



开放科学
(资源服务)
标识码
(OSID)

基于预训练语言模型的电网检修计划异常检测

吴海洋¹ 吴子辰² 吴博科³ 高华² 王莘然² 胡伟⁴

1. 国网江苏省电力有限公司 南京 210000;
2. 国网江苏省电力有限公司信息通信分公司 南京 210000;
3. 国网常州供电公司 常州 213003;
4. 南京大学计算机软件新技术全国重点实验室 南京 210023

摘要: [目的/意义] 电网检修计划异常检测技术可以发现电网检修计划内存在的异常,对于电网通信系统检修活动的正常开展和电力通信系统的稳定运行至关重要。目前,电网检修计划异常检测主要依靠人工判别的方式寻找检修计划的异常,存在准确率低与效率低下的问题。[方法/过程] 提供了一种基于预训练语言模型的电网检修计划异常检测方法,使用电网的检修计划数据对预训练语言模型进行微调,使得预训练语言模型能够获取相关领域的专业知识,同时充分利用预训练语言模型的上下文感知能力和领域通用性,使预训练语言模型能够深入理解检修计划的复杂语境,从而发现检修计划中存在的异常。[结果/结论] 实验证明,相较于传统方法,该异常检测方法能够有效优化电网检修计划异常检测的性能。

关键词: 预训练语言模型; 异常检测; 电网管理; 文本分类

中图分类号: G35; TP391

A Pre-trained Language Model-based Anomaly Detection Method for Grid Maintenance Plans

WU Haiyang¹ WU Zichen² WU Boke³ GAO Hua² WANG Shenran² HU Wei⁴

1. State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210000, China;
2. State Grid Jiangsu Electric Power Co., Ltd. Information & Telecommunication Branch, Nanjing 210000, China;
3. State Grid Changzhou Power Supply Company, Changzhou 213003, China;
4. State Key Laboratory for Novel Software Technology (Nanjing University), Nanjing 210023, China

Abstract: [Objective/Significance] Anomaly detection methods are designed to detect anomalies in grid maintenance plans, which are crucial for the normal implementation of grid maintenance and the stable operation of the grid system. Existing

基金项目 江苏省电力有限公司项目“基于数字孪生与自然语言处理的电力通信检修辅助决策关键技术研究”(J2023108)。

作者简介 吴海洋(1983-), 博士, 高级工程师, 主要研究方向为电力通信、人工智能、信号处理; 吴子辰(1988-), 硕士, 高级工程师, 主要研究方向为电力通信运行与管理; 吴博科(1983-), 硕士, 高级工程师, 主要研究方向为电力通信运行与管理; 高华(1996-), 硕士, 主要研究方向为电力通信运行技术, E-mail: hua.gao@foxmail.com; 王莘然(1999-), 硕士, 主要研究方向为电力通信运行技术。

引用格式 吴海洋, 吴子辰, 吴博科, 等. 基于预训练语言模型的电网检修计划异常检测[J]. 情报工程, 2024, 10(4): 14-24.

methods primarily rely on manual discernment, leading to issues of low accuracy and inefficiency. [Methods/Processes] This paper presents an anomaly detection method for grid maintenance plans based on pre-trained language models (PLMs). The method uses grid maintenance plan data to fine-tune the PLMs, so that the PLMs can obtain professional knowledge in related fields, while fully leveraging the contextual awareness and domain adaptability of PLMs. The combination of the two aspects enables the PLMs can deeply understand the complex context of the maintenance plans and detect anomalies in them. [Results/Conclusions] Experimental results demonstrate that the proposed method effectively enhances the performance of anomaly detection in grid maintenance plans.

Keywords: Pre-trained Language Model; Anomaly Detection; Grid Management; Text Classification

引言

在电网通信领域，定期检修电网线路对于保障电网系统的正常运行至关重要。每次线路检修都需要制定详细的检修计划，以确保检修过程能够尽快将电网系统恢复到正常的运行状态。

电网通信系统通常涉及复杂的网络结构和庞大的设备数量，而检修计划通常由不同的部门独立制定并上报进行审批，这使得多个检修计划之间可能存在冲突，即电网检修计划的异常。异常的存在会导致维修效率降低，给电网的可靠性带来威胁。目前，电网检修计划异常检测主要依赖工作人员对申报的检修计划进行审批与排布，以确保检修计划的可行性，优化维修效率。由于检修计划数量大、异常特征不明显，人工检测存在异常识别率低与效率低下的问题。如何高效地识别电网检修计划中的异常，成为当前电网研究中的一个紧迫问题。

本文基于大量的电网检修计划数据，对检修计划中常见的异常进行分析，基于文献[1]并结合对相应检修计划数据的观察，总结出3种检修计划中常见的异常（如表1所示），并对应地提出了3种检修计划异常检测任务。本文将这3种任务建模为自然语言处理任务中的文本分类任务，并设计了一种基于预训练语言模型的电网检修计划异常检测方法，该方法利用预训练语言模型在预训练阶段所获得的通用知识和强大的上下文感知能力，在全面考虑检修计划语义信息的基础上准确识别检修计划的异常。本文对所提出的方法进行了实验验证，并对实验结果进行了详细的分析。实验证明，相较于传统方法，本文提出的电网检修计划异常检测方法在准确性和鲁棒性上都取得了显著的提升，具备较强的泛化能力和实际应用潜力，有望为电网通信领域的检修计划异常检测提供有力支持，为电网智能化发展做出贡献。

