

基于数据增强和深度学习的水电站告警事件诊断

孙国强¹, 章逸舟¹, 唐杰阳², 唐凡², 卫志农¹, 臧海祥¹, 杨东²

(1. 河海大学 能源与电气学院, 江苏 南京 211100; 2. 雅砻江流域水电开发有限公司, 四川 成都 610051)

摘要:针对水电告警事件传统诊断方法存在效率低下、准确率不足等缺陷,设计了一种融合先验知识的数据增强方法和基于双向简单循环单元网络的层级注意力深度学习框架。针对水电告警规则不完善的问题,采用隐含狄利克雷分布-序列推理增强模型构建告警信号与告警特征间的映射机制;结合该水电告警先验知识提出改进隐含狄利克雷分布方法增强样本数据,最终由层级注意力模型学习样本特征并输出诊断结果。测试算例为某水电集控中心的实际告警数据,测试结果表明,所提方法可在低资源训练环境下实现快速和高准确率的水电告警事件诊断。

关键词:水电站告警事件;文本数据增强;注意力机制;深度学习;先验知识

中图分类号: TM73; TM622

文献标志码: A

DOI: 10.16081/j.epae.202302001

0 引言

当水电站设备运行异常或发生故障时,集控中心将接收大量文本形式的告警信号,而告警事件作为具有完整告警逻辑的离散信号集合,是调度人员分析设备运行状态和决策的重要依据。传统告警事件诊断依靠调度经验构建辨识规则^[1],结合人工识别诊断事件类型,易出现错判、漏判且效率低下。因此水电集控亟需一种快速准确的告警诊断方法,以提升水电站运行管控水平和风险应对能力。

随着人工智能技术发展,机器学习逐渐应用于电力文本识别领域。文献[2]采用支持向量机和 k -均值聚类算法处理实现缺陷文本的故障类型诊断。文献[3]提出基于卷积神经网络(convolutional neural networks, CNN)的电力缺陷文本诊断方法,诊断效果优于部分传统机器学习模型。为解决模型不能提取关键信息的问题,文献[4]将注意力机制和双向长短期记忆网络(bidirectional long short term memory, Bi-LSTM)结合进行电力设备缺陷文本类型识别。但上述研究分析的都是单句电力文本,对多信号序列的长告警文本未提出解决方案。针对电力系统中的告警事件分析,文献[5]结合CNN和长短期记忆网络(long short term memory, LSTM)的优点,构建CNN-LSTM模型诊断告警事件类型,实现识别精度的突破;文献[6]提出融合知识库和文本卷积神经网络(TextCNN)的电网监控告警诊断方法,具

备较高的容错性和鲁棒性;文献[7]提出代价敏感损失函数和Bi-LSTM结合的方法用于提高样本不平衡时的诊断准确性。但以上方法均无法区分重要词信息,导致精度低且应用场景受限。文献[8]将基于Transformer的双向编码器(bidirectional encoder representation from transformers, BERT)与CNN相结合提出一种电网调控的告警识别方法,但该方法参数量巨大、告警诊断耗时过长,难以应用于实际工程。

此外,样本规模受限也是告警文本分析面临的难题,该情况会导致深度学习模型泛化性减弱,自然语言处理中常采用数据增强的方法解决。有研究借鉴强化学习理论用于文本序列数据增强^[9],但无法保证长文本的生成质量。简单数据增强^[10](easy data augmentation, EDA)是一种基于词粒度的数据增强方法,但存在强随机性可能会向样本传入误导性噪声。实例交叉扩展^[11]是考虑标签的句粒度增强方法,通过情感极性相同的片段组合形成新样本。随着预训练语言模型发展,条件BERT^[12](conditional BERT, CBERT)被提出用于增强文本数据,通过随机遮蔽句间单词生成相同标签的新句子;文献[13]对比多种预训练模型,提出结合预标签信息的序列文本生成框架。但上述方法需大量训练资源,并在部分文本分析任务中的效果逊于EDA等方法。

针对传统水电告警诊断方法难以兼顾诊断效率和精度的问题,本文提出一种基于数据增强和深度学习的告警诊断方法:首先,基于隐含狄利克雷分布(latent Dirichlet allocation, LDA)模型和序列推理增强模型(enhanced sequential inference model, ESIM)构建信号特征映射关系的水电告警先验知识;然后,结合水电告警先验知识提出一种改进EDA的数据增强方法;最后,以改进EDA方法增广训练

收稿日期:2022-06-15;修回日期:2022-12-19

在线出版日期:2023-02-02

基金项目:雅砻江流域水电开发有限公司科技项目(0023-20XJ0017)

Project supported by the Science and Technology Program of Yalong River Hydropower Development Co., Ltd.(0023-20XJ0017)

样本,由基于改进双向简单循环单元网络(bidirectional simple recurrent units++, Bi-SRU++)的层级注意力网络(hierarchical attention networks, HAN)输出告警诊断结果。实际算例验证结果表明,本文方法在水电站发生严重故障,监控系统涌入大量告警信号时可做出智能化响应,兼具较高的诊断速度和精度,提升了集控中心安全调度水平。

1 水电站告警事件

1.1 水电站告警事件的定义和特点

告警信号由集控中心监控的各水电站发出,反映水电站主要设备的运行状态或动作信息。告警信号以 JSON 数据格式存储和转发,可选择时间戳字段、信号源字段、告警描述字段和告警状态字段解析信号主要信息。图 1 展示告警信号经解析后的部分信息,本文的告警信号指代信号的告警内容。

告警时间	告警位置	告警内容
2017-02-08 T 11:54:48	××厂站 1号机组	一号机定子线圈#47 温度过高报警!

图 1 告警信号结构示例

Fig.1 Example of alarm signal structure

告警事件是具有告警逻辑的离散信号集合,反映断路器跳闸、机组停机故障事件及故障主因。按照对事件诊断的重要性层次将信号特征划分为告警特征、辅助特征和一般特征,告警特征指规则库中的重要子逻辑,在事件告警诊断过程中起决定性作用;辅助特征通常反映于设备运行异常或量测值越限的信号,不属于主要告警逻辑;而一般特征反映于正常操作类、通信故障类、检修类信号等。

某典型水电监控告警事件示例见附录 A 图 A1,告警事件以时间窗方法读入:数据源为集控中心接收的告警信号流,以告警特征“出口开关分闸”或“机组事故停机”为时间窗触发特征,提取关联信号源前后一定时间尺度内所有告警状态非“复归”的离散信号构成单次事件。若以规则推理法标注事件类型,应采用关键字段或正则表达式的特征匹配方式,遍历事件告警特征并检验告警逻辑完备性。

水电站监控告警事件具有以下 5 个特点。

1)事件序列长度不统一。由于告警性质和严重程度不同,事件涵盖的告警信号数量存在差异。根据历史数据统计,信号数量在 200 条以上的事件占比约为 6%,20 条以下的事件占比约为 21%,其余告警事件的信号数量在二者之间。

