

【交通物流 / Transportation Logistics】

基于BERT-CNN的城轨列控车载设备故障分类

徐倩^{1,2}, 张雷^{1,2}, 欧冬秀^{1,2}, 贺云鹏³

1) 同济大学上海市轨道交通结构耐久与系统安全重点实验室, 上海 201804; 2) 同济大学交通运输工程学院, 上海 201804; 3) 中铁第四勘察设计院集团有限公司, 湖北武汉 430063

摘要: 针对基于通信的城市轨道交通列车控制系统车载设备故障排查困难, 故障维修日志由于信息零散、语义模糊及归类混乱等导致的传统文本分布式表示与浅层机器学习算法分类精度低等问题, 提出一种基于焦点损失函数BERT-CNN (bidirectional encoder representations from transformers - convolutional neural network) 的故障分类方法, 建立故障处理及结论、故障现象的关系模型. 利用预训练好的BERT模型微调获取故障现象的词向量, 充分捕捉融合了上下文的双向语义并关注重点词汇; 利用卷积神经网络 (convolutional neural network, CNN) 进行训练, 改进损失函数以缓解数据类别不平衡引起的性能下降问题. 通过对某车载信号工区数据进行实验, 对比基于交叉熵损失函数的BERT-CNN、单一BERT模型与word2vec-CNN (word to vector - CNN) 方法, 基于焦点损失函数BERT-CNN方法在分类指标上最优, 对某些样本数量少的类别能够更精准分类. 研究结果有助于建立更完善的智能运维故障案例库.

关键词: 交通运输工程; 城轨列控车载设备; BERT语言模型; 卷积神经网络; 故障分类; 类别不平衡
中图分类号: U284.95; TP391.1 **文献标志码:** A **DOI:** 10.3724/SP.J.1249.2023.05529

Fault classification method for on-board equipment of metro train control system based on BERT-CNN

XU Qian^{1,2}, ZHANG Lei^{1,2}, OU Dongxiu^{1,2}, and HE Yunpeng³

1) Shanghai Key Laboratory of Rail Infrastructure Durability and System Safety, Tongji University, Shanghai 201804, P. R. China

2) College of Transportation Engineering, Tongji University, Shanghai 201804, P. R. China

3) China Railway Siyuan Survey and Design Group Co. Ltd., Wuhan 430063, Hubei Province, P. R. China

Abstract: The on-board equipment of metro communication based train control (CBTC) is facing laborious maintenance problems, and its textual maintenance logs are criticized for having excessively fragmented information, ambiguous semantics and confused categorization, resulting in low classification metrics by traditional textual distributed representation with basic machine learning algorithms. A fault classification method based on bidirectional encoder representations from transformers - convolutional neural network (BERT-CNN) with the focal loss function is proposed to establish the relationship model between the 'fault processing and conclusion' and the 'fault phenomena'. The pre-trained bidirectional encoder representations from transformers (BERT) model is fine-tuned to fully capture the bidirectional semantics and focus on the keywords to produce better word vectors of the 'fault phenomena'. In order to counteract the classification performance degradation brought by data category imbalance, word vectors are trained using a convolutional neural network (CNN) model with the focal loss function. According to the experimental results conducted by the dataset from an on-board signaling department, the proposed

Received: 2022-10-12; **Accepted:** 2023-02-28; **Online (CNKI):** 2023-08-25

Foundation: National Natural Science Foundation of China (52172329); National Key Research and Development Program of China (2022YFB4300501); Project of Science and Technology Commission of Shanghai Municipality (23DZ2204900)

Corresponding author: Professor ZHANG Lei (reizhg@tongji.edu.cn)

Citation: XU Qian, ZHANG Lei, OU Dongxiu, et al. Fault classification method for on-board equipment of metro train control system based on BERT-CNN [J]. Journal of Shenzhen University Science and Engineering, 2023, 40(5): 529-538. (in Chinese)



method has the best classification performance among models of BERT-CNN, single BERT and word to vector - CNN (word2vec-CNN) using cross-entropy loss function, and it is also better to correctly classify categories with few samples and contributes to the development of a more comprehensive library of fault cases for intelligent operation and maintenance.

Key words: transportation engineering; on-board equipment of metro train control system; BERT language model; convolutional neural network (CNN); fault classification; category imbalance

基于通信的列车控制 (communication based train control, CBTC) 系统为城市轨道的安全、高效运营提供保障^[1]. CBTC 车载设备软硬件功能集成度高, 在信号总故障中占比大, 故障情况复杂多样, 人工排查较为困难. 列控车载设备故障数据形式包括维修人员记录的故障维修工作日志、车载安全计算机记录的行车日志及一些组件的应用事件日志(application event log, AElog)^[2].

自然语言处理模型已从统计语言模型、神经网络语言模型发展到了预训练语言模型^[3-4]. 传统文本分布式模型表示包括词袋模型、向量空间模型、词频-逆文本频率(term frequency - inverse document frequency, TF-IDF)、独热编码及整数编码, 但这些方法容易造成高维稀疏特征. 词嵌入模型如 word2vec (word to vector)、全局词向量表示(global vectors for word representation, GloVe)、基于语言模型的词嵌入方法(embeddings from language models, ELMO)、生成式预训练 transformer (generative pre-trained transformer, GPT)、基于 transformers 的双向编码器表示 (bidirectional encoder representations from transformers, BERT) 等模型受到研究者关注. 2022 年 11 月开发的基于 GPT-3.5 架构的对话式应用 ChatGPT, 提高了大众获取有效信息的效率.

应用于文本分类的浅层机器学习模型包括朴素贝叶斯、 k 近邻、支持向量机、随机森林及 XG-Boost 算法等. 谢明军等^[5]利用主题模型有监督线性判别分析 (supervised-latent Dirichlet allocation, sLDA) 对城轨地面设备故障日志进行语义聚类, 并用朴素贝叶斯模型进行分类. 刘江等^[6]针对 CTCS2-200H 型列控车载行车日志中的故障数据, 利用 XG-Boost 算法对 8 种典型故障类型进行分类. 但基于传统语言模型与浅层机器学习算法的故障分类方法在应对更复杂语义与更大数据量的数据集时, 存在效率低与准确率低等问题.