表1 常见的检修计划异常

异常类型	检修计划实例	异常说明
检修步骤与检修目标无关	某光缆割接至临时过渡光缆运行：（1）拆除原48#塔；（2）在31#塔处断开原光缆；（3）沿38#杆至31#塔布放临时光缆；（4）将临时光缆与原光缆进行熔接。	检修步骤（1）与检修目标无关
检修步骤顺序错乱	某光缆段改造：（1）开断原光缆；（2）布放新光缆；（3）拆除原光缆；（4）熔接新光缆。	检修步骤（2）和（3）顺序错乱
检修计划间存在冲突	【检修计划1】某光缆中断检修：…（2）从13#电力井至39#电力井断开原光缆；… 【检修计划2】某光缆段迁移至新管道：…（3）从13#电力井至39#电力井拆除原光缆；…	检修与改造无法同时开展，两个检修计划存在冲突

1 相关工作

1.1 文本分类任务

文本分类是自然语言处理（NLP）领域中的一个重要任务，旨在将文本分配到预定义类别或者标签内。传统方法采用朴素贝叶斯^[2]、支持向量机（SVM）^[3]、决策树^[4]等传统机器学习算法进行分类。基于深度学习的神经网络模型包括卷积神经网络（CNN）^[5]、循环神经网络（RNN）^[6]以及更加先进的长短期记忆网络（LSTM）^[7]和门控循环单元（GRU）^[8]等。这些方法难以捕捉全局依赖关系，对上下文理解不足，面对电网检修计划这类长文本时表现不佳。

由于存在异常的检修计划样本量少，电网检修计划异常检测问题是一个非平衡的文本分类任务。为解决非平衡分类问题，传统的机器学习领域通常采用过采样少数类别的样本^[9]、集成多个分类器的预测结果^[10]等技术来提高非平衡分类模型的性能。而在深度神经网络领域，则通过生成对抗网络（GAN）^[11]生成合成的样本、迁移学习^[12]以及优化损失函数^[13]等技术进一步提升模型的性能。本文提出的基于预训练语言模型的电网检修计划异常检测方法，将预训练模型蕴含的语义知识迁移到电网领域的检测任务上，有效提高了模型在非平衡数据集上的性能。

1.2 异常检测任务

电网检修领域的冲突检测目前以人工处理为主。有学者^[14-15]提出构建专家系统与知

识库实现检修计划的智能分析，但是需要经验丰富的专家手动完成，构建的知识库规模也较小。随着自然语言处理技术的发展，一些工作依靠领域专家进行冲突规则模板的预设^[16-18]，然后通过判断输入的检修计划文本是否匹配规则进行冲突检测。此类方法人工维护成本高，规则需要根据需求不断调整。由于深度学习的发展，BERT等预训练语言模型被用于电网通信系统的命名实体识别^[19]，自动化抽取检修计划中的关键信息，降低人工维护的成本，但是将预训练模型进一步应用到难度更大的异常检测任务中，则面临领域内的训练语料不足、模型性能不好等挑战。本文提出的电网检修计划异常检测方法可以高效识别电网检修计划的潜在冲突，推动电网智能化发展。

1.3 预训练语言模型

预训练语言模型基于Transformer^[20]等架构在大规模的无标注语料库上进行自监督学习，使得模型能够学到通用的语言表示，捕获语法、语义和世界知识。代表性的模型包括BERT^[21]和LLaMA^[22]。BERT能够深入理解文本中的上下文信息，面对检修计划这种存在大量专业术语和复杂技术性描述的文本，能够更好地处理这种语境敏感性，提高异常检测的准确性。LLaMA是文本生成的语言模型，可以对输入的问题进行理解和生成回答。

关于预训练语言模型在专业领域中的应用，现有工作涉及电网设备缺陷文本分类^[23]、商品属性抽取^[24]、案件要素识别^[25]等包含大量专有

名词的领域。这些工作表明，通过使用专业领域数据对预训练语言模型进行微调，预训练语言模型能充分理解专业领域的知识，提升模型在专业领域任务上的性能。本文同样借助检修计划语料对 BERT 和 LLaMA 进行微调，使其能根据获取的检修计划知识，结合自身的上下文感知能力和领域通用性，更加深入理解检修计划的复杂语境，从而发现检修计划中存在的异常。

2 任务定义

2.1 检修计划

检修计划的结构与实例如图 1 所示，一个检修计划包含一个检修目标和若干有序的检修步骤。本文将检修计划 P 定义为 $P=(g, s_1, s_2, \dots, s_N)$ ，其中 g 表示检修计划的目标， $s_i(i \in \{1, 2, \dots, N\})$ 表示计划的第 i 个步骤， N 表示该检修计划所包含的检修步骤的数量。检修目标和检修步骤是自然语言构成的文本序列。