2)告警识别规则复杂。由于缺少水电专业告警准则参考,并且由调度人员编写的水电告警规则库较简略,无法建立准确可靠的规则映射关系。

3)含有冗余特征。告警信号包含厂站、设备型号、设备编号等信息,致使信号内掺杂对事件诊断贡

献较弱的冗余信息。此外当告警发生时,需对邻近时段同信号源中所有可疑元件的告警信号进行遍历^[1],导致事件涵盖部分非关联设备的信号。

4)需要高效准确的告警响应。水电严重故障发生时,集控中心将迅速涌入大量信号,要求短时间内准确诊断当前的多例告警事件用于后续调度决策,对依赖于人工识别的诊断方法提出严峻挑战。

5)样本规模有限且类间数量不均衡。水电站大部分时间运行状态稳定,严重故障发生属于小概率事件,因此样本规模有限。由于水电设备特性不同,关联告警频率存在差异,例如历史数据中母线故障跳闸的事件数量远小于发电机组过速停机。

1.2 水电站告警事件诊断方法

针对传统的水电告警事件诊断方法存在效率、精度较低的问题,本文提出了一种融合水电告警先验知识的数据增强方法和层级注意力网络的告警诊断方法,主要工作如下。

1)完善规则库告警逻辑。梳理集控中心规则库的重要告警特征,并基于 LDA-ESIM 模型构建信号到告警特征的映射机制,形成水电告警先验知识。

2)增强水电告警事件样本。采用融合水电告警先验知识的改进 EDA 数据增强方法,为深度学习模型提供训练数据规模支撑。

3)告警样本的预处理和诊断。对告警事件样本进行分词和过滤停用词的文本预处理,并采用 Word2vec 模型对告警事件进行矩阵化建模。将矩阵化样本输入层级注意力网络进行特征学习,并在实际算例中输出告警诊断结果。

2 融合水电告警先验知识的数据增强

2.1 水电先验告警知识构建

由于各站点电力实体命名方式和告警描述习惯存在差异,不同类型信号可指向同一告警特征,例如信号“机组灭磁开关偷跳联跳 GCB|动作|”和“机组发电机出口开关 203 分位|动作|”都属于告警特征“出口断路器分闸”。而现有的规则库特征范式有限,无法枚举所有告警特征的信号表现情形。针对上述问题,本文提出基于 LDA-ESIM 的信号特征映射关系构建方法,分步处置归并信号的告警特征,方法流程见附录 A 图 A2。

2.1.1 基于 LDA 模型的告警信号聚类

LDA 模型是贝叶斯概率生成模型,关键思路是将文本视为隐含主题的概率分布,主题视为词语的概率分布,该分布的参数服从 Dirichlet 分布,模型采用 Gibbs Sampling 算法求解。由 LDA 模型预聚类告警信号的流程如下。

1)告警信号文本预处理。对告警信号数据进行分词和去停用词的文本预处理,并且为避免特殊信

息干扰模型判断,将站点名、设备编号、设备型号分别标准化为“station”“number”“type”。

2)参数设置。分别设置Dirichlet分布的先验参数 $\alpha=0.1$ 和 $\beta=0.01$,观察主题个数 K 增加时困惑度曲线变化,由拐点确定 K 的最佳取值。

3)形成预聚类结果。计算参数 α 、 β 、 K 确定下的聚类情况,设置最大主题概率的过滤阈值为0.85,高于阈值的样本归并类簇,低于主题概率阈值的标记为模糊信号不参与聚类。最后,剔除信号类型混杂的聚簇及不属于告警特征的低价值聚簇,余下聚簇根据涵盖的信号内容命名聚簇主题。

2.1.2 基于ESIM的模糊信号特征匹配

ESIM由文献[14]提出,是结合Bi-LSTM和交互注意力机制的深度学习模型,模型结构如附录A图A3所示,共分为输入编码层、局部推理层和推理组合层。ESIM以词为最小粒度学习序列间相关性,各词语的词向量由Word2vec模型^[15]生成。首先在输入编码层,由Bi-LSTM编码待匹配的输入词语序列 \mathbf{a} 和 \mathbf{b} ,让序列各词向量融合上下文信息,如式(1)、(2)所示。

$$\bar{\mathbf{a}}_i = \text{Bi-LSTM}(\mathbf{a}, i) \quad i \in \{1, 2, \dots, \ell_a\} \quad (1)$$

$$\bar{\mathbf{b}}_j = \text{Bi-LSTM}(\mathbf{b}, j) \quad j \in \{1, 2, \dots, \ell_b\} \quad (2)$$

式中: $\bar{\mathbf{a}}_i$ 和 $\bar{\mathbf{b}}_j$ 分别为序列 \mathbf{a} 和 \mathbf{b} 经Bi-LSTM编码后第 i 时间步和第 j 时间步的输出; ℓ_a 和 ℓ_b 分别为序列 \mathbf{a} 和 \mathbf{b} 含有的词语数;Bi-LSTM(\cdot, \cdot)表示Bi-LSTM编码。

局部推理层中采用矩阵点积的方式计算编码序列 $\bar{\mathbf{a}}$ 和 $\bar{\mathbf{b}}$ 之间的相似度输出注意权重矩阵,并通过注意权重矩阵推算编码序列间的局部相关性:

$$\mathbf{e}_{ij} = \bar{\mathbf{a}}_i^\top \bar{\mathbf{b}}_j \quad (3)$$

$$\tilde{\mathbf{a}}_i = \sum_{j=1}^{\ell_b} \frac{\exp(\mathbf{e}_{ij})}{\sum_{k=1}^{\ell_b} \exp(\mathbf{e}_{ik})} \bar{\mathbf{b}}_j \quad i \in \{1, 2, \dots, \ell_a\} \quad (4)$$

$$\tilde{\mathbf{b}}_j = \sum_{i=1}^{\ell_a} \frac{\exp(\mathbf{e}_{ij})}{\sum_{k=1}^{\ell_a} \exp(\mathbf{e}_{kj})} \bar{\mathbf{a}}_i \quad j \in \{1, 2, \dots, \ell_b\} \quad (5)$$

式中: \mathbf{e}_{ij} 为注意权重矩阵 \mathbf{e} 的第 i 行第 j 列元素; $\tilde{\mathbf{a}}$ 和 $\tilde{\mathbf{b}}$ 分别为基于 $\bar{\mathbf{b}}$ 和 $\bar{\mathbf{a}}$ 的交互注意权重加权平均后的序列信息; $\tilde{\mathbf{a}}_i$ 和 $\tilde{\mathbf{b}}_j$ 分别为 $\tilde{\mathbf{a}}$ 和 $\tilde{\mathbf{b}}$ 的第 i 时间步和第 j 时间步的输出。随后通过学习序列间的相似性和分歧性形成局部推理信息:

$$\mathbf{m}_a = [\bar{\mathbf{a}}; \tilde{\mathbf{a}}; \bar{\mathbf{a}} - \tilde{\mathbf{a}}; \bar{\mathbf{a}} \odot \tilde{\mathbf{a}}] \quad (6)$$

$$\mathbf{m}_b = [\bar{\mathbf{b}}; \tilde{\mathbf{b}}; \bar{\mathbf{b}} - \tilde{\mathbf{b}}; \bar{\mathbf{b}} \odot \tilde{\mathbf{b}}] \quad (7)$$