应用于文本分类的深度学习算法包括卷积神经网络(convolutional neural network, CNN)、递归神经网络及其扩展, 如双向长短时记忆网络. 周璐婕

等^[7]利用 word2vec 中连续词袋 (continuous bag-of-words, CBOW) 模型获取高铁列控车载设备自动列车防护与控制单元 (automatic train protection and control unit, ATP-CU) 的应用设备记录 (application equipment log, AElog) 数据的词向量, 再利用 CNN 算法实现故障分类, 精确率达 0.873 2. AElog 数据是统一规范化的英文故障语句, 识别相对简单.

预训练语言模型的通用范式是先在大规模文本中训练出通用的语言表示, 再通过微调实现领域适应. 利用 BERT 模型分析 CBTC 故障维修工作日志的研究相对较少. CINELLI 等^[8]利用 transformer 与神经网络对每日钻井报告中的文本故障数据进行分类. LI 等^[9]利用 BERT 模型进行瞬态工作参数处理, 用于检测当前仪器测量值与理论值之间的偏差. 夏林中等^[10]研究了 BERT 模型在短文本分析中的优势.

智能运维需要大量历史数据建立完备的故障案例库, 以提供维修建议, 但受限于传统语言模型及机器算法在故障小样本、样本不均衡类别的弱分析能力, 城轨车载设备故障维修日志尚未得到充分利用. 本研究利用 BERT-CNN 模型对 CBTC 车载设备故障维修日志进行故障分类, 并引入基于焦点损失 (focal loss) 函数的 CNN 模型进行优化, 解决传统文本分布式表示与浅层机器学习模型及传统交叉熵损失函数在样本不平衡时分析精度较低的问题.

1 CBTC 车载设备结构及其故障维修日志

1.1 CBTC 车载设备结构

装备 CBTC 系统的列车车载设备包括 CBTC、车辆设备及接口设备等. 车头和车尾的车载控制器 (vehicle on-board controller, VOBC) 通过通信线缆相连. 本研究考虑的 CBTC 是有人值守下的列车自动运行, 车地通信采用交叉感应环线方式, 列车主用模式为 CBTC 控制模式, 后备模式为点式级与联锁级控制模式.

车载机柜上的设备包括: ① 应答器传输单元 (balise transmission module, BTM) 主机模块、车载列车自动防护 (automatic train protection, ATP) 系统主机及列车自动运行驾驶 (automatic train operation, ATO) 系统主机^[11]. BTM 主机模块与应答器接收天线结合实现应答器报文解析及列车位置矫正等功能; ② 在 ATP 防护下, ATO 实现列车的自动驾驶、区间运行自动调整、列车门和站台门自动开关以及精确停车; ③ 车载 ATP 设备根据获取的移动授权

信息和线路上障碍物信息, 结合电子地图, 计算紧急制动速度并实现超速防护, 保证列车不越过移动授权防护范围及防护速度. ATP 还具有确定列车停站位置、列车完整性检测、列车轮径矫正、车门允许及防护等功能^[12-13]. VOBC 到车辆主要通过接口继电器单元 (interface relay unit, IRU) 与司法记录单元 (juridical recording unit, JRU) 记录运行数据. 此外, 还包括测速测距设备、辅助驾驶设备及通信设备.

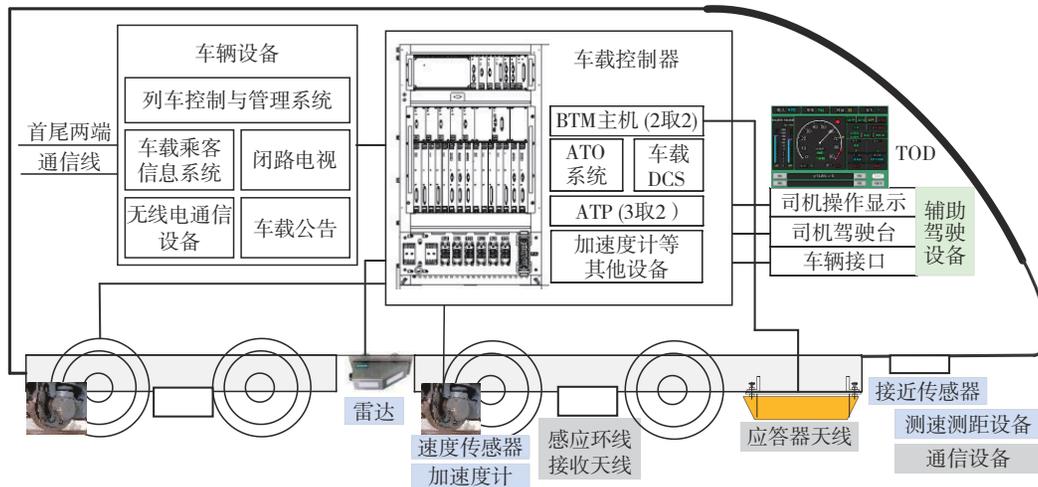


图1 装备CBTC系统的列车车载设备结构

Fig. 1 (Color online) Schematic diagram of CBTC on-board equipment.

1.2 CBTC 车载设备故障维修日志

CBTC 车载设备故障维修日志由序号、故障时间、故障现象、故障地点、故障代码、及故障过程与处理情况组成. 本研究仅列出故障分类所需信息, 如表1所示. 可见, 故障处理及结论易造成传统文本处理算法精度低的原因包括: ① 短文本, 即由几个词到几十个词组成, 文本长度及涵盖内容可能存在较大差异, 所包含信息量有限但表达了重要内容. 重要局部特征和上下文信息均能影响故障所属类别, 不同故障类别的故障描述可能存在相似度较高的特征. ② 模糊现象, 即由于维修人员对故障的理解和描述习惯的不同, 存在多词同义或歧义的现象, 如表1中记录7“接近传感器线缆接口有松动情况”与记录8“车底接近传感器插头接触不良”的语义一致. 此外, 故障过程及故障致因归类可能出现混乱.

文本预处理过程中, 首先, 将每日的故障维修日志汇总; 其次, 对文本清洗, 去除特殊符号和空格, 保持中英文词语统一, 去除停用词; 最后, 依据咨询维修人员的维修经验及分析大量故障案例,

分析故障现象与故障类别关系, 为每条故障纪录创建标签.