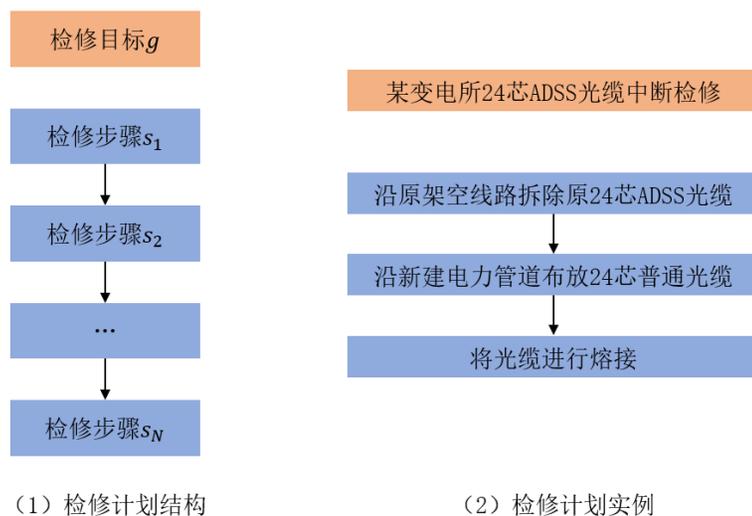


图 1 检修计划结构与实例

2.2 电网检修计划异常

根据研究者提到的步骤推理、顺序推理等任务^[1]，以及结合对检修计划数据的观察，本文总结了 3 种常见的检修计划异常，分别是：

(1) 检修步骤是否与检修目标相关；(2) 检修步骤的顺序是否存在错误；(3) 两个检修计划是否可同时开展。考虑到这 3 种异常相互独立，本文提出分别针对 3 种异常的检测任务，并将每个异常的检测任务建模为自然语言处理任务中的文本分类任务来进行后续的处理。具体如下：

检修步骤相关性检测：第一种常见的检修计划异常是检修步骤中包含与当前检修目标不相关的检修步骤，不相关的检修步骤会对检修计划的开展产生未知的影响。针对这种异常，本文设计了检修步骤相关性检测任务。该任务给定检修目标 g 与检修步骤 s_i ，目标是判断 g 与 s_i 是否属于同一个检修计划。

检修步骤顺序性检测：第二种常见的检修计划异常是检修步骤之间顺序错乱。检修步骤之间通常具有先后顺序，按序执行才可确保检修计划的正常实施。针对这种异常，本文设计

了检修步骤顺序性检测任务。该任务给定检修计划 P 的检修目标 g 以及两个检修步骤 s_i 、 s_j ，目标是判断 s_i 和 s_j 执行的先后顺序。值得注意的是，检修目标 g 对于判断检修步骤之间的先后顺序是必须的，因为不同的检修计划对于同样两个检修步骤的顺序要求可能不同。

检修计划冲突检测：与前两种检修计划异常不同，第三种常见的检修计划异常发生在两个检修计划之间。不同的检修计划可能涉及同一线路同一时间的不同操作，这些操作之间是互斥的。即使两个检修计划都是准确无误的，检修计划也有可能无法正常开展。针对这种异

常，本文设计了检修计划冲突检测任务，该任务给定两个检修计划 P_1 和 P_2 ，目标是判断两个检修计划是否可以同时开展。

3 电网检修计划异常检测方法

本文设计了基于 BERT 的异常检测模型 GAD(Grid Anomaly Detection)-BERT 以及基于 LLaMA 的异常检测模型 GAD-LLaMA，如图 2 所示。其中，GAD-BERT 整体采用编码器与分类器的结构；GAD-LLaMA 对 LLaMA 进行指令微调。本节将分别介绍提出的两个检修计划异常检测模型。



图 2 检修计划异常检测模型框架图

3.1 基于BERT的电网检修计划异常检测方法

GAD-BERT 主要包含编码器与分类器两个模块，编码器通过 BERT 编码输入文本并获取向量表示。分类器是一个多层感知机，用于计算异常存在与否的概率。三种任务输入不同，编码器的设计也略有不同。本节首先介绍 GAD-BERT 进行电网异常检测的通用流程，之后分别介绍三种任务不同的编码方式。值得注意的是，三种任务对应的异常检测模型不共享

任何参数，彼此独立。

GAD-BERT 采用 BERT 作为基础的编码器，给定一段输入文本 T ，通过分词得到序列 $x=[[-CLS], t_1, t_2, \dots, t_n, [SEP]]$ ，其中 $t_i(i \in \{1, 2, \dots, n\})$ 表示构成 T 的第 i 个词语， t_i 是预定义在 BERT 词表中的词语， $[CLS]$ 和 $[SEP]$ 是 BERT 预训练时使用的特殊词语，分别用于表示输入序列的开始和结束，这两个特殊词语并不包含在输入文本 T 中。