式中: \odot 代表矩阵间的哈达玛积运算。在推理组合层,使用Bi-LSTM编码增强后的局部推理信息 \mathbf{m}_a 和 \mathbf{m}_b 使其具有上下文含义,经编码后输出为 \mathbf{v}_a 和 \mathbf{v}_b 。为提取所有推理信息特征,对编码向量平均池化和最大池化后拼接所得结果,如式(8)–(10)所示。

$$\mathbf{v}_{a, \text{ave}} = \sum_{i=1}^{\ell_a} \frac{\mathbf{v}_{a,i}}{\ell_a}, \quad \mathbf{v}_{a, \text{max}} = \max_{i=1, 2, \dots, \ell_a} \mathbf{v}_{a,i} \quad (8)$$

$$\mathbf{v}_{b, \text{ave}} = \sum_{i=1}^{\ell_b} \frac{\mathbf{v}_{b,i}}{\ell_b}, \quad \mathbf{v}_{b, \text{max}} = \max_{i=1, 2, \dots, \ell_b} \mathbf{v}_{b,i} \quad (9)$$

$$\mathbf{v} = [\mathbf{v}_{a, \text{ave}}; \mathbf{v}_{a, \text{max}}; \mathbf{v}_{b, \text{ave}}; \mathbf{v}_{b, \text{max}}] \quad (10)$$

式中: $\mathbf{v}_{a, \text{ave}}$ 和 $\mathbf{v}_{b, \text{ave}}$ 分别为 \mathbf{v}_a 和 \mathbf{v}_b 经平均池化后的张量; $\mathbf{v}_{a,i}$ 、 $\mathbf{v}_{b,i}$ 分别为 \mathbf{m}_a 、 \mathbf{m}_b 经Bi-LSTM编码后的第 i 个时间步输出; $\mathbf{v}_{a, \text{max}}$ 和 $\mathbf{v}_{b, \text{max}}$ 分别为 \mathbf{v}_a 和 \mathbf{v}_b 经最大池化后的张量; \mathbf{v} 为推理组合层拼接的特征合并张量。特征合并张量 \mathbf{v} 最终经过以softmax为激活函数的全连接层,输出序列间的告警特征匹配概率 m 。

采用ESIM界定信号告警特征的流程如下。

1)形成主题特征序列。对于每个主题,抽取对应主题概率最高的10个特征词,与该主题聚簇的高置信度样本中出现频数最高的10个词语去重合并为主题特征序列,该序列用于概括主题信息。

2)构建ESIM训练样本。顺序采样指定主题聚簇下的信号,与主题特征词序列构成同特征序列对;从指定主题聚簇外的信号池中随机采样20%的告警信号,分别与当前主题特征序列构成异特征序列对。以1和0的样本标签代表序列对类型。

3)参数设置和模型训练。输入编码层和推理组合层的Bi-LSTM隐含节点数均设置为100,优化器采用nadam,损失函数采用二元交叉熵。

4)模糊信号的告警特征识别。对于各模糊信号样本,依次检验由LDA模型输出的5个最大概率主题。将模糊信号和对应主题特征序列作为输入序列对,输出ESIM匹配结果。若循环检验过程中某主题匹配成功,则终止循环并输出该主题;若所有主题均匹配失败,则由人工方法识别主题。

为便于告警规则查询,根据完善后的告警信号特征映射规则及对集控中心告警规则库的告警类型、信号源、告警特征、告警性质等实体概念间的关系梳理,以Neo4j图数据库构建水电站告警知识图谱^[16],其中部分可视化结果如附录A图A4所示。

2.2 融合告警先验知识的EDA数据增强技术

深度学习模型的有效性依赖足量的训练样本,而数据增强方法可提高低资源训练环境下模型的健壮性。EDA是经典的文本数据增强技术,操作包括同义词替换和词语的随机插入、删除及交换。但由于EDA存在强随机性,这导致增强样本含误导性噪声,影响模型训练效果。鉴于此,本文提出一种融合水电告警先验知识的改进EDA方法,根据是否与告警特征存在映射关系将信号分为关键信号和非关键信号,并进行下列操作。

1)关键信号替换。该方法实现途径为:随机选取事件中的关键信号,替换为同告警特征主题的其他信号,并保留机组和线路名称等告警位置信息。

替换信号和事件关键信号数比例为 ε 。

2)非关键信号删除。从事件中随机删除非关键信号,删除信号数和事件总信号数比例为 δ_1 。

3)非关键信号插入。选择从邻近时间节点采样信号,保证插入信号与当前告警环境相适应。实现方式为:从关联信号源中,随机采样时间窗边界前后 10 s 内的非关键信号按照原信号发生时序插入事件中。插入信号数和事件总信号数比例为 δ_2 。

4)非关键信号时序交换。为避免告警特征的前后时序逻辑遭破坏,仅交换事件中非关键信号的位置,每次操作选择 2 条非关键信号交换时序位置,交换信号数和事件总信号数比例为 δ_3 。

改进 EDA 的具体操作示例见附录 A 图 A5。

相比于原 EDA 方法,改进 EDA 的优势在于:由水电告警知识引导增强样本的方式避免了随机性对关键内容的破坏,能够保留主要告警特征,因此增强样本仍满足告警规则的逻辑完备性;改进 EDA 采用信号层级的数据增强方式,扩大了增强样本和原始样本的信息差异,避免重复学习样本特征从而提高泛化性。考虑到训练数据的类间不平衡会导致模型学习具有偏向性,因此选择以样本数确定各告警事件类型的数据增强比例:

$$\alpha_i = \left(c_i \sum_{k=1}^n \frac{1}{c_k} \right)^{-1} \times 100\% \quad (11)$$

式中: α_i 为事件类型 i 的数据增强比例; c_i 为事件类型 i 的样本数量; n 为告警事件类型总数。

3 基于层级注意力的水电告警诊断模型

基于层级注意力网络的水电告警事件诊断流程如下。

1)对事件信号进行分词和去停用词。分词词表参照集控中心提供的《流域电站主要调管设备名称》,共包含 272 个水电站专业词汇。

2)采用静态词向量模型 Word2vec 将告警事件映射为 $L \times N \times M$ 阶矩阵,其中 $L=200$ 、 $N=20$ 、 $M=300$ 分别对应事件的信号数上限、信号的分词数上限和词向量维度,当信号或分词数不足上限时,填充为维度相同的 0 向量或 0 矩阵。

诊断流程图见附录 B 图 B1, Word2vec 模型参数见附录 B 表 B1。

3.1 序列编码层 Bi-SRU++ 网络结构

3.1.1 SRU++ 网络

简单循环单元(simple recurrent units, SRU)网络相比于门限循环单元(gate recurrent units, GRU)网络、LSTM 等经典循环神经网络,可避免复杂状态计算和门控机制,降低门状态对前一时间步依赖。SRU 结构见附录 B 图 B2,其计算流程如下:

$$f_t = \sigma(W_f x_t + v_f \odot c_{t-1} + b_f) \quad (12)$$

$$c_t = f_t \odot c_{t-1} + (1 - f_t) \odot (W x_t) \quad (13)$$

$$r_t = \sigma(W_r x_t + v_r \odot c_{t-1} + b_r) \quad (14)$$

$$h_t = r_t \odot c_t + (1 - r_t) \odot x_t \quad (15)$$

式中: x_t 为时间步 t 的输入; $\sigma(\cdot)$ 为 sigmoid 函数运算; W 、 W_f 和 W_r 为参数矩阵; v_f 、 v_r 和 b_f 、 b_r 分别为权重和偏置向量。因式(12)~(14)关于 $x_t \in \mathbf{R}^d$ (d 为输入向量隐状态维度)的运算部分可独立进行而不依赖彼此间信息传递,因此可并行处理以提高 SRU 运算效率,如式(16)所示。