2 基于BERT-CNN故障分类模型

图2为用于故障文本分类的BERT-CNN模型结构. 将预处理后的数据转换为向量输入到BERT模型中, 生成动态词向量, 同时将词向量与一维位置向量拼接, 在句子中标记位置, 为模型提供更多有效信息. 其次, 将拼接好的词向量矩阵分别通过卷积层提取得到不同层次的特征向量. 最后, 将特征向量经过池化层进行平均池化, 降低维度后的向量通过全连接层及softmax分类器生成最终的故障类别. CNN模型是处理故障日志这类非时间序列、短文本的有效方法, 与BiLSTM模型相比, CNN结构简单、训练速度快^[14], 便于及时更新案例库.

2.1 基于BERT模型的词向量获取

BERT模型是字符级的语言模型, 根据自带的 BertTokenizer 工具将文本分割成单个字符的最小单位 token. 为了提高模型对句子的特征表示能力和

表1 CBTC车载设备故障维修日志示例

Table 1 Fault maintenance logs examples of CBTC on-board equipment

序号	故障现象	故障处理及结论	序号	故障现象	故障处理及结论
1	门关状态丢失导致紧急制动	没有门关闭锁闭信号,没有右门、左门允许的回采. 并且在没有门允许的情况下,司机打开了司机室门	5	VOBC超时故障	VOBC没有接收到牵引命令的回采,此为列车牵引的输出与输入命令不一致,怀疑是IRU内部继电器故障或者板卡故障导致
2	VOBC失去通信	数据下载后发现无代码,VOBC检查无异常. 根据故障过程及故障分析,某车以限速驾驶模式出场投入失败	6	对位故障	查看接近传感器,某车接近传感器的接口检查良好,但灵敏度偏低
3	门未关好	在停车点门不能关闭,只报故障	7	对位故障	检查某个接近传感器,发现线缆接口有松动情况,已重新校准,并将线缆绑扎
4	维调报某车在某站突发紧急制动	数据下载后发现两侧车端无代码,检查各个线缆以及板卡均无异常,测量各天线电阻正常. 司机在未正确转换 auto 模式的情况下按压发车按钮发车未果	8	对位故障	发现接近传感器接头接触不良,晃动插头时,感应灯会出现闪断现象,现用扎带重新捆扎牢固

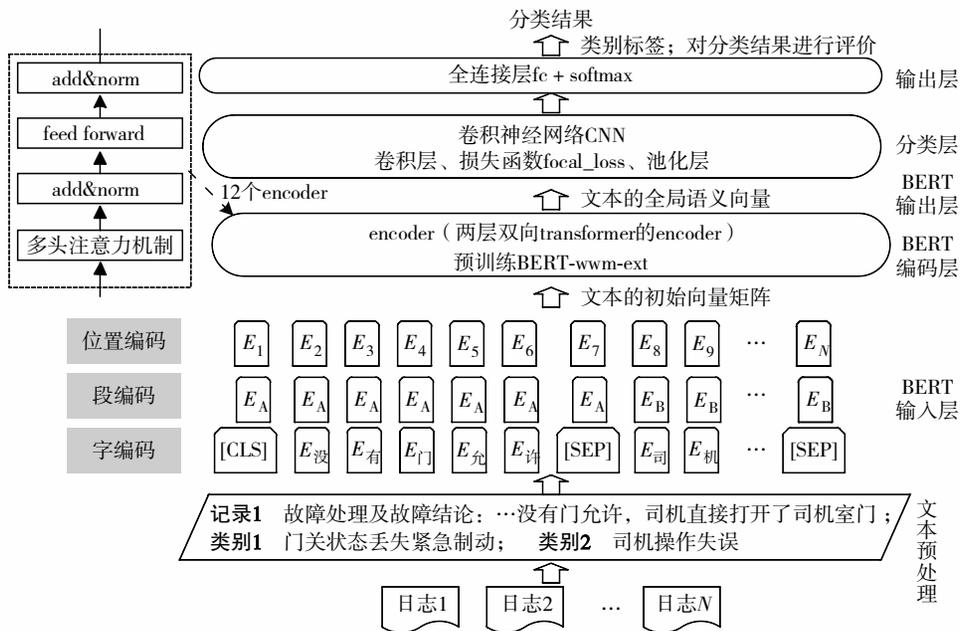


图2 用于故障文本分类的BERT-CNN模型结构

Fig. 2 Structural diagram of BERT-CNN model for fault text classification.

泛化能力, BERT模型使用掩码语言模型和下句预测训练方法. BERT模型的输入层由 token 编码、段编码及位置编码组成^[15]. 其中, token 编码是指将每个字或标记映射到 1 个高维向量空间的过程, 示例记录编码后为 $E_{没}, E_{有}, \dots$; 段编码是指区分不同段落或句子中的字或标记的过程, 示例记录编码后为 E_A, E_B, \dots ; 位置编码为每个字或标记在序列中分配 1 个唯一的向量, 示例记录编码后为 E_1, E_2, \dots .

将故障文本整句话中每个字符的初始向量矩阵 $X_{e,i}$ 输入至加载预训练参数的 BERT 模型, BERT 将

12 个 transformer 的 encoder 模块串联, 每一层的编码结果作为下一层的输入, 以便在不同层的编码模块中均能自动提取文本的不同语言特征. 多头注意力层通过计算词与词之间的关联度来调整词的权重, 反映了该词与这句话中所有词之间的相互关系以及每个词的重要程度. 对 $X_{e,i}$ 进行线性变换, 得到当前句子每个字符的查询向量 Q 、键向量 K 和价值向量 V ^[16], 计算为

$$Q = X_{e,i} \times W_Q \tag{1}$$

$$K = X_{e,i} \times W_K \tag{2}$$

$$V = X_{e,i} \times W_V \tag{3}$$

其中, \mathbf{W}_Q 、 \mathbf{W}_K 及 \mathbf{W}_V 分别为查询向量映射矩阵、键向量映射矩阵及值向量映射矩阵.

单头自注意力机制为

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (4)$$

其中, $\sqrt{d_k}$ 是缩放因子用于缩放点积.

通常使用多头自注意力机制进行并行计算, 用于捕捉不同维度的文本特征^[16], 即

$$\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)\mathbf{W}^o \quad (5)$$

$$\text{head}_i = \text{Attention}(\mathbf{Q}\mathbf{W}_i^Q, \mathbf{K}\mathbf{W}_i^K, \mathbf{V}\mathbf{W}_i^V) \quad (6)$$

其中, \mathbf{W}^o 、 \mathbf{W}_i^Q 、 \mathbf{W}_i^K 及 \mathbf{W}_i^V 为系数矩阵; head_i 表示第*i*头的自注意力计算结果.