将序列 x 输入到 BERT 中，可以获取序列中每个词语对应的向量表示：

$$[e_{[\text{CLS}]}, e_1, e_2, \dots, e_n, e_{[\text{SEP}]}] = \text{BERT}(x) \quad (1)$$

其中， $e_{[\text{CLS}]} \in R^d$ 是特殊词语 [CLS] 对应的向量表示，其中 d 是 BERT 输出的向量表示的维数。将 $e_{[\text{CLS}]}$ 视为输入文本 T 的向量表示 e_T ，输入到分类器中完成分类：

$$p = \text{Softmax}(W_2 \text{ReLU}(W_1 e_T + b_1)) + b_2 \quad (2)$$

其中， $p \in R^2$ 是输出的概率向量， $p[0]$ 表示输入的检修计划存在异常的概率， $p[1]$ 表示不存在异常的概率，Softmax 函数保证了 $p[0] + p[1] = 1$ 。本文所使用的分类器是由两个全连接层构成的感知机，其中 $W_1 \in R^{d_1 \times d}$ ， $W_2 \in R^{2 \times d_1}$ ， $b_1 \in R^{d_1}$ ， $b_2 \in R^2$ 是多层感知机的参数， d_1 是一个超参数，表示感知机中间表示的维数，ReLU 是感知机采用的非线性激活函数。

在获得预测概率后，通过交叉熵函数计算分类损失 L ：

$$L = \text{CE}(p, l) \quad (3)$$

其中，CE 表示交叉熵损失函数， l 是输入文本 T 的标记信息， $l = [1, 0]$ 表示 T 中存在异常， $l = [0, 1]$ 表示 T 中不存在异常。基于分类损失，通过梯度反向传播算法计算模型参数的梯度，对模型进行优化。

3.1.1 检修计划相关性检测编码器

检修计划相关性检测任务的输入是检修目标 g 与检修步骤 s_i ，对 g 和 s_i 同时进行分词，得到序列：

$$x_r = [[\text{CLS}], t_1, t_2, \dots, t_n, [\text{SEP}], t_{n+1}, t_{n+2}, \dots, t_{n+m}, [\text{SEP}]] \quad (4)$$

其中 x_r 表示经过分词处理后的序列， t_1, t_2, \dots, t_n 和 $t_{n+1}, t_{n+2}, \dots, t_{n+m}$ 分别是检修目标 g 与检

修步骤 s_i 对应的分词结果。

将序列 x_r 输入到 BERT 中，获取序列中每个元素对应的向量表示：

$$[e_{[\text{CLS}]}, e_1, e_2, \dots, e_n, e_{[\text{SEP}]}, e_{n+1}, e_{n+2}, \dots, e_{n+m}, e_{[\text{SEP}]}] = \text{BERT}(x_r) \quad (5)$$

选择 $e_{[\text{CLS}]} \in R^d$ 作为检修目标 g 与检修步骤 s_i 统一的向量表示，记作 e_r 。

将 e_r 输入到检修计划相关性检测模型的分类器中，得到预测的概率 p_r 。 p_r 与标记信息 l_r 通过交叉熵损失函数计算得到检修计划相关性检测的损失 L_r 。

3.1.2 检修计划顺序性检测编码器

检修计划顺序性检测任务的输入是检修目标 g 以及检修步骤 s_i, s_j ，对这三部分文本分别进行分词，得到对应的序列：

$$x_g = [[\text{CLS}], t_1^g, t_2^g, \dots, t_{n_1}^g, [\text{SEP}]] \quad (6)$$

$$x_{s_i} = [[\text{CLS}], t_1^{s_i}, t_2^{s_i}, \dots, t_{n_2}^{s_i}, [\text{SEP}]] \quad (7)$$

$$x_{s_j} = [[\text{CLS}], t_1^{s_j}, t_2^{s_j}, \dots, t_{n_3}^{s_j}, [\text{SEP}]] \quad (8)$$

其中， x_g, x_{s_i} 和 x_{s_j} 分别表示 g, s_i 和 s_j 分词后的结果， n_1, n_2 和 n_3 分别是 g, s_i 和 s_j 分词后的词语数量。使用 BERT 对 x_g, x_{s_i} 和 x_{s_j} 分别进行编码，并选择 [CLS] 对应的向量作为检修目标 g 和检修步骤 s_i, s_j 的语义表示，记作 e_g, e_{s_i} 和 e_{s_j} 。

将 e_g, e_{s_i} 和 e_{s_j} 拼接后作为编码器的输出 $e_s \in R^{3d}$ 。将其输入到分类器中，得到预测的概率 p_s 。 p_s 与标记信息 l_s 通过交叉熵损失函数计算得到检修计划顺序性检测的损失 L_s 。