$$U^T = [W, W_f, W_r]^T [x_1, x_2, \dots, x_g] \quad (16)$$

式中: g 为输入序列长度; U^T 为对输入进行单次并行运算的输出张量。为增强序列数据特征的分析能力,SRU++^[17] 在 SRU 基础上以自注意力^[18] 替代线性变换式(16),堆叠 SRU++ 在多项文本分析任务的表现均优于 Transformer。对给定输入 $X = [x_1, x_2, \dots, x_g]$,分别由式(17)~(19)计算查询矩阵 Q 、键矩阵 K 和值矩阵 V 。

$$Q = W^q X^T \quad (17)$$

$$K = W^k Q \quad (18)$$

$$V = W^v Q \quad (19)$$

式中: $W^q \in \mathbf{R}^{d' \times d}$ 、 $W^k \in \mathbf{R}^{d' \times d}$ 、 $W^v \in \mathbf{R}^{d' \times d}$ 分别为训练查询矩阵 Q 、键矩阵 K 和值矩阵 V 的参数矩阵, d' 为小于 d 的注意维度。为降低运算复杂度和保留 Q 中参数, K 和 V 由 Q 映射得到。根据 Q 、 K 和 V 计算自注意力值:

$$A^T = \text{softmax} \left(\frac{Q^T K}{\sqrt{d'}} \right) V^T \quad (20)$$

$$U^T = W^o \text{layernorm}(Q + \alpha A) \quad (21)$$

式中: W^o 为权重参数矩阵;layernorm(\cdot) 为层标准化操作; α 为自注意力层的调节参数, $|\alpha|$ 越大则模型分析告警文本序列长期依赖性的能力越强。

3.1.2 Bi-SRU++

SRU++ 仅能预测单向文本序列信息,而 Bi-SRU++ 可通过双向结构综合考虑前、后向文本信息,分析结果更加全面可靠。Bi-SRU++ 结构图如附录 B 图 B3 所示,其由 2 个结构对称的单向 SRU++ 构成,二者输入的文本信息相同,信息传递方向相反,各自更新内部状态并输出。时间步 t 的隐状态 h_t 由时间步 t 的正向传播隐状态 \vec{h}_t 和反向传播隐状态 \overleftarrow{h}_t 拼接形成,如式(22)所示。

$$h_t = \vec{h}_t \oplus \overleftarrow{h}_t \quad (22)$$

式中: \oplus 表示向量间的拼接操作。

3.2 基于 Bi-SRU++ 的层级注意力告警诊断模型

层级注意力网络由文献[19]提出,本文基于该模型进行改进,在词语和信号序列编码层采用 Bi-SRU++ 替换 Bi-GRU,用于提取序列特征并加速模型训练,层级注意力网络结构图如图 2 所示。

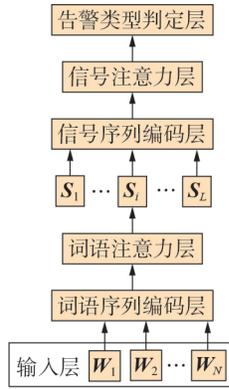


图2 基于Bi-SRU++的层级注意力网络

Fig.2 Hierarchical attention networks based on Bi-SRU++

Embedding层:将 Word2vec 训练的词向量结果作为该层初始化权重矩阵,以告警信号的分词作为单个 token,根据对应的 token-id 形成 token 的词向量。

词语序列编码层:词语序列编码层结构为 Bi-SRU++,由 Bi-SRU++分析词语间的前后依赖关系。 $w_i(t \in [1, N])$ 表示告警信号 i 的在时间步 t 的词向量,经特征学习后 Bi-SRU++输出信号中各词向量的隐状态 h_{it} 为:

$$h_{it} = \text{Bi-SRU++}(w_i) \quad t \in [1, N] \quad (23)$$

词语注意力层:考虑到告警信号中仅部分词对事件类型诊断有信息贡献,由注意力机制按照重要性差异为词语隐状态分配权重 α_{it} ,并将单条告警信号 i 所有隐状态 h_{it} 加权平均生成信号向量 s_i 。

$$u_{it} = \tanh(W_w h_{it} + b_w) \quad (24)$$

$$\alpha_{it} = \frac{\exp(u_{it}^T u_w)}{\sum_t \exp(u_{it}^T u_w)} \quad (25)$$

$$s_i = \sum_t \alpha_{it} h_{it} \quad (26)$$

式中: W_w 和 b_w 分别为 h_{it} 的权重参数矩阵和偏置向量; u_{it} 为 h_{it} 经过单层感知机的输出; u_w 为根据上下文随机初始化的词语向量。

信号序列编码层:该层结构为 Bi-SRU++,各时间步输入为信号向量 $s_i(i \in [1, L])$ 。由于事件中告警信号的时序具有隐含关联,可通过该层学习告警信号间序列关联性,输出信号编码向量 h_i :

$$h_i = \text{Bi-SRU++}(s_i) \quad i \in [1, L] \quad (27)$$

信号注意力层:告警事件是多信号的序列文本数据,而冗余信号对类型判断影响微弱,因此由信号注意力层区分不同信号的重要性。首先提取信号关键语义特征,计算信号序列编码层输出的各时间步隐状态权重,生成事件特征向量 v_E (E 表示告警事件),如式(28)–(30)所示。

$$u_i = \tanh(W_s h_i + b_s) \quad (28)$$

$$\alpha_i = \frac{\exp(u_i^T u_s)}{\sum_i \exp(u_i^T u_s)} \quad (29)$$

$$v_E = \sum_i \alpha_i h_i \quad (30)$$

式中: s 为告警信号; W_s 和 b_s 分别为 h_i 的权重参数矩阵和偏置向量; u_i 为 h_i 经过单层感知机的输出; u_s 为根据上下文随机初始化的信号向量。

告警类型判定层:归纳上游网络学习的深层特征,采用 softmax 分类器输出告警事件类型标签,如式(31)所示。

$$p = \text{softmax}(W_E v_E + b_E) \quad (31)$$

式中: W_E 和 b_E 分别为该层的权重参数矩阵和偏置向量; p 为各告警类型标签的概率,由 argmax 函数选取 p 中最大元素对应的告警类型作为诊断结果。

4 算例测试

4.1 软硬件平台配置

算例测试的集成开发环境为 Pycharm,运行硬件为 CPU i7-9750H(2.6 GHz),显卡为 RTX-2080。深度学习框架采用 1.11.1 版本的 Torch、2.2.0 版本的 Tensorflow 和 2.4.0 版本的 Keras,训练集与验证集划分按照 8:2 的比例设 5 组不同的随机切分情况,取测试结果的平均值评估诊断性能。