为解决具备复杂网络结构、层数更深BERT模型可能出现的训练缓慢和梯度消失问题, 引入add&norm层. 以上结果输入前馈神经网络, 由两个线性变换组成, 并且在两次线性变换中加入ReLU激活函数, 增强encoder的非线性拟合能力. 再次输入add&norm层. 经过12个encoder, 最终将长度 $N = 50$ 的故障文本转换为 $N \times 768$ 维度的词向量 \mathbf{W}_i .

2.2 基于CNN的故障分类

将BERT的输出结果 $\mathbf{y}^{[CLS]}$ 作为CNN的词嵌入层, 在卷积层中应用卷积运算, 提取输入词向量矩阵 \mathbf{W}_i 的高阶局部上下文语义特征. 1个卷积操作使用1个卷积核 $\mathbf{f} \in \mathbf{R}^{l \times N}$ 产生1个特征向量 \mathbf{h}_j , 其中, l 和 N 分别表示卷积核高度(词窗口大小)和卷积核宽度(词向量维度). 为捕获不同粒度的特征, 本研究选择 $l = 2, 3, 4$ 进行卷积操作,

$$\mathbf{h}_j = \text{ReLU}(\text{conv}(\mathbf{W}, \mathbf{f}) + \mathbf{b}_j) \quad (7)$$

其中, ReLU是一种常用的非线性激活函数; conv为卷积操作; $\mathbf{b}_j \in \mathbf{R}$ 为偏置项. 卷积层输出结果是经过多个卷积核所生成特征向量 \mathbf{h}_j 的集合 $\mathbf{H} = \{\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_n\}$, n 为提取的特征向量数量.

池化层的作用是特征降维, 压缩数据和参数, 抑制过拟合现象, 在多分支全局最大池化层对特征数据做全局最大池化处理. 输入向量 \mathbf{P} 经过全连接层后, 得到最终输出 \mathbf{F}_c 为

$$\mathbf{F}_c = \sigma(\mathbf{W}_f\mathbf{P} + \mathbf{b}_f) \quad (8)$$

其中, \mathbf{P} 为故障类别; \mathbf{W}_f 为 \mathbf{P} 的权重; \mathbf{b}_f 为偏置项; σ 为激活函数, 本研究选择ReLU作为激活函数.

通过softmax进行归一化处理, 得到每个标签的预测概率, 选取概率最大的标签作为该文本的分类标签label,

$$\text{label} = \arg \max(\text{softmax}(\mathbf{F}_c)) \quad (9)$$

传统CNN模型采用最小化交叉熵损失函数的方法, 即

$$\text{Loss}_{\text{cross_entropy}} = -\frac{1}{D} \sum_{i=1}^D \sum_{j=1}^C \hat{p}_{ij} \ln p_{ij} \quad (10)$$

其中, D 为训练样本数; C 为目标故障分类数量; \hat{p}_{ij} 为实际故障类别; p_{ij} 为预测故障类别.

为改进类别不平衡及难分类的样本对分类效果的影响, 本研究引入了焦点损失函数. 通过调节权重因子 α_j 和 γ , 控制类别间的损失权重^[17]. 对于易分类的样本减小其权重, 对于难分类的样本增加其权重, 使模型更加关注难以分类的样本. 将每个类别的损失相加即可得到多类别问题下的焦点损失函数.

$$\text{Loss}_{\text{focal_loss}} = -\frac{1}{D} \sum_{i=1}^D \sum_{j=1}^C \alpha_j (1 - \hat{p}_{ij})^\gamma \hat{p}_{ij} \ln p_{ij} \quad (11)$$

3 实验与讨论

3.1 实验环境及数据集

本实验硬件环境为Intel(R) Core(TM) i7-10700F CPU、16 GByte RAM及NVIDIA GeForce RTX 3070 8 GByte GPU; 软件环境为Windows 10操作系统、基于Python3.9的Pytorch1.8.0框架, 使用transformer库及哈工大讯飞联合实验室提出的BERT中文预训练参数库BERT-wwm-ext.

数据集基于某条城轨线路2017—2021年CBTC车载设备故障维修日志, 原始数据集共有5537条故障记录. 故障代码统计见图3, 故障代码由“编码-内容描述”组成. 原始数据中“门未关好”故障现象所对应的“4B在停车点门不能关闭”、“对位故障”对应的“4E对位故障”及“VOBC失去通信”对应的“无代码”, 这3类故障现象尽管占比很大, 但故障处理方式及结论单一, 实际维修过程中可通过故障代码及关键词与故障案例数据库直接匹配, 无需进行深层次语义理解. 因此, 数据预处理时对这3类故障进行欠采样处理, 保留200条, 最后获得1398条具有复杂多样的故障现象、维修人员需要排查较大的范围而处置困难的故障记录.

本研究数据集也包括实际日志中包含的轨旁设

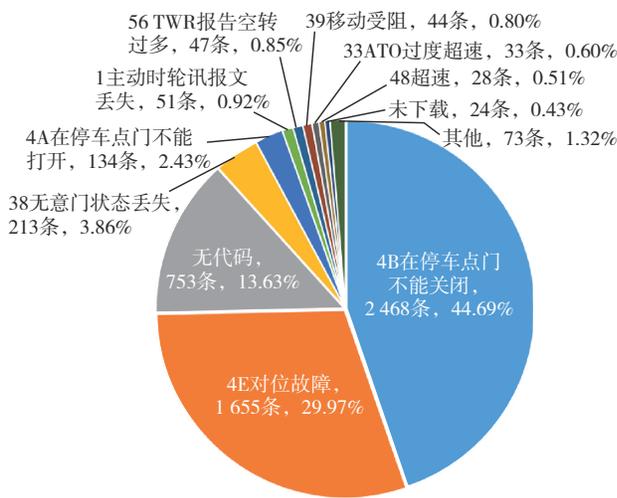


图3 某城轨线路的CBTC车载设备故障代码统计
 Fig. 3 (Color online) Statistical chart of fault codes for CBTC on-board equipment from a certain metro line.

备故障与车辆故障信息. 依据维修人员经验及大量故障案例分析, 提出故障现象与故障类别关系, 并标注预处理后各类别的数量, 如图4. 其中, 包含14种故障类别, 分别标注为 F_1 — F_{14} . 将故障现象对应的故障处理及结论作为模型训练输入, 根据致因结果标注类别作为标签, BERT-CNN用于挖掘关联关系.

