



计算机科学

COMPUTER SCIENCE

面向轨道交通智能故障检测的边云计算方法

李志, 林森, 张强

引用本文

李志, 林森, 张强. 面向轨道交通智能故障检测的边云计算方法[J]. 计算机科学, 2024, 51(9): 331-337.

LI Zhi, LIN Sen, ZHANG Qiang. [Edge Cloud Computing Approach for Intelligent Fault Detection in Rail Transit](#) [J]. Computer Science, 2024, 51(9): 331-337.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[融合多模态物联网设备指纹与集成学习的物联网设备识别方法](#)

IoT Device Recognition Method Combining Multimodal IoT Device Fingerprint and Ensemble Learning
计算机科学, 2024, 51(9): 371-382. <https://doi.org/10.11896/jsjcx.230800076>

[面向物联网僵尸网络多阶段攻击的异常流量检测方法](#)

Abnormal Traffic Detection Method for Multi-stage Attacks of Internet of Things Botnets
计算机科学, 2024, 51(8): 379-386. <https://doi.org/10.11896/jsjcx.230700197>

[驶向智能未来:深度学习在轨道交通革新中的应用](#)

Driving Towards Intelligent Future:The Application of Deep Learning in Rail Transit Innovation
计算机科学, 2024, 51(8): 1-10. <https://doi.org/10.11896/jsjcx.240300099>

[基于BERT和CNN的药物不良反应个案报道文献分类方法](#)

Literature Classification of Individual Reports of Adverse Drug Reactions Based on BERT and CNN
计算机科学, 2024, 51(6A): 230400049-6. <https://doi.org/10.11896/jsjcx.230400049>

[面向物联网的分布式联邦学习加密验证研究](#)

Study on Cryptographic Verification of Distributed Federated Learning for Internet of Things
计算机科学, 2024, 51(6A): 230700217-5. <https://doi.org/10.11896/jsjcx.230700217>

面向轨道交通智能故障检测的边云计算方法

李志^{1,2} 林森¹ 张强³

1 北京交通大学自动化与智能学院 北京 100044

2 中国电子科技集团公司第十五研究所 北京 100083

3 中国人民解放军 61741 部队 北京 100070

(22115005@bjtu.edu.cn)

摘要 轨道交通系统是当今社会中交通运力的主要承载系统,对安全性有极高的要求。轨道交通系统的多个组件由于直接暴露在环境中,受多种外界因素影响,易出现故障。这些故障可能会导致列车延误、乘客滞留、服务暂停,甚至是灾难性的生命或财产损失。因此,需要设计针对轨道交通系统的实时故障检测方案,进而才能采取有效的维护措施。不同于基于传统的机器学习(Machine Learning, ML)的故障检测工作,本研究采用中文双向编码器表示转换器(Bidirectional Encoder Representation from Transformer, BERT)深度学习(Deep Learning, DL)模型进行实时的智能故障检测。该模型能够在处理故障检测任务时获取双向上下文的理解,从而更准确地捕捉句子中的语义关系,使得其对故障描述的理解更为精准。BERT 的训练需要大量的数据支持,而轨道交通领域中存在多个运营商,它们各自持有独立的故障检测数据。由于数据的保密性,这些数据无法进行共享,从而限制了模型的训练,故采用了联邦边云计算方法,允许多个运营商在保持数据隐私的前提下共同训练 BERT 模型。联邦学习结合边云计算方法,在本地对轨道交通各运营商的数据进行初步处理,然后将汇总后的梯度上传至云端进行模型训练,最终将训练得到的模型参数发送回各边缘设备,实现模型的更新。研究表明,采用联邦边云计算方法进行 BERT 模型训练,在轨道交通领域的故障检测任务中优于目前已有的先进方案。这一方法在解决数据保密性问题的同时,有效提升了轨道交通故障检测的准确性与可靠性。