4.2 实验结果和分析

本文算例数据源为某水电站集控中心 2011—2020 年的约 600 万条监控告警信号,信号以数据库形式存储。从发变组、开关站、气体绝缘组合电器设备(gas insulated switchgear, GIS)告警系统和直流告警系统等相关信号源中筛选告警信号进行 LDA 聚类。对同类型或重复的历史信号进行归并,共形成信号样本数 5661 条,监控的设备涵盖发电机组、主变压器、厂输配电线路、母线、安控装置等。根据困惑度值曲线变化,确定 LDA 模型的输出主题数为 74,筛选并保留其中 33 个符合条件的主题聚簇,共产生模糊信号样本 787 条,ESIM 参数设置及测试结果见附录 C 表 C1。解析历史关联信号库后,由时间窗方法共提取出告警事件共 1970 例,根据告警子逻辑的完备性标注各事件样本的告警类型,样本分布统计情况见附录 C 表 C2。评价指标采用评价分类模型常用的准确率、召回率和 F_1 值,对于告警类型 k 的诊断评价指标为:

$$P_k = E_k / A \quad (32)$$

$$R_k = E_k / B \quad (33)$$

式中: P_k 、 R_k 分别为告警类型 k 的准确率、召回率; E_k 为诊断正确的告警类型 k 样本; A 为告警类型 k 的样本总数; B 为所有被诊断为告警类型 k 的样本总数。

告警诊断的整体评价指标 F_1 计算公式为:

$$F_1 = \frac{1}{11} \sum_{k=1}^{11} 2P_k R_k / (P_k + R_k) \quad (34)$$

以 F_1 值为优化目标,由网格搜索方法寻优序列编码层的 Bi-SRU++ 隐含节点数,节点数为 96 时模型性能最高。本文模型参数如附录 C 表 C3 所示。

为寻优改进 EDA 方法各操作的最佳控制参数值,本文以 F_1 值的提升来评价模型性能增益,分别抽取 20%、50% 和 100% 比例的原始训练样本规模进行对比,改进 EDA 增强样本规模为抽取原始数据的 2 倍。改进 EDA 控制参数改变对模型性能增益的影响如图 3 所示。由图 3 可见:当维持参数 ε 在 0.3, δ_1 、 δ_2 和 δ_3 在 0.2 左右时,各操作对模型的性能增益达到最高;且在测试范围内,改进 EDA 方法在训练数据规模越小的场景下对模型的性能增益越高。

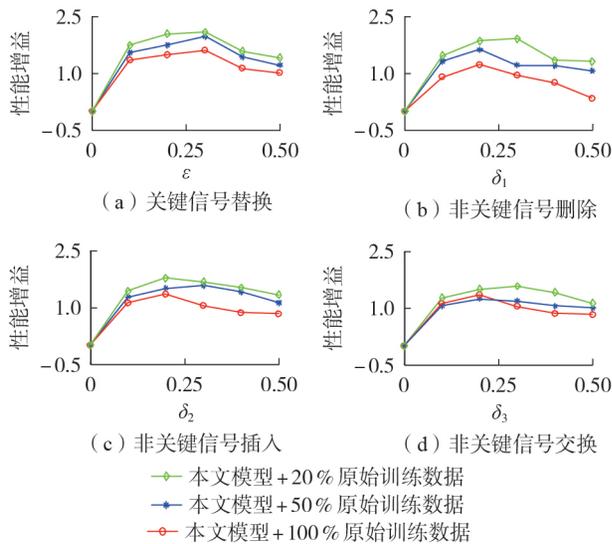


图 3 改进 EDA 控制参数改变对模型性能增益的影响

Fig.3 Influence of control parameter change of improved EDA method on model performance gain

为验证改进 EDA 方法的有效性,设置其他文本数据增强方法作为对照,测试结果见表 1。改进 EDA 方法各操作增强比例一致。对于 EDA^[10] 的同义词替换,本文采用 Python 工具包 Gensim 的 most_similar 函数返回近义词检索结果;CBERT 模型^[12] 的预训练语料为水电站过去 10 a 的历史告警信号以及操作人员记录的告警事件简报;回译法基于 Google 翻译接口,以英语、日语和西班牙语作为语言框架,选取表

表 1 本文模型在不同数据增强方法下的测试结果比较
Table 1 Comparison of test results of proposed model under different data enhancement methods

模型	准确率 / %	召回率 / %	F_1 / %
本文模型	97.31	96.41	96.86
本文模型+改进 EDA	98.21	97.27	97.74
本文模型+CBERT	97.61	96.72	97.17
本文模型+EDA	97.40	96.80	97.10
本文模型+回译法	96.52	95.98	96.30

现最优的结果作为对照。

由表 1 可见:EDA 方法略优于无数据增强场景,但由于随机性较强且无法辨识重要信息,模型性能提升有限;回译法将文本数据在不同语言框架间往复映射生成新样本,但翻译电力文本时会产生部分错误和歧义,测试效果不佳;CBERT 模型考虑了替换句间词语后对原文本的影响,但基于词替换的样本增强方式较单一,对模型泛化性提高有限;改进 EDA 方法的性能增益优于其他对照方法,相比无数据增强的识别准确率、召回率和 F_1 值分别提升了 0.90%、0.86% 和 0.88%。

以其他深度学习模型作为对照,验证本文模型的有效性。各对比模型的 Word2vec 训练词向量共享,改进 EDA 方法的数据增强比例相同,损失函数采用 Focal loss^[20] 提高对弱样本的关注。以 Early Stopping 工具监视每轮迭代的测试集损失变化,若无明显降低则终止训练。不同深度学习模型的测试集损失值变化曲线如图 4 所示。由图可见:本文模型与 HAN 模型收敛特性相近,迭代到六七轮时收敛。

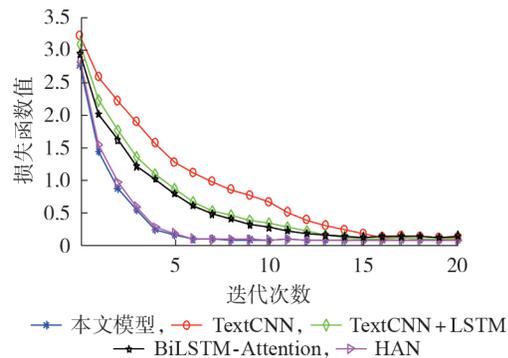


图 4 不同深度学习模型的测试集损失值变化曲线

Fig.4 Change curves of testset loss values of different deep learning models

为检验本文模型的有效性,设置了不同的深度学习模型作为对比,结果如表 2 所示。由于 TextCNN 和 TextCNN+LSTM 模型通常用于分析单序列的文本信息,文献[5]和文献[6]仅用该类模型解析信号序列级别的信息,在文本矢量化过程中采用平均词向量生成信号向量的特征糅合方式,虽然提高了模型训练效率,但造成大量词信息损失,导致在复杂的告警场景下表现不佳。考虑到水电站事故发生时,告警误判将造成严重经济损失和运行风险,因此该类低精度的基准模型不再适用。HAN 模型由层级结构解析词、信号粒度信息并由注意力机制筛选重要特征,虽相比于上述模型准确率有大幅提高,但训练时间成本也显著增加。本文将单层 Bi-SRU++ 替换 HAN 的 Bi-GRU 结构,同样可维持 HAN 的高精度,并将训练时间缩减为原模型的 37.5%,单例事件的平

均测试时间约为0.06 s,诊断时间远低于人工识别所需的平均用时3.2 s,大幅提升了水电告警系统的判断效率。

表2 不同深度学习模型的实验结果对比

Table 2 Comparison of experimental results among different deep learning models

模型	准确率 / %	训练时间 / s	测试时间 / s
本文模型	98.21	121.45	21.44
TextCNN	89.86	65.24	8.70
TextCNN+LSTM	91.22	134.76	15.44
Bi-LSTM+Attention	92.47	128.94	14.05
HAN	98.11	404.60	53.32