检修人员通过已识别出的故障类别缩小检修范围, 进而提高现场运维效率, 完善历史故障案例库. F_1 类故障由车辆方配合处理; F_2 类通过加强司机操作规范来改善; F_3 类的处理如图5, 其中, 速度传感器故障与测速雷达的检修由车辆信号工区人员检修, 应答器故障由地面信号工区检修; F_4 、 F_5 及 F_9 类由地面信号工区处理; F_6 、 F_8 、 F_{10} 、 F_{11} 、 F_{13} 及 F_{14} 类由车载信号工区处理; F_{12} 类由通信工区配合处理; F_7 为突发事件.

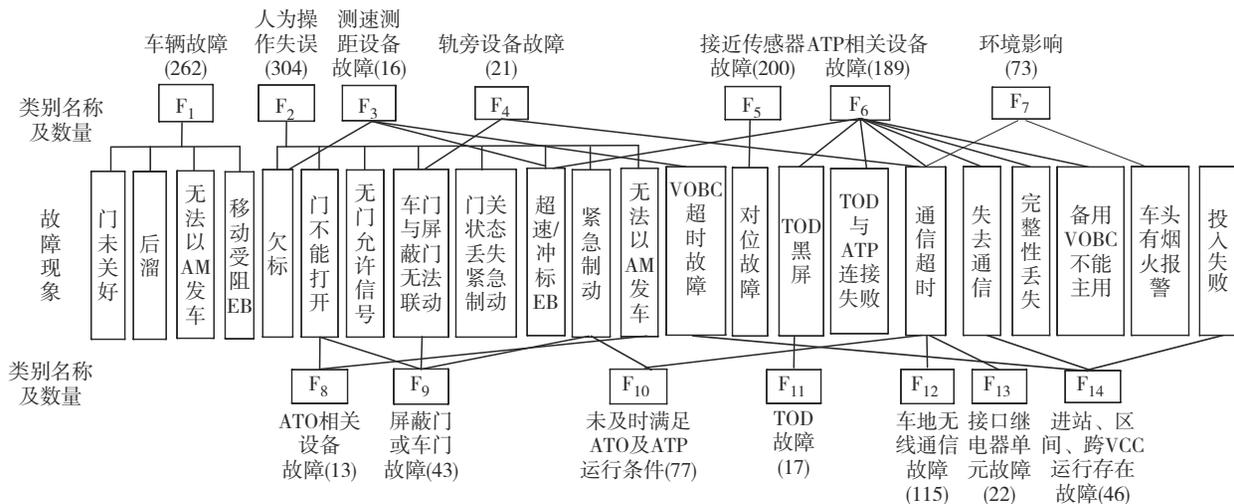


图4 故障现象与故障类别间关系及样本分布
 Fig. 4 Relationship and distribution between fault phenomena and classification categories.

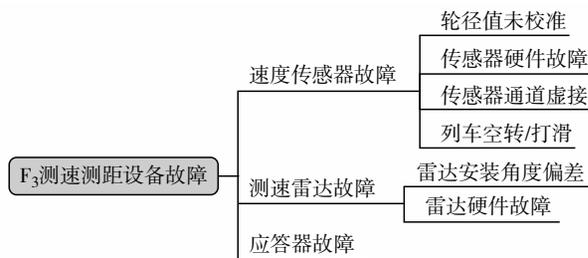


图5 F_3 类别故障处理示例
 Fig. 5 Process example diagram of F_3 fault category.

随着城轨运营里程的增加, 同类型的列控车载设备及不同线路条件也会积累更多的故障维修记录, 进而使偶发性故障累积. 本研究的BERT-CNN

模型具备分析庞大数据量的能力, 理论上数据量的增加能进一步提升BERT-CNN模型下的车载设备故障分类效果, 建立更完备的故障案例库. 实际上由于列控系统的安全苛求系统特性, 漏洞在运营过程中被不断修正, 不会导致故障维修纪录的大幅增加, 因此, 研究城轨列控车载设备故障分类仍然是小样本、样本类别不平衡的分类问题, 具有重要应用价值.

3.2 实验设计及多评价指标

预处理时将训练集与测试集比例划分为7:3, 在进行多种模型效果对比时, 考虑到样本分布的影响, 每组实验均使用相同的训练集与测试集. 多分

类的分类指标定义如下. 准确率为预测正确的结果数量占总样本的百分比, 计算为

$$\text{Accuracy} = \frac{\sum_{i=1}^N \text{TP}_i}{\sum_{i=1}^N \text{TP}_i + \sum_{i=1}^N \text{FP}_i + \sum_{i=1}^N \text{FN}_i + \sum_{i=1}^N \text{TN}_i} \quad (12)$$

其中, TP_i 为第 i 类样本的真正例 (true positive, TP), 即样本实际为正, 预测结果为正; FP_i 为第 i 类样本的假正例 (false positive, FP), 即样本实际为负, 预测结果为正; FN_i 为第 i 类样本的假负例 (false negative, FN), 即样本实际为正, 预测结果为负; TN_i 为第 i 类样本的真负例 (true negative, TN), 即样本实际为负, 预测结果为负; N 为类别的总数量.

准确率评价模型整体性能, 但不能真实反映小样本类别的分类效果. 精确率 Precision 衡量某一类别预测结果的准确性, 计算为

$$\text{Precision} = \frac{\sum_{i=1}^N \text{TP}_i}{\sum_{i=1}^N \text{TP}_i + \sum_{i=1}^N \text{FP}_i} \quad (13)$$

召回率 Recall 衡量某一类别预测结果的覆盖面, 计算为

$$\text{Recall} = \frac{\sum_{i=1}^N \text{TP}_i}{\sum_{i=1}^N \text{TP}_i + \sum_{i=1}^N \text{FN}_i} \quad (14)$$

F_1 分数是综合考虑精确率与召回率的分类指标, 计算为

$$F_1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (15)$$

宏平均 Macro_avg 先对每一类别统计指标值, 然后再对所有类求算术平均值. 微平均 Micro_avg 不区分类别, 先对数据集中每一类别进行统计建立全局混淆矩阵, 然后计算相应指标. 加权平均 Weight_avg 是宏平均的改进, 考虑了每个类别样本数量在总样本中的占比. 如精确率的宏平均、微平均及加权平均分别为

$$\text{Macro_avg}_P = \frac{1}{n} \sum_{i=1}^N P_i \quad (16)$$

$$\text{Micro_avg}_P = \frac{\sum_{i=1}^N \text{TP}_i}{\sum_{i=1}^N \text{TP}_i + \sum_{i=1}^N \text{FP}_i} \quad (17)$$

$$\text{Weight_avg}_P = \sum_{i=1}^N \frac{\text{TP}_i + \text{FN}_i}{\text{Total}} P_i \quad (18)$$

其中, Total 表示总样本数量.

