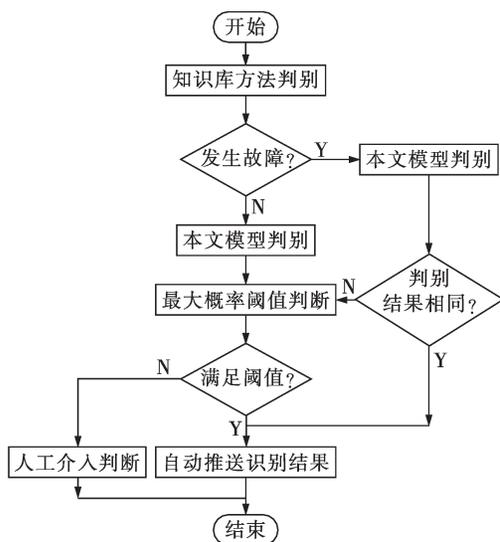


图4 融合知识库方法与本文模型的应用流程图

Fig.4 Application flowchart of combining knowledge base method with proposed model

本文所提识别模型属于神经网络模型,最后输出归属于每个事件类别的概率,并选取概率最大的

那类事件作为最终的事件识别结果,必要时可以通过设置模型的最大概率阈值(如95%,可整定)作为本文模型是否识别正确的条件。

首先,采用知识库方法进行在线监视,只有当监控信息特征满足库中的逻辑知识,才会推送故障结果。若的确无故障发生或者特征丢失不满足逻辑知识(即出现漏判)都会输出一切正常。然后,进入本文模型判别,此时由于仅依靠本文模型进行故障类型判别,为了降低误判,需启动最大概率阈值判断,若满足阈值,则可自动推送识别结果;若不满足阈值要求,则需要通过人工介入判断。

同样地,若特征满足知识库方法的条件,便启动知识库方法判别并输出某一故障结果(包括故障判断正确或误判2种情况)。当知识库方法出现故障的判别结果后,进入本文模型判别,若本文模型判断结果与前者相同,则直接通过双重验证,输出最终的结果(为了降低两者同时误判的概率,当两者结果相同,且经事后分析发现仍然误判时,则需要进行逻辑分析和模型修复来减少此类情况的发生),若本文模型判断结果与前者不同,为了降低误判率,则启动最大概率阈值判断,若满足阈值,则说明本文模型的可信度较高,可直接输出最终结果;若不满足最大概率阈值,则需要人工介入判断。

当知识库方法出现误判或漏判时,本文模型可以对其进行补充判别;当本文模型出现误判时,可通过最大概率阈值判断或与知识库方法结果一致性判断来提升识别结果的可靠性。由以上分析可见,两者结合使用可以进一步降低事件识别的误判率和漏判率。

## 4 结论

本文针对当前海量监控告警信息人为处理效率低、误判率高等现状,从监控业务的实际需求出发,提出了一种融合知识库和深度学习的监控告警事件识别方法。将CNN模型在挖掘单条短文本局部特征中具有的优势性能类比应用于对一系列时序短文本的局部特征提取中,并结合Word2vec模型对分布式向量表示的优势构建能够自主识别电网监控告警事件的分类模型。通过离线训练和在线应用验证了本文模型的有效性和实用性,并与知识库融合应用提高所提方法的可靠性,为人工智能应用于电网监控领域的发展提供了新的思路。

本文所提方法需要基于足量样本对知识和经验进行学习,因此样本量较少的事件可以采用基于知识库的处理方法,两者的有机结合才能构成完整的智能告警系统。下一步的工作将尝试引入更多的特征输入以及丰富更多电网事件类别及其样本量,从而提高本文所提方法的泛化能力。另外,本文是辅