4.3 工程应用

为和工程实际接轨,以2020年6月17日发生于该水电站的“直流双极闭锁严重事故”不安全事件快报为验证对象。快报显示事故持续时间为当天13:38—14:30,从该时段集控中心接收的12 556条告警信号中共生成15例告警事件,模型诊断结果经检验全部正确,共用时1.06 s。2例典型事件的注意力热图如附录C图C1,事件中不同信号和词语的注意力权重由模型的信号及词注意力层输出,根据结果显示,本文模型可区分告警文本信息的重要性。

5 结论

本文针对水电站告警推理规则复杂,样本规模有限且类间数量不平衡等诊断难点,提出了一种结合数据增强和深度学习的水电告警诊断方法:

1)基于LDA-ESIM构建了水电告警信号至告警特征的映射机制,提出一种分步处置的告警特征匹配方法,优化了集控中心告警规则库的特征检索逻辑,为水电告警诊断提供规则支撑;

2)提出一种融合水电告警先验知识的改进EDA方法,以4种信号层级数据增强操作为深度学习提供训练规模支撑,方法易于实现且具备可解释性,提升了低训练资源时诊断模型的泛化性能;

3)将HAN模型应用于水电站告警事件诊断任务中,并基于HAN模型改进,将编码文本序列的Bi-GRU结构替换为Bi-SRU++,维持高诊断精度的前提下,大幅提升模型训练和测试效率。

本文为水电告警事件诊断提供了一种高效率高精度的智能告警诊断模型。下一步研究工作是将事件分级处置、关联告警设备定位等作为研究内容,探索集告警类型诊断,告警严重度分级和告警处置预案生成为一体的多任务学习方法。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

[1] 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.

[2] 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.

[3] 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):644-651.

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): 644-651.

[4] 冯斌,张又文,唐昕,等. 基于BiLSTM-Attention神经网络的电力设备缺陷文本挖掘[J]. 中国电机工程学报,2020,40(增刊1):1-10.

FENG Bin, ZHANG Youwen, TANG Xin, et al. Power equipment defect record text mining based on BiLSTM-Attention neural network[J]. Proceedings of the CSEE, 2020, 40(Supplement 1): 1-10.

[5] BAI Ziyu, SUN Guoqiang, ZANG Haixiang, et al. Identification technology of grid monitoring alarm event based on natural language processing and deep learning in China[J]. Energies, 2019, 12(17): 1-19.

[6] 孙国强,沈培锋,赵扬,等. 融合知识库和深度学习的电网监控告警事件智能识别[J]. 电力自动化设备,2020,40(4):40-47.

SUN Guoqiang, SHEN Peifeng, ZHAO Yang, et al. Intelligent recognition of power grid monitoring alarm event combining knowledge base and deep learning[J]. Electric Power Automation Equipment, 2020, 40(4): 40-47.

[7] 卫志农,石东明,张明,等. 考虑样本类别不平衡的电网故障事件智能识别方法[J]. 电力自动化设备,2021,41(11):93-99.

WEI Zhinong, SHI Dongming, ZHANG Ming, et al. Intelligent identification method of power grid fault events considering sample classification imbalance[J]. Electric Power Automation Equipment, 2021, 41(11): 93-99.

[8] 晏鹏,黄晓旭,黄玉辉,等. 基于BERT-DSA-CNN和知识库的电网调控在线告警识别[J]. 电力系统保护与控制,2022,50(4):129-136.

YAN Peng, HUANG Xiaoxu, HUANG Yuhui, et al. Online alarm recognition of power grid dispatching based on BERT-DSA-CNN and a knowledge base[J]. Power System Protection and Control, 2022, 50(4): 129-136.

[9] YU Lantao, ZHANG Weinan, WANG Jun, et al. SeqGAN: sequence generative adversarial nets with policy gradient[C]//Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence. San Francisco, California, USA: ACM, 2017: 2852-2858.

[10] WEI J, ZOU Kai. EDA: easy data augmentation techniques for boosting performance on text classification tasks[C]//2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). Hong Kong, China: Association for Computational Linguistics, 2019: 6382-6388.

[11] LUQUE F M. Atalaya at TASS 2019: data augmentation and robust embeddings for sentiment analysis [EB/OL]. (2019-09-25)[2022-06-15]. <https://arxiv.org/abs/1909.11241>.

- [12] WU Xing, LÜ Shangwen, ZANG Liangjun, et al. Conditional BERT contextual augmentation[EB/OL]. (2018-12-17)[2022-06-15]. <https://arxiv.org/abs/1812.06705>.
- [13] KUMAR V, CHOUDHARY A, CHO E. Data augmentation using pre-trained transformer models[EB/OL]. (2020-03-04)[2022-06-15]. <https://arxiv.org/abs/2003.02245>.
- [14] CHEN Qian, ZHU Xiaodan, LING Zhenhua, et al. Enhanced LSTM for natural language inference[C]//Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA, USA: Association for Computational Linguistics, 2017: 1657-1668.
- [15] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality[J]. Advances in Neural Information Processing Systems, 2013, 26(5): 3111-3119.
- [16] 郭榕, 杨群, 刘绍翰, 等. 电网故障处置知识图谱构建研究与应用[J]. 电网技术, 2021, 45(6): 2092-2100.
GUO Rong, YANG Qun, LIU Shaohan, et al. Construction and application of power grid fault handling knowledge graph[J]. Power System Technology, 2021, 45(6): 2092-2100.
- [17] TAO Lei. When attention meets fast recurrence: training language models with reduced compute[C]//Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. Stroudsburg, PA, USA: Association for Computational Linguistics, 2021: 7633-7648.
- [18] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: MIT Press, 2017: 6000-6010.
- [19] YANG Z C, YANG D Y, DYER C, et al. Hierarchical attention networks for document classification[C]//Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Stroudsburg, PA, USA: Association for Computational Linguistics, 2016: 12-17.
- [20] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318-327.

作者简介:



孙国强

孙国强(1978—),男,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(E-mail: hhusunguoqiang@163.com);

章逸舟(1998—),男,硕士研究生,主要研究方向为基于人工智能的电力告警文本分析(E-mail: 3220138144@qq.com)。

(编辑 任思思)

Diagnosis method of hydropower alarm events based on data augmentation and deep learning

SUN Guoqiang¹, ZHANG Yizhou¹, TANG Jieyang², TANG Fan², WEI Zhinong¹,
ZANG Haixiang¹, YANG Dong²

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China;

2. Yalong River Hydropower Development Co., Ltd., Chengdu 610051, China)

Abstract: Aiming at the shortcomings of traditional diagnosis methods of hydropower alarm events, such as low efficiency and low accuracy, a data augmentation method combining prior knowledge and a hierarchical attention deep learning framework based on bidirectional simple recurrent units++ (Bi-SRU++) are designed. Aiming at the problem of imperfect hydropower alarm rules, the latent Dirichlet allocation-enhanced sequential inference model (LDA-ESIM) is used to construct the mapping mechanism between warning signals and warning features. Then, combined with the prior knowledge of hydropower alarm rules, an improved LDA method is proposed to augment the sample data. The hierarchical attention model learns the sample features and outputs the diagnosis results. The test example is actual alarm data of a hydropower centralized control center. The test results show that the proposed method can realize rapid diagnosis of hydropower alarm events with high accuracy in low resource training environment.