分类报告可获取准确率、各指标的宏平均及加权平均. 通过调节超参数的值, 选择最优的一组超参数实现评价指标最优. BERT-CNN 及对比模型的训练参数和超参数如下.

1) word2vec-CNN 模型. 采用 word2vec 中的 CBOW 模型, 以 1 个词语的上下文作为输入来预测这个词语本身; 批处理大小 batch_size = 32, 窗口宽度 window = 4, 词向量维度为 200, 3 层一维卷积操作 Conv1D 的卷积核数量 filters 均取 128, 卷积核的长度 kernel_size 分别取 2、3、4, 输入周围的填充数量 padding 均为 same, 激活函数均为 ReLU, 丢弃比例 dropout = 0.1, 隐藏层维度 hidden_size = 768.

2) 单一 BERT 及 BERT-CNN 模型. 单一 BERT 可直接用于故障分类; BERT-CNN 是将 BERT 作为分类任务的词嵌入层. 设置学习率 lr = 5×10^{-5} , dropout = 0.1. 单一 BERT 与基于焦点损失函数的 BERT-CNN 模型 (简记为 word2vec-CNN (focal loss)) 中 batch_size = 32, 基于交叉熵损失函数的 BERT-CNN 模型 (简记为 word2vec-CNN (交叉熵)) 中 batch_size = 64. BERT-CNN 的 CNN 部分参数与 word2vec-CNN 一致.

3.3 BERT-CNN 与 word2vec-CNN、BERT 模型的故障分类效果比较

验证损失值 (Val_loss) 为每个轮次结束后训练集和测试集上计算得到的损失函数值, 用以判断模型的训练情况. 图 6 为 BERT-CNN、word2vec-CNN 及 BERT 模型的 Val_loss 下降过程. 可见, BERT-CNN (交叉熵)、BERT 模型训练拟合效果达到最优的轮次最少, 仅需训练 4 轮后, 损失值降至 0.2 左右, 且在前 10 次迭代训练后已经趋于稳定. 但 word2vec-CNN 算法在迭代 60 次情况下, 验证损失值仍有波动.

焦点损失函数的参数取值会影响故障分类性能, 结果见表 2. 可见, 当 $\alpha = 0.25$, $\gamma = 0.5$ 时, 能够找到不均衡类别间、易分与难分样本间的平衡点, 此时 Macro_avg_{F₁} 值最高.

多种方法获得的分类指标评价结果如表 3, 其中, 下标 R 表示召回率. 由于故障类别存在严重的数据不平衡问题, 准确率并不能完全反映真实情况, 因此, 更关注精确率及召回率, 并得到以下结论.

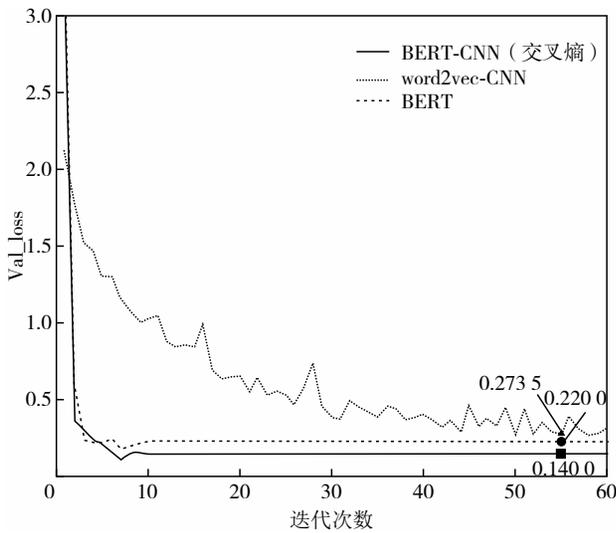


图6 BERT-CNN、word2vec-CNN及BERT模型的 Val_loss 下降过程

Fig. 6 Diagram of Val_loss reductions of BERT-CNN model (solid line), word2vec-CNN model (dotted line) and BERT model (dashed line), respectively.

1) word2vec-CNN(交叉熵)相比 word2vec-SVM 的各指标均有提升. 相比于 SVM, CNN 可以通过滑动卷积核在不同位置提取特征, 因此, CNN 可以捕捉到文本中的局部相关性信息. CNN 还可以使用不同大小的卷积核, 因此, 能够在不同尺度下捕获特征. SVM 默认是基于铰链损失(hinge loss), 基于

表3 word2vec 及 BERT 结合 SVM 或不同损失函数下 CNN 的分类评价

Table 3 Classification evaluation for word2vec and BERT combined with SVM or CNN with different loss functions

指标评价	word2vec-SVM	word2vec-CNN (交叉熵)	word2vec-CNN (focal loss)	BERT	BERT-CNN (交叉熵)	BERT-CNN (focal loss)
Accuracy	0.753 9	0.888 1	0.911 3	0.950 5	0.954 8	0.971 4
Macro_avg _P	0.793 5	0.901 6	0.876 7	0.900 5	0.898 4	0.962 3
Weight_avg _P	0.909 3	0.933 1	0.940 5	0.950 6	0.958 1	0.972 0
Macro_avg _R	0.753 9	0.753 8	0.786 4	0.874 2	0.924 0	0.937 4
Weight_avg _R	0.926 2	0.888 1	0.892 9	0.950 5	0.954 8	0.971 4
Macro_avg _{F₁}	0.763 2	0.798 0	0.812 1	0.885 0	0.904 1	0.948 1
Weight_avg _{F₁}	0.926 2	0.901 1	0.907 2	0.949 6	0.955 1	0.971 0

注: 灰底数值代表最优值.