关键词: 轨道交通;故障检测;边云计算;联邦学习;BERT

中图分类号 U285.4;TP391

Edge Cloud Computing Approach for Intelligent Fault Detection in Rail Transit

LI Zhi^{1,2}, LIN Sen¹ and ZHANG Qiang³

1 School of Automation and Intelligence, Beijing Jiaotong University, Beijing 100044, China

2 The 15th Research Institute of China Electronics Technology Group Corporation, Beijing 100083, China

3 The Chinese People's Liberation Army 61741 Unit, Beijing 100070, China

Abstract Rail transit systems are the main carrying system of transportation capacity in the current society. It is extremely sensitive to safety. Because multiple components of the system are directly exposed to the environment, they are affected by various environments and are prone to failures, which may cause train delays, passenger retention, service outage, or even catastrophic loss of life or property. Therefore, it is necessary to design a fault detection scheme so that effective maintenance measures can be taken. Different from traditional machine learning (ML) based fault classification work, this paper adopts Chinese bidirectional encoder representation from transformer (BERT) deep learning (DL) model for intelligent fault detection. The model can obtain bidirectional contextual understanding when dealing with fault detection tasks, so as to more accurately capture the semantic relationship in sentences, and understand the fault descriptions more accurately. The training of BERT requires a large amount of data support, and there are multiple operators in the field of rail transit, each of which holds independent fault detection data. Due to the confidentiality of the data, these data cannot be shared, which limits the training of the BERT model. This paper designs and adopts the federated edge cloud computing method, allowing multiple operators to jointly train the BERT model while maintaining data privacy. Federated learning combined with the edge cloud computing method allows the data of rail transit operators to be preliminary processed locally, and then the summarized gradients are uploaded to the cloud for model training, and finally the trained model parameters are sent back to each edge device to realize model updates. The research results show that the BERT model training using the federated edge cloud computing method is superior to the existing advanced solutions in the fault detec-

到稿日期:2023-12-27 返修日期:2024-05-24

通信作者:林森(21120216@bjtu.edu.cn)

tion task in the field of rail transit. This method not only solves the problem of data confidentiality, but also effectively improves the accuracy and reliability of fault detection.

Keywords Rail transit, Fault detection, Edge cloud computing, Federated learning, Bidirectional encoder representation from transformer

1 引言

轨道交通系统作为现代社会主要的交通运输系统,承担着越来越多的交通运力需求^[1-3],同时对其安全性的要求也越来越高^[4-5]。然而,由于轨道交通系统中的多个组件直接暴露在环境中,容易受到多种环境因素的影响而出现故障,进而可能导致列车延误、乘客滞留、服务中断,甚至造成严重的生命和财产损失。因此,为确保轨道交通系统的持续安全性和正常运营,迫切需要切实可行的故障检测方案,协助轨道交通系统的运营人员在出现故障时采取必要的维护和修复措施^[6],以最大程度地减少对乘客和运营的不利影响。

目前,大多数故障检测工作都依赖于传统的机器学习(Machine Learning, ML)技术^[7-8],如支持向量机(Support Vector Machine, SVM)^[9-11]、决策树(Decision Tree, DT)^[12-14]和贝叶斯网络^[15-17]。然而,这些 ML 模型在故障检测任务中需要手动从系统日志中提取特征,这个过程容易导致大量的故障信息丢失^[18]。为了克服这一问题,引入中文双向编码器表示变压器(BERT)深度学习(DL)模型,实现自动从原始文本日志中提取故障特征^[19]。BERT 模型具有许多显著优势。首先,在处理自然语言任务时,它对故障描述等文本信息的理解更为精准。其次,由于 BERT 模型能够获得丰富的语言表征,在故障检测任务上表现出色,因此选择采用 BERT 模型作为轨道交通智能故障检测的核心模型。

轨道交通领域存在着常见的数据孤岛问题^[20-22],不同运营商拥有故障检测数据的独立所有权,因此数据的隐私和保密性问题成为限制 BERT 模型训练的关键难题。为解决这一问题,本研究特别关注了数据的保密性问题,提出了一种创新的联邦边云计算方法,在保护数据隐私的同时,能够联合多个运营商的数据资源,共同训练 BERT 故障检测模型。这一联邦边云计算方法允许各运营商在本地维护其数据的完整性和隐私性,同时还能够通过安全的计算协议将数据的有关信息分享到云端,以进行模型训练。

这一创新性的方法不仅解决了数据的隐私和保密性问题,还能够为轨道交通系统提供更强大的故障检测工具。此外,该方法还具有在其他领域的数据隐私保护和分布式计算中广泛应用的潜力。通过联合多方的数据,可以更好地应对数据孤岛问题,为数据驱动的应用提供更多可能性。