3.1.3 检修计划冲突检测编码器

检修计划冲突检测任务的输入是两个检修计划 $P_1 = (g_1, (s_1^1, s_2^1, \dots, s_{N_1}^1))$ 和

$P_2 = (g_2, (s_1^2, s_2^2, \dots, s_{N_2}^2))$ ，其中 N_1 和 N_2 分别是 P_1 和 P_2 所包含的检修步骤的数量。本文首先利用 BERT 对两个检修计划的检修目标和检修步骤分别编码，同样选择 [CLS] 对应的向量作为文本整体的向量表示，记作 $[e_g^1, e_{s_1}^1, e_{s_2}^1, \dots, e_{s_{N_1}}^1]$ 和 $[e_g^2, e_{s_1}^2, e_{s_2}^2, \dots, e_{s_{N_2}}^2]$ 。之后引入 LSTM 网络进一步进行编码：

$$[\hat{e}_g^2, \hat{e}_{s_1}^2, \hat{e}_{s_2}^2, \dots, \hat{e}_{s_{N_2}}^2] = \text{LSTM}([e_g^2, e_{s_1}^2, e_{s_2}^2, \dots, e_{s_{N_2}}^2]) \quad (9)$$

$$[\hat{e}_g^1, \hat{e}_{s_1}^1, \hat{e}_{s_2}^1, \dots, \hat{e}_{s_{N_1}}^1] = \text{LSTM}([e_g^1, e_{s_1}^1, e_{s_2}^1, \dots, e_{s_{N_1}}^1]) \quad (10)$$

利用 LSTM 网络的长距离依赖特性，保证每一部分的语义信息可以传达到其他部分。最后，对 LSTM 网络更新后的表示进行平均池化的操作，得到整个检修计划的向量表示：

$$e_{P_1} = \text{Pooling}([\hat{e}_g^1, \hat{e}_{s_1}^1, \hat{e}_{s_2}^1, \dots, \hat{e}_{s_{N_1}}^1]) \quad (11)$$

$$e_{P_2} = \text{Pooling}([\hat{e}_g^2, \hat{e}_{s_1}^2, \hat{e}_{s_2}^2, \dots, \hat{e}_{s_{N_2}}^2]) \quad (12)$$

其中， $e_{P_1} \in R^d$ 和 $e_{P_2} \in R^d$ 分别是检修计划 P_1 和 P_2 的向量表示，Pooling 表示平均池化操作。

将 e_{P_1} 和 e_{P_2} 拼接后输入到分类器中获取两个检修计划之间是否存在冲突的概率 p_c 。 p_c 与标记信息 l_c 通过交叉熵损失函数计算得到检修计划冲突检测的损失 L_c 。

3.2 基于LLaMA的检修计划异常检测方法

GAD-LLaMA 使用电网检修计划对 LLaMA 进行指令微调，实现对异常的识别。本文针对三种异常检测任务设计不同的提示 (prompt)，并使用 LoRA^[26] 实现参数高效的微调^[27]。表 2 是本文针对三种检修计划异常检测任务设计的提示模板，针对具体的检修计划，只需将其对应的文本内容填充到提示模板中。

表 2 GAD-LLaMA 的提示模板

异常检测任务	输入	提示模板
检修计划相关性检测	检修目标 g 检修步骤 s_i	给定检修目标和检修步骤，判断二者是否相关。[检修目标] g ； [检修步骤] s_i 。[输出]：
检修计划顺序性检测	检修目标 g 检修步骤 s_i 检修计划 s_j	给定如下检修目标和两个检修步骤，判断检修步骤顺序是否异常。[检修目标] g ；[检修步骤] s_i ；[检修计划] s_j 。[输出]：
检修计划冲突检测	检修计划 $P_1 = (g_1, (s_1^1, s_2^1, \dots, s_{N_1}^1))$ ； 检修计划 $P_2 = (g_2, (s_1^2, s_2^2, \dots, s_{N_2}^2))$	给定如下两个检修计划，判断二者是否可以同时开展。[检修计划]： P_1 ；[检修计划]： P_2 。[输出]：

4 实验研究

4.1 数据集与实验设置

4.1.1 数据集构建

电网检修计划异常检测目前没有成熟的数据集，本文收集了大量来源于电网通信领域的检修计划表用于构建具有丰富检修步骤信息的数据集。首先对现有检修计划语料进行人工标

注，识别可能存在的异常。之后对文本进行数据清洗，包括去除敏感信息、处理噪声和规范化文本格式等，确保每个样本的结构尽可能保持一致，提高数据集的质量。

我们按照 8 : 1 : 1 的比例将数据集划分为训练集、验证集和测试集，以便在模型训练和评估中进行有效监控和调整。考虑到现实中异常的情况往往是少数，我们对数据集进行了

非均衡采样，即训练集、验证集和测试集中不包含异常的样本与包含异常的样本比例为 5 : 1。

三个子任务的样本是从同一个数据源（即原始的检修计划表集合）中抽取得到的，由于每个子任务的输入上下文存在差异，例如顺序性检测的多个样本可以从同一个检修计划的若干步骤构造得到，而冲突检测的样本则只能拼接两个完整的检修计划，因此数据集的样本数量是不相同的。三个检修计划异常检测子任务数据集的统计信息如表 3 所示。数据集的规模足以微调 BERT 与 LLaMA 等预训练语言模型，不存在过拟合问题^[28]。