故障类别不平衡问题会导致分类器在预测时更倾向于数量较多的类别, 进而忽略数量较少的类别. 可通过以下方法进行改进: ① 数据级方法, 如从多数类别中删除样本的欠采样方法、为少数类别生成新样本的过采样方法或两者的混合方法; ② 算法级方法, 如代价敏感学习或类别权重调整; ③ 集成方法, 如将一种数据级或算法级方法与集

表2 焦点损失函数中参数取值
Table 2 Different parameter values of focal loss function

α	γ	Macro_avg _{F₁}
0.20	0.5	0.904 1
0.25	0.5	0.948 1
0.25	0.7	0.923 1
0.50	1.0	0.923 1
0.50	2.0	0.939 6
0.25	2.0	0.874 6

注: 灰底数值代表最优值.

交叉熵的 CNN 相比基于 hinge loss 的 SVM 可以更好地优化模型分类效果.

2) BERT、基于交叉熵的 BERT-CNN 与基于交叉熵的 word2vec-CNN 相比, 各指标均有很大提升, 表明 BERT 能够有效挖掘短文本的重要信息.

3) 基于焦点损失函数的 word2vec-CNN 与基于交叉熵的 word2vec-CNN 相比提升较小, 表明限制 word2vec 分类效果的原因可能不只是类别不平衡问题, 还包括模型本身.

4) 单一 BERT 与基于交叉熵的 BERT-CNN 相比差别不大, 但引入焦点损失函数后在表 3 中的各项指标均提升明显, 表明焦点损失函数能够改善不平衡数据的整体分类效果.

成学习中的 AdaBoost 方法结合. 在数据层面, 本研究对故障现象频次高且重复率高的类型进行欠采样处理. 在算法层面, 由于 BERT 是一种预训练语言模型, 在通用语言表示学习基础上, 通过较少的参数调整提高模型效果; BERT 能够根据上下文信息对文本进行更准确理解, 因此, 在处理短文本上比 word2vec 更有优势. CNN 中引入焦点损失函数, 给

小样本类别赋予较高权重, 使模型在训练时更关注小样本类别. 选用混淆矩阵展示测试集上各类别的判别结果, 如图7. 其中, 矩阵的行和列分别为预测类别和真实类别, 对角线上的数值表示预测正确

的数量, 非对角线上的数字表示错误分类的数量. 可见, 图7(a)中非对角线上的数字多于图7(b), 表明基于焦点损失函数的BERT-CNN分类效果更优.

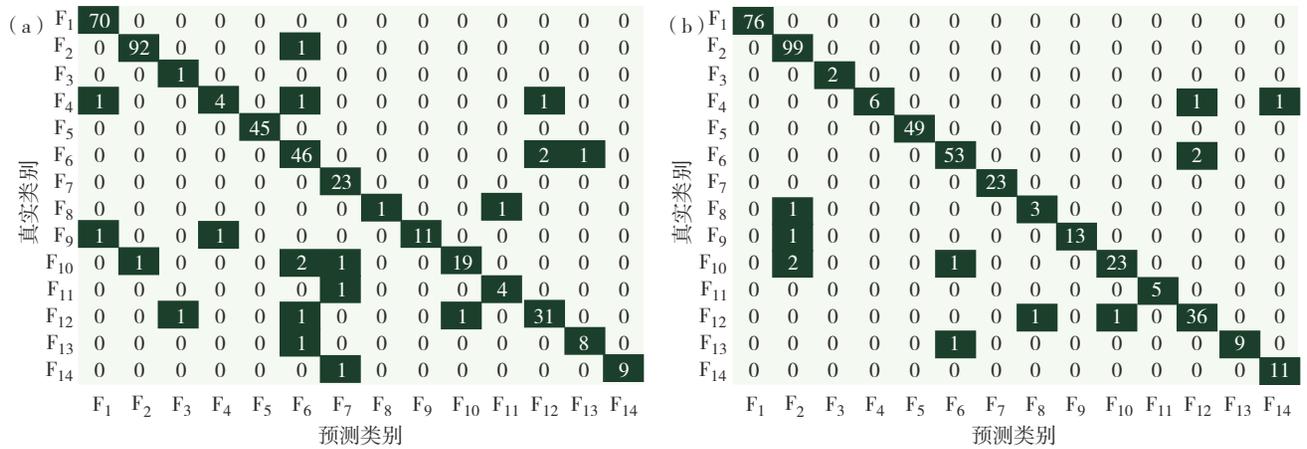


图7 (a)基于交叉熵的BERT-CNN与(b)基于焦点损失函数BERT-CNN模型的混淆矩阵

Fig. 7 (Color online) Confusion matrix for (a) BERT-CNN model with cross-entropy and (b) BERT-CNN model with focal loss function.

表4为基于不同损失函数的BERT-CNN故障记录误分类. 其中, F₃、F₄、F₈、F₉、F₁₁、F₁₃及F₁₄为小样本类别. 可见, 尽管基于交叉熵的BERT-CNN已达到较高精度, 基于焦点损失函数的BERT-CNN在F₄、F₉、F₁₁及F₁₄在误分类情况上均有降低. 文献[8]采用基于焦点损失函数的word2vec-CNN, 其精确率、召回率及F₁值分别为0.873 2、0.827 1及0.849 5, 而本方法宏平均精确率可达0.962 3, 因此, 采用焦点损失函数的BERT-CNN可作为城轨智能运维系统的底层算法.

障情况复杂、人工排查难, 需通过智能运维算法提升检修效率. 由于车载设备故障维修日志的文本短、语义模糊, 基于传统文本表示及机器学习的故障分类方法的分类效果较差. 本研究提出一种基于BERT模型的故障分类方法, 基于某城轨线路中1 398条影响实际运营、语义复杂的故障维修日志作为案例数据, 在对日志进行预处理后, 利用中文BERT预训练模型获取词向量, 并利用CNN进行故障分类. 在相同训练集、测试集及相同交叉熵损失函数下, BERT-CNN与word2vec-CNN、单一BERT相比在多项分类指标上提升明显, Macro_avg_{F₁}值由对比模型的0.798 0、0.885 0提高至0.904 1. 本研究通过引用焦点损失函数解决故障分类的数据不平衡问题. 与基于交叉熵BERT-CNN相比, 基于焦点损失函数BERT-CNN的小样本类别效果提升明显, Macro_avg_{F₁}由0.904 1提高至0.948 1. 未来工作将基于更完善的数据集, 研究知识图谱等故障处理的可视化结果.