Key words: hydropower station alarm events; text data augmentation; attention mechanism; deep learning; prior knowledge

附录 A

励磁系统故障跳闸

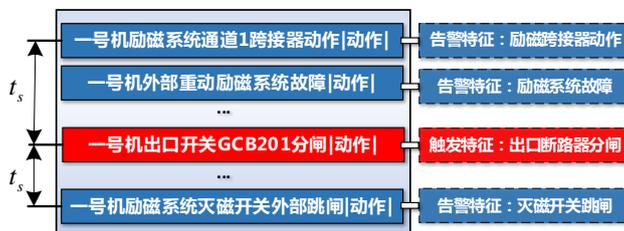


图 A1 典型水电监警告警事件示例

Fig.A1 Example of typical hydropower monitoring alarm event

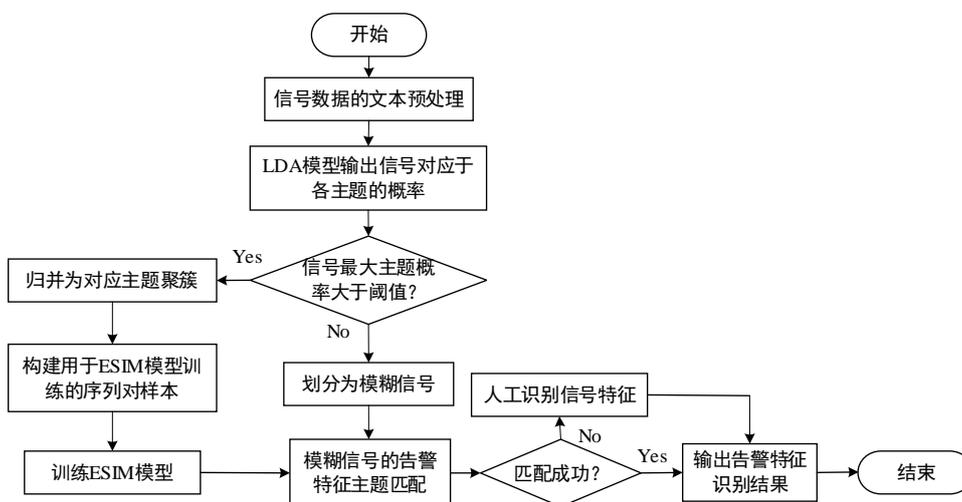


图 A2 基于 LDA-ESIM 的信号特征映射规则构建流程

Fig.A2 Flowchart of constructing mapping rules between signal and features based on LDA-ESIM

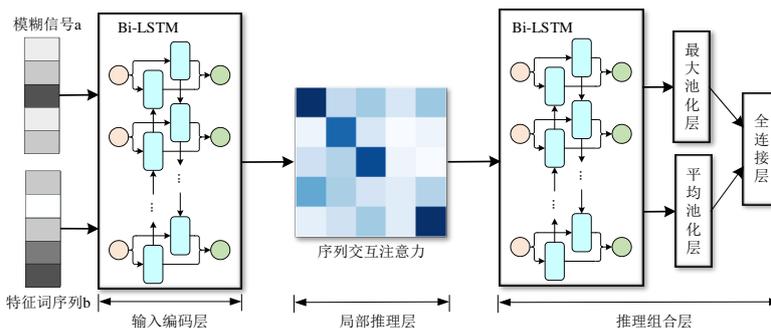


图 A3 ESIM 网络结构

Fig.A3 Network structure of ESIM

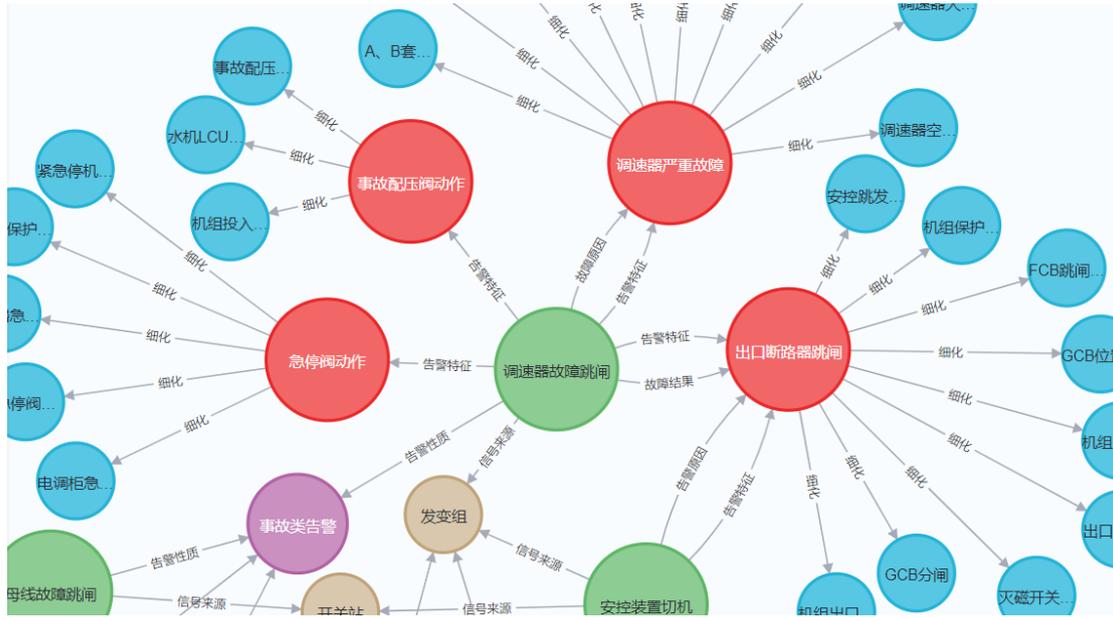


图 A4 基于告警实体间关系的水电告警知识图谱

Fig.A4 Knowledge map of hydropower alarm based on relationship between alarm entities