在联邦边云计算方法中,各运营商的故障检测数据都始终保持在本地环境中,不被外部共享,严格遵循数据隐私的完整性和安全性原则。在训练过程中,各运营商的服务器相互连接,构建了一个虚拟的联邦网络。各运营商的服务器在本地根据自有的故障检测数据进行初步的 BERT 模型训练,生成本地的梯度更新信息。本地梯度的更新信息通过安全的加密方式被传送到云端,由中央云服务器用于整体模型训练和参数更新。采用联邦学习的方法, BERT 模型能够逐步融合

各运营商提供的特定故障检测信息,从而显著增强模型的泛化能力和准确性;多个运营商可以在确保数据隐私的前提下,共同训练出一个具有优秀检测能力的 BERT 模型。本文的主要贡献有:

1)应用 BERT 模型赋能轨道交通系统故障检测。相较于传统的机器学习方法, BERT 能够从原始文本日志中自动提取故障特征,避免手动特征提取可能引发的信息丢失,并且 BERT 模型能够获得丰富的语言表征以及双向上下文关系,从而提高了轨道交通系统故障检测的准确率和效率。

2)采用了联邦边云计算方案,该方案中每个运营商在本地训练 BERT 模型,产生本地梯度更新,汇总至云端,由中央云服务器进行模型的整体训练和参数更新。该方案保证了各运营商的数据隐私性,克服了多个运营商之间数据不共享的问题。通过联邦学习,模型能够跨越运营商边界,共同训练得到更具泛化能力的故障检测模型,有效提升了整体的检测性能。

3)实验结果表明,采用的 BERT 模型在联邦边云计算训练后具有较高的故障检测精度。此外,通过比较几种常用的 ML, DL 故障检测方法,证明了 BERT 模型在几个评价指标上优于其他模型。本文采取的基于 BERT 模型的联邦边云计算故障检测方法能够有效汇总多运营商的故障检测特征,实现轨道交通系统高精度智能故障检测。

本文第 2 章介绍面向轨道交通系统智能故障检测的联邦边云计算方案,并对系统模型数学建模;第 3 章描述基于 BERT 模型的故障检测模型;第 4 章介绍实验设置、结果并进行讨论;最后总结全文并展望未来。

2 面向轨道交通系统智能故障检测的联邦边云计算方案

如图 1 所示,多家轨道交通系统运营商各自连接到对应的边缘服务器,而每个边缘节点都在与中央云服务器建立联系。这一联邦边云计算框架中,模型同时存在于边缘和云端,构成了一个高度分布化的结构。

各运营商都维护着独立的故障检测文本日志数据库。而在这一框架中,运营商将其私密的故障检测数据上传至相应的边缘节点。这些边缘节点接收数据后,执行本地的 BERT 模型训练,生成本地梯度更新数据,随后将这些梯度更新数据上传至中央云服务器,以供进一步的数据汇总。这一过程有助于中央云服务器执行“无数据”的模型更新,以整合各运营商的信息并更新模型参数。经过一定时间后,中央云服务器将具备出色的故障检测性能,可以同时应对多家运营商的不同故障检测数据。此时,中央云服务器可以将其 BERT 模型的参数下发到连接的每个边缘节点,从而为每个运营商提供强大的文本日志故障检测能力。




图1 面向轨道交通系统智能故障检测的联邦边云计算系统架构
Fig.1 Federated edge cloud computing system architecture for intelligent fault detection of rail transit system

本研究的主要创新在于设计了一个专门用于轨道交通系统智能故障检测的联邦边云计算系统。该系统由一组边缘节点和一个云服务器组成,旨在应对轨道交通系统中基于文本日志的智能故障检测任务。需要特别注意的是,这些边缘节点可以是本地计算机,也可以是安装在各个运营商公司中的强大物联网设备,用于数据训练和处理。在这一系统中,各运营商都积极参与联邦学习过程,使用自己的文本日志故障检测数据集,借助中央云服务器,一同构建整体 BERT 模型,旨在生成高质量的文本故障检测模型,从而提升轨道交通系统的故障检测水平。这一设计采用了 BERT 模型作为主要工具来处理文本故障检测问题,而 BERT 模型的具体细节以及联邦边云学习的算法将在下一章中详细描述。