表4 基于不同损失函数的BERT-CNN故障记录误分类情况

Table 4 Misclassification analysis of BERT-CNN fault logs based on different loss functions

类别	BERT-CNN(交叉熵)	BERT-CNN(focal loss)
F ₃	—	—
F ₄	误分类为F ₁ 、F ₆ 及F ₁₂ 各1次	误分类为F ₁₂ 及F ₁₄ 各1次
F ₈	误分类为F ₁₁ 有1次	误分类为F ₁ 有1次
F ₉	误分类为F ₁ 及F ₄ 各1次	误分类为F ₂ 有1次
F ₁₁	误分类为F ₇ 有1次	—
F ₁₃	误分类为F ₆ 有1次	误分类为F ₆ 有1次
F ₁₄	误分类为F ₇ 有1次	—

结 语

CBTC车载设备在信号总故障中占比大, 且故

基金项目: 国家自然科学基金资助项目(52172329); 国家重点研发计划资助项目(2022YFB4300501); 上海市科委资助项目(23DZ2204900)

作者简介: 徐倩(xuqian0403@tongji.edu.cn), 同济大学博士研究生. 研究方向: 智能交通异常检测.

引 文: 徐倩, 张雷, 欧冬秀, 等. 基于BERT-CNN的城轨列控车载设备故障分类[J]. 深圳大学学报理工版, 2023, 40(5): 529-538.

参考文献 / References:

- [1] TANG Ruifan, DE DONATO L, BESINOVIĆ N, et al. A literature review of artificial intelligence applications in railway systems [J]. *Transportation Research Part C: Emerging Technologies*, 2022, 140: 103679.
- [2] 中国铁路总公司. 列控车载设备典型故障案例[M]. 北京: 中国铁道出版社, 2013: 29-71.
China Railway Corporation. Typical failure cases of on-board equipment of train control systems [M]. Beijing: China Railway Publishing House, 2013: 29-71. (in Chinese)
- [3] DHAR A, MUKHERJEE H, DASH N S, et al. Text categorization: past and present [J]. *Artificial Intelligence Review*, 2021, 54(4): 3007-3054.
- [4] LI Qian, PENG Hao, LI Jianxin, et al. A survey on text classification: from traditional to deep learning [J]. *ACM Transactions on Intelligent Systems and Technology*, 2022, 13(2): 31.
- [5] 谢明军, 何剑峰, 胡小溪, 等. 基于故障日志的城轨地面信号故障诊断[J]. *北京交通大学学报*, 2020, 44(5): 27-35.
XIE Mingjun, HE Jianfeng, HU Xiaoxi, et al. Fault diagnosis for urban rail transit trackside signaling equipment based on fault logs [J]. *Journal of Beijing Jiaotong University*, 2020, 44(5): 27-35. (in Chinese)
- [6] 刘江, 许康智, 蔡伯根, 等. 基于XGBoost的列控车载设备故障预测方法[J]. *北京交通大学学报*, 2021, 45(4): 95-106.
LIU Jiang, XU Kangzhi, CAI Baigen, et al. XGBoost-based fault prediction method for on-board train control equipment [J]. *Journal of Beijing Jiaotong University*, 2021, 45(4): 95-106. (in Chinese)
- [7] 周璐婕, 党建武, 王瑜鑫, 等. 基于卷积神经网络的列控车载设备故障分类研究[J]. *铁道学报*, 2021, 43(6): 70-77.
ZHOU Lujie, DANG Jianwu, WANG Yuxin, et al. Research on fault classification method for onboard equipment of train control system based on convolutional neural network [J]. *Journal of the China Railway Society*, 2021, 43(6): 70-77. (in Chinese)
- [8] CINELLI L P, DE OLIVEIRA J F L, DE PINHO V M, et al. Automatic event identification and extraction from daily drilling reports using an expert system and artificial intelligence [J]. *Journal of Petroleum Science and Engineering*, 2021, 205: 108939.
- [9] LI Xiangyu, CHENG Kun, HUANG Tao, et al. Research on false alarm detection algorithm of nuclear power system based on BERT-SAE-iForest combined algorithm [J]. *Annals of Nuclear Energy*, 2022, 170: 108985.
- [10] 夏林中, 叶剑锋, 罗德安, 等. 基于BERT-BiLSTM模型的短文本自动评分系统[J]. *深圳大学学报理工版*, 2022, 39(3): 349-354.
XIA Linzhong, YE Jianfeng, LUO Dean, et al. Short text automatic scoring system based on BERT-BiLSTM model [J]. *Journal of Shenzhen University Science and Engineering*, 2022, 39(3): 349-354. (in Chinese)
- [11] 郜春海. 基于通信的列车运行控制(CBTC)系统[M]. 北京: 中国铁道出版社, 2018: 9-38.
GAO Chunhai. Communication-based train control system [M]. Beijing: China Railway Publishing House, 2018: 9-38. (in Chinese)
- [12] 中国城市轨道交通协会. 城市轨道交通 CBTC 信号系统规范 第 1 部分: ATP 子系统: T/CAMET 04018. 1—2019[S]. 北京: 中国铁道出版社, 2019.
China Association of Metro. Urban rail transit system specification of communication based train control system part 1: ATP subsystem: T/CAMET 04018. 1—2019 [S]. Beijing: China Railway Publishing House, 2019. (in Chinese)
- [13] KIM S, WON Y, PARK I H, et al. Cyber-physical vulnerability analysis of communication-based train control [J]. *IEEE Internet of Things Journal*, 2019, 6(4): 6353-6362.
- [14] KIM Y. Convolutional neural networks for sentence classification [C]// *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Stroudsburg, USA: ACL, 2014: 1746-1751.
- [15] ROGERS A, KOVALEVA O, RUMSHISKY A. A primer in BERTology: what we know about how BERT works [J]. *Transactions of the Association for Computational Linguistics*, 2020, 8: 842-866.
- [16] 李金洪. 基于BERT模型的自然语言处理实战[M]. 北京: 电子工业出版社, 2021: 206-237.
LI Jinhong. BERT model-based natural language processing in practice [M]. Beijing: Publishing House of Electronics Industry, 2021: 206-237. (in Chinese)
- [17] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]// *IEEE International Conference on Computer Vision (ICCV)*. Piscataway, USA: IEEE, 2017: 2999-3007.

【中文责编: 方圆; 英文责编: 淡紫】