表 3 数据集统计信息

	训练集	验证集	测试集	无异常样本数	异常样本数
相关性检测数据集	37032	4834	4475	38618	7723
顺序性检测数据集	52175	6219	6108	53752	10750
冲突检测数据集	4885	610	610	5087	1018

4.1.2 评价标准

本文使用准确率 P、召回率 R 和 F1 值作为评价指标。评价指标的计算方法如公式（13）所示：

$$P = \frac{TP}{TP+FP}, R = \frac{TP}{TP+FN}, F1 = \frac{2 \times P \times R}{P+R} \quad (13)$$

其中 TP 代表存在异常的样本被判定为存在异常，FP 表示不存在异常的样本被判定为存在异常，FN 表示存在异常的样本被判定为不存在异常。

4.1.3 实现细节

本文所有实验均在公共服务器上进行，所用显卡为 NVIDIA RTX3090，CPU 为 Intel Xeon Gold 6326，内存 512GB，操作系统为 Ubuntu

18.04.3 LTS。使用的编程语言为 Python3.6，模型主要基于 PyTorch 1.10.2 和 Transformers 4.11.3 实现。预训练语言模型 BERT 选择 BERT-base-chinese，LLaMA 选择 LLaMA-2-7B。对于 GAD-BERT，其中 BERT 的学习率范围是 {1e-5, 3e-5, 5e-5, 1e-4}，LSTM 和分类器的学习率范围是 {1e-4, 3e-4, 5e-4, 1e-3}，分类器中间表示的维度范围是 {32, 64, 128, 256, 512}。对于 GAD-LLaMA，指令微调通过调用 Transformers 的 Trainer 类实现，LoRA 学习率范围是 {1e-4, 2e-4, 3e-4, 4e-4, 5e-4}。

4.2 对比方法

本文选择的对比方法包括 Rule-Based、TextRNN^[29] 和 LSTM。Rule-Based 是异常检测任务的传统方法，利用正则表达式抽取检修步骤的关键词，判断是否命中预设的规则模板进行检测。然而，Rule-Based 需要领域专家针对数据进行规则的设计，成本比较昂贵，并且难以处理特殊情况。TextRNN 是一种基于 RNN 的模型，能够有效地处理变长序列数据，捕捉文本中的上下文信息，但是容易出现梯度消失或梯度爆炸问题，限制了其对长距离依赖关系的建模能力。LSTM 旨在解决传统 RNN 中的长距离依赖问题，通过引入门控机制更好地捕捉和保持长期记忆，能够有效地处理序列数据中的长距离依赖关系，并缓解梯度消失和梯度爆炸的问题，使得模型在学习长文本时更为有效。然而，TextRNN 和 LSTM 等传统序列模型面对具体的电网领域文本时，仍面临语义理解有限的问题。本文提出的电网检修计划异常检测方法，利用了语言模型在预训练阶段获取的语义

理解能力与常识,可以有效避免由于电网领域训练语料较少导致的模型分类性能较差。

对于 Rule-Based 的方法,我们分别针对 3 项电网检修计划的异常检测任务,总结相应的响应规则,设计正则表达式进行判断。对于 TextRNN 和 LSTM,本文选择 Glove^[30] 作为预训练的词向量表示,将异常检测任务对应文本的词向量输入到 TextRNN 或 LSTM 神经网络中

进行分类。

4.3 实验结果与分析

本节主要对比不同方法在电网检修计划异常检测任务上的表现。结果如表 4 所示,本文提出的方法 (GAD-BERT 和 GAD-LLaMA) 明显优于对比方法 (Rule-Based、TextRNN 和 LSTM),其中 GAD-LLaMA 取得了最好的效果。

表 4 检修计划异常检测的实验结果

	相关性预测			顺序性预测			冲突检测		
	准确率	召回率	F1 值	准确率	召回率	F1 值	准确率	召回率	F1 值
Rule-Based	0.782	0.779	0.781	0.747	0.681	0.712	0.655	0.621	0.637
TextRNN	0.878	0.801	0.838	0.841	0.711	0.771	0.773	0.689	0.728
LSTM	0.901	0.826	0.862	0.863	0.764	0.810	0.814	0.711	0.759
GAD-BERT	0.939	0.841	0.887	0.892	0.806	0.847	0.856	0.743	0.795
GAD-LLaMA	0.952	0.856	0.901	0.901	0.811	0.854	0.861	0.748	0.801

通过观察不同方法在三个电网检修计划异常检测子任务上的表现,有以下结论: (1) Rule-Based 准确率最低。考虑到规则是硬性定义的,输入文本与规则略有差异或存在噪音,就会导致样本无法命中规则; (2) BERT 通过双向上下文建模能够更好地理解检修计划中的语义信息,而 TextRNN 和 LSTM 在处理电网检修计划这类长文本时,其对上下文的理解不及 BERT; (3) GAD-BERT 和 GAD-LLaMA 利用预训练语言模型的通用知识,在有限的标注数据上更好地泛化,而 TextRNN 和 LSTM 受限于数据规模和标注质量; (4) 注意力机制使本文提出的方法在处理变长序列方面更为灵活,能够更好地捕捉文本中的关键信息,而 TextRNN 和 LSTM 存在信息损失; (5) GAD-LLaMA 相比 GAD-BERT 有着明显的提升,这说明预训练语言模型的参数量与其在下游任务上的表现呈正相关。