助决策的第一个重要环节,为调度员快速推送故障节省了时间,关于监控人员进一步进行决策分析、事件分级处置等将是后续的研究方向。

附录见本刊网络版(<http://www.epae.cn>)。

### 参考文献:

- [1] 中国电机工程学会信息化专委会. 中国电力大数据发展白皮书[M]. 北京:中国电力出版社,2013:9-11.
- [2] 张东霞,苗新,刘丽平,等. 智能电网大数据技术发展研究[J]. 中国电机工程学报,2015,35(1):2-12.  
ZHANG Dongxia, MIAO Xin, LIU Liping, et al. Research on development strategy for smart grid big data[J]. Proceedings of the CSEE, 2015, 35(1): 2-12.
- [3] 龚钢军,张帅,吴秋新,等. 基于TensorFlow的高压输电线路异物识别[J]. 电力自动化设备,2019,39(4):204-209,216.  
GONG Gangjun, ZHANG Shuai, WU Qiuxin, et al. Foreign body identification based on TensorFlow for high voltage transmission line[J]. Electric Power Automation Equipment, 2019, 39(4): 204-209, 216.
- [4] LEE H J, PARK D Y, AHN B S, et al. A fuzzy expert system for the integrated fault diagnosis[J]. IEEE Transactions on Power Delivery, 2000, 15(2): 833-838.
- [5] 闪鑫,戴则梅,张哲,等. 智能电网调度控制系统综合智能告警研究及应用[J]. 电力系统自动化,2015,39(1):65-72.  
SHAN Xin, DAI Zemei, ZHANG Zhe, et al. Research on and application of integrated smart alarm based on smart grid dispatching and control systems[J]. Automation of Electric Power Systems, 2015, 39(1): 65-72.
- [6] 李再华,白晓民,周子冠,等. 基于特征挖掘的电网故障诊断方法[J]. 中国电机工程学报,2010,30(10):16-22.  
LI Zaihua, BAI Xiaomin, ZHOU Ziguan, et al. Method of power grid fault diagnosis based on feature mining[J]. Proceedings of the CSEE, 2010, 30(10): 16-22.
- [7] 张旭,魏娟,赵冬梅,等. 一种用于电网故障诊断的遥信信息解析方法[J]. 中国电机工程学报,2014,34(22):3824-3833.  
ZHANG Xu, WEI Juan, ZHAO Dongmei, et al. An analytic alarm information method for power grid fault diagnosis[J]. Proceedings of the CSEE, 2014, 34(22): 3824-3833.
- [8] 鲁华永,袁越,郭泓佐,等. 基于正则表达式的变电站集中监控信息解析方法[J]. 电力系统自动化,2017,41(5):78-83.  
LU Huayong, YUAN Yue, GUO Hongzuo, et al. Regular expressions based information analytic method for substation centralized monitoring[J]. Automation of Electric Power Systems, 2017, 41(5): 78-83.
- [9] 邱剑,王慧芳,应高亮,等. 文本信息挖掘技术及其在断路器全寿命状态评价中的应用[J]. 电力系统自动化,2016,40(6):107-112,118.  
QIU Jian, WANG Huifang, YING Gaoliang, et al. Text mining technique and application of lifecycle condition assessment for circuit breaker[J]. Automation of Electric Power Systems, 2016, 40(6): 107-112, 118.
- [10] 鞠平,周孝信,陈维江,等. “智能电网+”研究综述[J]. 电力自动化设备,2018,38(5):2-11.  
JU Ping, ZHOU Xiaoxin, CHEN Weijiang, et al. “Smart Grid Plus” research overview[J]. Electric Power Automation Equipment, 2018, 38(5): 2-11.
- [11] 汪崔洋,江全元,唐雅洁,等. 基于告警信号文本挖掘的电力调度故障诊断[J]. 电力自动化设备,2019,39(4):126-132.  
WANG Cuiyang, JIANG Quanyuan, TANG Yajie, et al. Fault diagnosis of power dispatching based on alarm signal text mining[J]. Electric Power Automation Equipment, 2019, 39(4): 126-132.
- [12] RUDIN C, WALTZ D, ANDERSON R N, et al. Machine learning for the New York City power grid[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(2): 328-345.
- [13] 刘梓权,王慧芳,曹靖,等. 基于卷积神经网络的电力设备缺陷文本分类模型研究[J]. 电网技术,2018,42(2):644-650.  
LIU Ziquan, WANG Huifang, CAO Jing, et al. A classification model of power equipment defect texts based on convolutional neural network[J]. Power System Technology, 2018, 42(2): 644-650.
- [14] 尹雪燕,闫炯程,刘玉田,等. 基于深度学习的暂态稳定评估与严重程度分级[J]. 电力自动化设备,2018,38(5):64-69.  
YIN Xueyan, YAN Jiongcheng, LIU Yutian, et al. Deep learning based transient stability assessment and severity grading[J]. Electric Power Automation Equipment, 2018, 38(5): 64-69.
- [15] 牛哲文,余泽远,李波,等. 基于深度门控循环单元神经网络的短期风功率预测模型[J]. 电力自动化设备,2018,38(5):36-42.  
NIU Zhewen, YU Zeyuan, LI Bo, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network[J]. Electric Power Automation Equipment, 2018, 38(5): 36-42.
- [16] 黄新波,胡潇文,朱永灿,等. 基于卷积神经网络算法的高压断路器故障诊断[J]. 电力自动化设备,2018,38(5):136-140,147.  
HUANG Xinbo, HU Xiaowen, ZHU Yongcan, et al. Fault diagnosis of high-voltage circuit breaker based on convolution neural network[J]. Electric Power Automation Equipment, 2018, 38(5): 136-140, 147.
- [17] 赵文清,沈哲吉,李刚. 基于深度学习的用户异常用电模式检测[J]. 电力自动化设备,2018,38(9):34-38.  
ZHAO Wenqing, SHEN Zheji, LI Gang. Anomaly detection for power consumption pattern based on deep learning[J]. Electric Power Automation Equipment, 2018, 38(9): 34-38.
- [18] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space[J]. Computer Science, 2013(1): 28-36.
- [19] MIKOLOV T, LE Q V, SUTSKEVER I. Distributed representations of words and phrases and their compositionality[J]. Advances in Neural Information Processing Systems, 2013, 26: 3111-3119.
- [20] 周练. Word2vec的工作原理及应用探究[J]. 科技情报开发与经济,2015,25(2):145-148.  
ZHOU Lian. Exploration of the working principle and application of Word2vec[J]. Sci-Tech Information Development & Economy, 2015, 25(2): 145-148.
- [21] 高明霞,李经纬. 基于word2vec词模型的中文短文本分类方法[J]. 山东大学学报(工学版),2019,49(2):34-41.  
GAO Mingxia, LI Jingwei. Chinese short text classification method based on word2vec embedding[J]. Journal of Shandong University(Engineering Science), 2019, 49(2): 34-41.
- [22] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [23] KIM Y. Convolutional neural networks for sentence classification[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha, Qatar: Association for Computational Linguistics, 2014: 1746-1751.
- [24] 施聪莺,徐朝军,杨晓江. TFIDF算法研究综述[J]. 计算机应用,2009,29(增刊1):167-170,180.  
SHI Congying, XU Chaojun, YANG Xiaojiang. Study of TFIDF algorithm[J]. Journal of Computer Applications, 2009, 29(Sup-