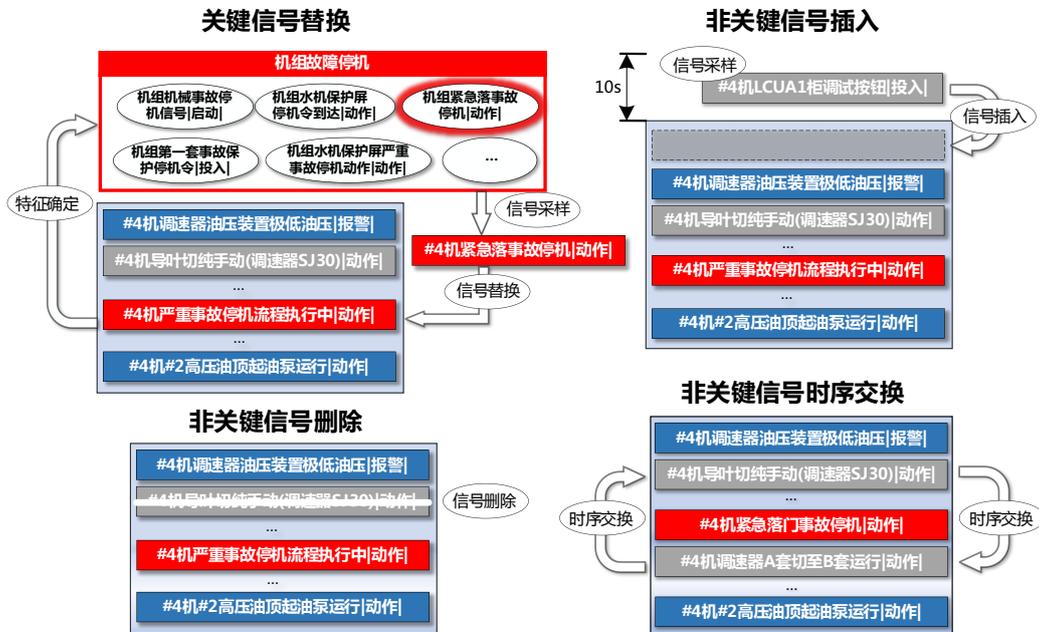


图 A5 改进 EDA 方法的 4 种数据增强方式

Fig.A5 Four data augmentation methods of improved EDA

附录 B

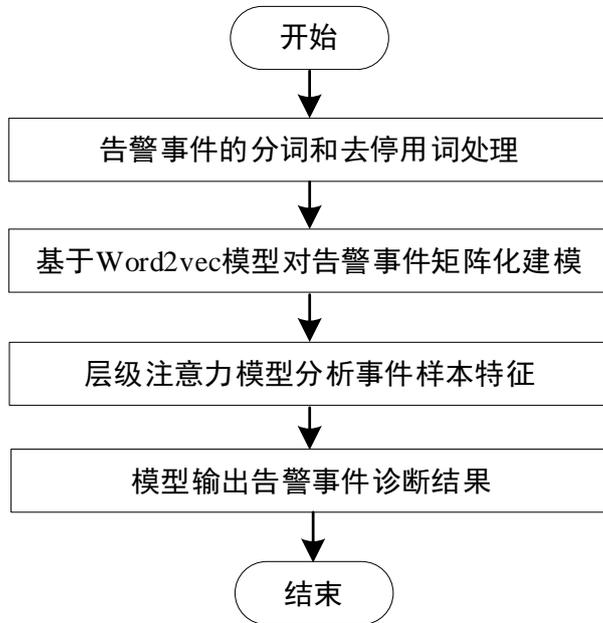


图 B1 水电告警事件识别流程图

Fig.B1 Flowchart of hydropower alarm event identification

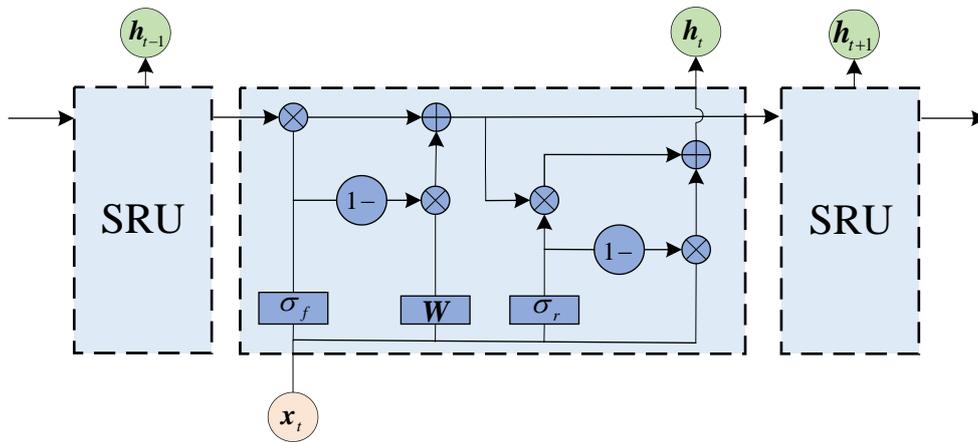


图 B2 SRU 网络结构示意图

Fig.B2 Schematic diagram of structure of SRU network

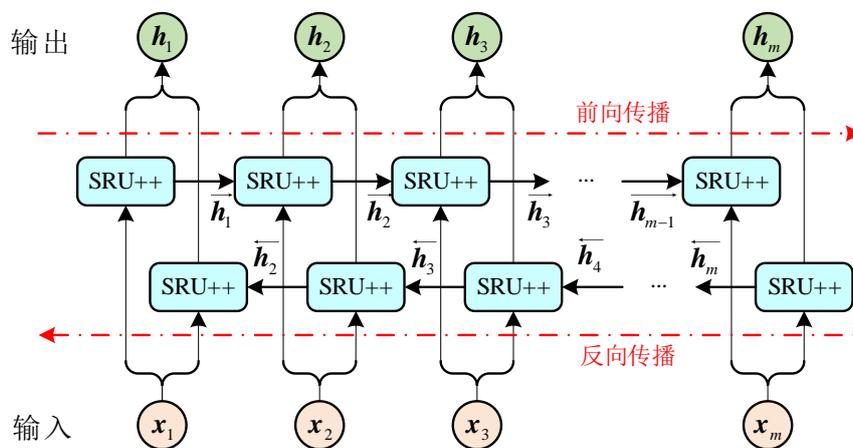


图 B3 Bi-SRU++网络结构示意图

Fig.B3 Schematic diagram of structure of Bi-SRU++ network

表 B1 Word2vec 模型参数

Table B1 Parameters of Word2vec model

模型参数	参数值	参数含义
训练算法	0	CBOW 算法
窗口大小	5	中心词与预测词同一信号中的最大距离
最小词频	5	出现词频少于次数的词语会被舍弃
训练加速策略	1	hierarchical softmax
词向量维度	300	每个词的向量维度

附录 C



图 C1 典型事件样本的注意力热图

Fig.C1 Attention heat map of typical event samples

表 C1 ESIM 参数设置及测试结果

Table C1 Parameter setting and test results of ESIM

参数名称	参数值	参数名称	参数值
学习率	0.001	训练集样本数	3384
优化函数	nadam	验证集样本数	340
最大迭代次数	10	验证集识别准确率	94.33%
单次训练样本数	256	匹配成功信号数	654
编码层隐含节点数	100	匹配失败信号数	133

表 C2 告警事件样本数量统计

Table C2 Statistics of alarm event sample quantity

序号	告警事件类型	样本数量
1	主变压器温度过高停机	265
2	发电机组转速过快停机	556
3	剪断销剪断停机	105
4	发电机组低油压停机	84
5	主轴密封水流量过低停机	93
6	励磁系统故障跳闸	172
7	发电机组保护动作跳闸	132
8	输配电线路故障跳闸	340
9	调速器故障跳闸	106
10	安控装置切机跳闸	66
11	母线故障跳闸	51
告警事件数量总和		1970

表 C3 本文模型参数设置

Table C3 Parameter setting of proposed model

参数名称	参数值	参数名称	参数值
Bi-SRU++隐含层数量	1	学习率	0.001
Bi-SRU++隐含层节点数	96	优化函数	rmsprop
全连接层激活函数	softmax	最大迭代次数	20
全连接层输出维度	11	单次训练样本数	256
损失函数	focal loss	早停机制评估指标	testset loss