综上所述,在电网检修计划异常检测任务中,基于预训练语言模型的方法更具优越性。

4.4 模型参数实验

本文设计了两个参数实验,分别探究 GAD-BERT 分类器的中间表示的维度对异常检测效果的影响,以及在检修计划冲突检测任务中,GAD-BERT 中使用的 LSTM 网络对冲突检测效果的影响,其结果如图 3 所示。

由图 3 (1) 可知,分类器中间表示的维度整体与异常检测模型的性能呈正相关。对于相关性检测和冲突检测任务,中间表示的维度选择 256 时表现最好,而顺序性检测在中间表示维度为 128 时表现最好。由图 3 (2) 可知,添加 LSTM 模块的 GAD-BERT 在三个评价标准上都取得了更好的效果,说明 LSTM 可以将语义信息传播到整个检修计划各个部分中,对于充分

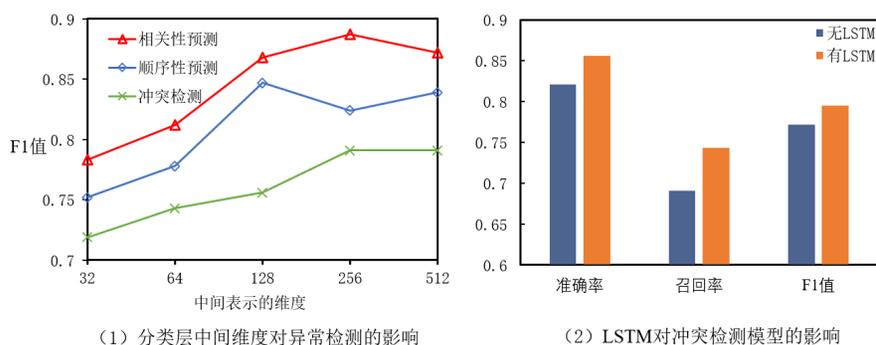


图 3 模型参数实验

编码整个检修计划具有重要的作用。

4.5 错误分析

本节对 GAD-LLaMA 分类错误的情况进行分析。针对 3 种电网检修计划的异常，分别挑选一个分类错误的测试样例进行分析。对于相关性预测任务，GAD-LLaMA 错误地将发生在同一条线路（读车 5249 线）两处不同位置（002# 塔和 001# 塔）的检修计划识别为同一个检修计划。对于顺序性检测任务，GAD-LLaMA 错误地认为“新旧 OPGW 光缆熔接”应当在“拆除

临时 ADSS 光缆”之前实施。对于冲突检测任务，GAD-LLaMA 错误地认为发生在同一条线路（晋家 5269 线 / 晋港 5270 线）两处不同位置（139#-140# 档、152#-164# 段）的检修计划不能同时开展。通过分析得知，LLaMA 具备区分不同线路与不同光缆的能力，但是缺乏同一条线路不同路段的检修计划相互独立、不同光缆之间存在检修顺序的常识。本文认为上述分类错误是 LLaMA 缺乏电网检修相关的领域知识造成的，在后续工作中可尝试在电网检修计划语料上进行预训练缓解该问题。

表 5 GAD-LLaMA 的错误样例

检修任务	检修计划实例	GAD-LLaMA 预测	实际结果
检修计划相关性检测	[检修目标] 读车 5249 线木湫变 002# 塔 OPGW 光缆恢复搭接 [检修步骤] 读车 5249 线 001# 塔迁改	检修目标与检修步骤相关	检修目标与检修步骤无关
检修计划顺序性检测	[检修目标] 陆桥加强 500kV 线路工程 500kV 斗常 5267 线升高改造 [检修步骤 1] 新旧 OPGW 光缆熔接 [检修步骤 2] 拆除临时 ADSS 光缆	顺序无异常	顺序异常
检修计划冲突检测	[检修计划 1] 晋家 5269 线 / 晋港 5270 线在 139#-140# 档开展相关线路迁改工作 (1) 晋家 5269 线在 134# 塔和 144# 塔处断开 OPGW 光缆 (2) 在 134# 塔和 144# 塔处将原光缆和 ADSS 临时光缆熔接 [检修计划 2] 晋家 5269 线 / 晋港 5270 线 152#-164# 段塔基、线路开展线路迁改工作 (1) 在晋家 5269 线 152# 塔 ~164# 塔处架设 2 根 72 芯 OPGW 光缆 (2) 开断晋家 5269 线 151# 塔、165# 塔临时过渡 ADSS 光缆 (3) 搭接晋家 5269 线 151# 塔和 165# 塔处 OPGW 光缆 (4) 搭接 500kV 晋家 5269 线 36 芯 OPGW 光缆	存在冲突	无冲突