plement 1):167-170,180.

[25] 李林. 基于word2vec和卷积神经网络的文本分类研究[D]. 重庆:西南大学,2018.

LI Lin. Research on text classification based on word2vec and convolutional neural network[D]. Chongqing:Southwest University,2018.

#### 作者简介:

孙国强(1978—),男,江苏江阴人,副教授,博士,主要研究方向为电力系统运行分析、新能源发电以及直流输电系统



孙国强

(E-mail:hhusunguoqiang@163.com);

沈培锋(1971—),男,江苏南京人,研究员级高级工程师,硕士,主要研究方向为电力系统规划及运营管理(E-mail:15150688959@139.com);

赵扬(1982—),男,江苏南京人,高级工程师,硕士,主要研究方向为电力系统调控运行(E-mail:279007604@qq.com)。

(编辑 陆丹)

## Intelligent recognition of power grid monitoring alarm event combining knowledge base and deep learning

SUN Guoqiang<sup>1</sup>, SHEN Peifeng<sup>2</sup>, ZHAO Yang<sup>2</sup>, ZHU Hongqin<sup>2</sup>, DING Xiaoliu<sup>1</sup>,  
WEI Zhinong<sup>1</sup>, ZANG Haixiang<sup>1</sup>

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 210098, China;

2. Nanjing Power Supply Company of State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210019, China)

**Abstract:** Power grid monitoring alarm information is an important data base for monitoring personnel to identify monitoring events. In view of the low efficiency of artificial processing of mass monitoring alarm information and the demand for deepening the application of power grid intelligent technologies, an automatic recognition of power grid monitoring alarm events based on knowledge base and deep learning is proposed. Based on Word2vec model in natural language processing technology, the vectorized modeling of monitoring alarm information is carried out, and the recognition model of monitoring alarm event is established based on convolutional neural network. The effectiveness and practicability of the proposed model are verified by comparison of examples. The application method of integrating knowledge base and the proposed model is proposed, which realizes the intelligent perception and reliable recognition of power grid monitoring alarm events.

**Key words:** power grid monitoring; alarm message; Word2vec; convolutional neural network; event recognition; knowledge base; deep learning

# 附 录

表 A1 典型监控告警事件的识别结果  
Table A1 Recognition results of typical monitoring alarm events

监控告警事件	识别结果	监控告警事件	识别结果
××市××变 10kV 段母线接地告警动作 ××市××变 10kV 段母线接地告警复归 ××市××变 10kV 九莲塘线 111 分闸 ××市××变 111 保护动作 ××市××变 111 事故总信号动作 ××市××变全站事故总动作 ××市××变 10kV 九莲塘线 111 合闸 ××市××变 111 重合闸动作 XX 市 XX 变 111 弹簧未储能动作 XX 市 XX 变 111 重合闸复归 XX 市 XX 变 111 事故总信号复归 XX 市 XX 变 111 弹簧未储能复归	线路瞬时故障 (重合成功)	××市××变 272 开关过流 II 段动作 ××市××变 272 开关过流 II 段复归 ××市××变朱门线 272 分闸 ××市××变 272 开关事故总信号动作 ××市××变全站事故总动作 ××市××变 272 开关重合闸动作 ××市××变朱门线 272 合闸 ××市××变 272 开关弹簧未储能动作 ××市××变 272 开关重合闸复归 ××市××变事故总信息复归 ××市××变全站事故总复归 ××市××变 272 保护装置告警动作 ××市××变 272 开关过流加速动作 ××市××变 272 开关过流加速复归 ××市××变 10kV 朱门线 272 分闸	线路永久故障 (重合失败)