5 结论

本文提出了基于预训练语言模型的检修计划冲突检测方法 GAD-BERT 和 GAD-LLaMA，

旨在发现检修计划中存在的异常。实验证明，本文的方法成功地提高了检修计划异常检测的准确性，在电网通信领域的场景下表现出色，并具有较强的泛化能力和实际应用潜力。相较于传统方

法, 基于预训练语言模型的方法显著提高了计划冲突检测的效率和准确性, 为推动电网通信领域的自动化和智能化发展迈出了重要的一步。

参考文献

- [1] ZHANG L, LYU Q, CALLISON-BURCH C. Reasoning about goals, steps, and temporal ordering with WikiHow[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). 2020: 4630-4639.
- [2] RISH I. An empirical study of the naive Bayes classifier[C]//IJCAI 2001 workshop on empirical methods in artificial intelligence, 2001, 3(22): 41-46.
- [3] HEARST M A, DUMAIS S T, OSUNA E, et al. Support vector machines[J]. IEEE Intelligent Systems and their applications, 1998, 13(4): 18-28.
- [4] SONG Y, LU Y. Decision tree methods: applications for classification and prediction[J]. Shanghai Archives of Psychiatry, 2015, 27(2): 130-135.
- [5] GU J, WANG Z, KUEN J, et al. Recent advances in convolutional neural networks[J]. Pattern recognition, 2018, 77: 354-377.
- [6] MEDSKER L R, JAIN L C. Recurrent neural networks[J]. Design and Applications, 2001, 5(64-67): 2.
- [7] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural computation, 1997, 9(8): 1735-1780.
- [8] CHUNG J, GULCEHRE C, CHO K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[J]. arXiv preprint arXiv:1412.3555, 2014.
- [9] WANG L, HAN M, Li X, et al. Review of classification methods on unbalanced data sets[J]. IEEE Access, 2021, 9: 64606-64628.
- [10] SUN Z, SONG Q, ZHU X, et al. A novel ensemble method for classifying imbalanced data[J]. Pattern Recognition, 2015, 48(5): 1623-1637.
- [11] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks: An overview[J]. IEEE signal processing magazine, 2018, 35(1): 53-65.
- [12] WEISS K, KHOSHGOFTAAR T M, WANG D D. A survey of transfer learning[J]. Journal of Big data, 2016, 3: 1-40.
- [13] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE international conference on computer vision. 2017: 2980-2988.
- [14] 缪相林, 孙超, 李彦, 等. 电网检修计划设计的智能分析与可视化实现[J]. 西安交通大学学报, 2005, 39(6): 582-585.
- [15] 程丽, 缪相林, 张培海, 等. 基于专家系统编排电网设备检修计划的求解策略[J]. 河北工业大学学报, 2006, 35(3): 63-67.
- [16] 丁毓峰, 胡业发, 盛步云, 等. 基于规则和事例混合推理的冲突解决技术研究[J]. 机械科学与技术, 2005, 24(3): 256-260.
- [17] 施荣华, 莫锐, 赵文涛. 一种基于冲突检测的无关联规则集匹配算法[J]. 计算机工程与科学, 2010, 32(10): 1-4.
- [18] 刘洁群. 基于谓词推理的冲突检测算法[J]. 吉林大学学报(理学版), 2016, 54(1): 112-115.
- [19] 孙玉芹, 肖静婷, 王海超. 基于多模型融合的电力的运检命名实体识别[J]. 科学技术与工程, 2024, 23(36): 15545-15552.
- [20] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in neural information processing systems, 2017.
- [21] DEVLIN J, CHANG M W, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding[J]. arXiv preprint arXiv:1810.04805, 2018.
- [22] TOUVRON H, LAVRIL T, IZACARD G, et al. Llama: Open and efficient foundation language models[J]. arXiv preprint arXiv:2302.13971, 2023.
- [23] 田园, 原野, 刘海斌, 等. 基于BERT预训练语言模型的电网设备缺陷文本分类[J]. 南京理工大学学报, 2020, 44(4): 446-453.
- [24] 张世奇, 马进, 周夏冰, 等. 基于预训练语言模型的商品属性抽取[J]. 中文信息学报, 2022, 36(1): 56-64.
- [25] 刘海顺, 王雷, 孙媛媛, 等. 基于预训练语言模型的案件要素识别方法[J]. 中文信息学报, 2021, 35(11): 91-100.
- [26] HU E J, SHEN Y, WALLIS P, et al. Lora: Low-rank adaptation of large language models[J]. arXiv preprint arXiv:2106.09685, 2021.
- [27] DING N, QIN Y, YANG G, et al. Parameter-efficient fine-tuning of large-scale pre-trained language models[J]. Nature Machine Intelligence, 2023, 5(3): 220-235.
- [28] DOR L E, HALFON A, GER A, et al. Active learning for BERT: an empirical study[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). 2020: 7949-7962.
- [29] LIU P, QIU X, HUANG X. Recurrent neural network for text classification with multi-task learning[J]. arXiv preprint arXiv:1605.05101, 2016.
- [30] PENNINGTON J, SOCHER R, MANNING C D. Glove: Global vectors for word representation[C]//Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP). 2014: 1532-1543.