3 基于 BERT 的联邦边云计算求解方案

3.1 针对文本日志故障检测的独立 BERT 模型

本节分析了独立的 BERT 模型,这是在中轨道交通系统中用于检测故障的一种先进的深度学习模型。在这种情况下,各运营商只使用自己的文本数据集来训练 BERT,而不需要联合起来。BERT 是一种预训练的语言表示模型,它放弃了传统的单向语言模型或两个单向语言模型,可以生成深度双向语言表示。此外,研究表明其在各种 NLP 任务中取得了优异的结果。预训练一般是将许多低成本收集到的训练数据放在一起,让模型学习到共性。使用少量带注释的数据进行微调来训练预训练模型。在这种情况下,模型只需要从处理通用数据集开始,然后针对特定任务学习更专业的特征。屏蔽语言模型(Masked Language Model, MLM)作为 BERT 模型中的预训练任务,随机屏蔽输入序列中一定数量的词,并对屏蔽后的词进行预测。MLM 使 BERT 能够学习到分布式的上下文表示。

如图 2 所示,一个独立的 BERT 故障检测模型可以接收文本故障数据,进行模型内部分析,得出最终的故障类别。

模型内部可分为四大模块:分词器、嵌入层、编码层、分类层。




图2 独立 BERT 文本故障检测模型

Fig.2 Independent BERT text fault detection model

分词器由 2 个部分组成:基本标记器和字块标记器。基本标记器作为主要部分,执行一些基本操作(大小、标点符号分割、小写转换、中文字符分割和重音删除),然后返回一组单词;字块标记器根据设置的词汇表进行分词。不同的词汇表(字符、单词和句子词汇表)对标记化过程有显著影响。在这些词汇表中,单词词汇表表现得最好,并被采用。单词数组可以直接输入到以下的层,即嵌入层。

嵌入层分为标记嵌入层、分段嵌入层和位置嵌入层 3 个嵌入层。标记嵌入层将每个单词转换为 d 维的向量表示。段嵌入层只有两个向量表示,前一个向量为第一句中的每个标记分配 0,后者为第二个句中的每个标记分配 1。如果输入只有一个句子,则段嵌入是一个零数组。位置嵌入层在每个位置学习一个向量,并对表示序列顺序的信息进行编码。位置嵌入层是一个序列长度为 d 的查找表,该表的第一行表示第一个序列的第一个位置,第二行表示该序列的第二个位置,以此类推。位置嵌入的计算是使输入文本具有序列效应。因此,可以保留关于语言顺序的信息。位置嵌入的计算如式(1)所示:

$$P(pos, 2index) = \sin\left(\frac{pos}{10000 \frac{2index}{d}}\right) \quad (1)$$

其中, pos 表示第 pos 个单词在整个句子中的位置, d 表示模型的维数。

文本特征将在编码层中被提取。编码层中的附加规范层可以帮助编码器网络对这些层进行标准化。前馈中的每一层都接收上一层的输出并将其传递给下一层,这可以看作是一个函数,通过多次恢复非线性函数,生成输入空间到输出空间的复杂映射。

分类层用于将编码层的输出映射到具体的故障检测类别上,可以包括多个全连接层以及一个激活函数,用于将编码层的特征进行加工和组合,从而得到最终的分类结果。在训练过程中,模型会通过反向传播算法不断调整分类层的权重和偏置,使其能更好地拟合训练数据,从而提高故障检测的准确率。

分类层训练完成后,BERT 模型就可以对新的文本故障数据进行分类。具体地,输入文本数据经过分词器、嵌入层、编码层提取特征,然后通过分类层的映射,预测出该文本数据所对应的故障检测类别。BERT 模型中有自注意力、多头注意力两个关键机制。

自注意力机制(Self-Attention),通常用于处理序列数据,特别是在自然语言处理和计算机视觉领域。自注意力机制允许模型在处理输入序列的每个元素时,动态地分配不同的权重给每个元素,以捕捉元素之间的关联性。这使得自注意力机制非常适用于长序列建模,并且不会受到固定窗口大小或

固定权重的限制。因此 BERT 模型采用了自注意力机制对一句话中不同单词的值进行加权求和,计算相应注意力值的权重系数。自注意力机制的核心思想是,每个输入元素都会与其他元素发生交互,而这种交互的强度由元素之间的关系来决定。这种交互可以用权重矩阵来表示,而这个权重矩阵是动态生成的。自注意力机制通常包括以下几个关键步骤:

1) 查询(Query, Q): 对于每个输入元素,计算一个查询向量,用来衡量这个元素与其他元素的相关性。

2) 键(Key, K): 为每个输入元素计算一个键向量,用于表示其他元素的重要性。

3) 值(Value, V): 为每个输入元素计算一个值向量,用于存储其他元素传递过来的信息。

4) 权重计算: 计算每个查询向量与所有键向量之间的相似度,通常使用点积、缩放点积等方法,然后将这些相似度经过 softmax 函数进行归一化,得到权重。

5) 加权求和: 使用上一步得到的权重来对所有值向量进行加权求和,从而生成最终的输出表示。

自注意力机制的优点包括其能够处理不定长的序列,捕捉长距离的依赖关系,以及学习到不同位置之间的权重分布。这些特性使得自注意力机制在机器翻译、文本生成、文本分类、语音识别、图像处理等任务中取得了显著的成功。在 BERT 模型的自注意力机制中,每个文本句子中的单词的权重是由该句话中的所有单词来计算的,同时为了避免因方差较大而引起的训练问题,将内积除以维数的平方,以减少方差。

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right) \quad (2)$$

多头注意力机制(Multi-head Attention)是自注意力机制的一种扩展,它提高了模型的表达能力,允许模型在不同的注意力子空间中关注不同的关系。多头注意力机制通常被用于深度神经网络,尤其是在自然语言处理领域,以改善模型对不同单词之间关系的捕捉和表示。多头注意力机制包括以下几个关键步骤:

1) 投影: 对输入序列进行 3 次线性投影,分别得到查询(Query)、键(Key)、和值(Value)的向量表示。这 3 次投影使用不同的权重矩阵,以生成多个子注意力的表示。

2) 多头计算: 对每一组 (Q, K, V) 进行单独的自注意力计算。这意味着模型会同时计算多个子注意力,每个子注意力都关注不同的关系和上下文。多头计算可以通过并行处理来加速。

3) 拼接: 每个子注意力的输出结果被拼接在一起,形成一个更高维的表示。这个拼接操作将不同子注意力的信息整合在一起,以更好地捕捉序列中不同层次的关系。

4) 线性投影: 将拼接的表示再次通过线性投影,映射回与原始输入相同的维度。这个线性投影操作也使用不同的权重矩阵。

多头注意力机制的优点在于它允许模型在不同子空间中捕捉不同类型的关系,从而提高了模型的表达能力。这对于自然语言处理任务特别有用,因为语言中存在多种不同层次的关系,例如语法关系、语义关系、上下文关系等。多头注意力

机制的引入使得模型能够更好地理解和处理这些复杂关系。

简单来说,在采用的 BERT 模型中,多头注意机制就是将 n 个自注意力得到的 softmax 输出向量进行拼接,并对每一个自注意力进行随机初始化。这样,就可以捕捉到 n 种不同类型的注意力组合。主要计算如式(3)所示:

$$MultiAttention(Q, K, V) = \text{concat}(Attention_1, Attention_2, \dots) \cdot w \quad (3)$$

其中, w 是 $d * d$ 的投影矩阵。从特征融合的角度来看,在合并不同的子空间时,应考虑不同头部的特征匹配。合并后的向量可以用多个特征的最后一个加权融合矩阵映射到 d 维。

基于式(2)和式(3),BERT 的文本特征输出可计算为:

$$BERT(Q, K, V) = \text{concat}\left(\text{softmax}\left(\frac{Q_1 K_1 w_1}{\sqrt{d}}\right), \text{softmax}\left(\frac{Q_2 K_2 w_2}{\sqrt{d}}\right), \dots\right) \cdot w \quad (4)$$

3.2 基于 BERT 的联邦边云计算方法

独立 BERT 模型需要大量数据进行计算才能得到优良的故障检测性能,而运营商的数据隐私性对这一要求产生了极大的阻碍。利用联邦边云计算方法,可以在保护运营商数据隐私的前提下,利用海量数据完成对 BERT 的充分训练。

将全局训练迭代范围表示为 t , N 个运营商通过更新 BERT 的参数,得到梯度更新参数 θ ,并将其上传至云服务器进行聚合。图 3 展示了该算法的流程。




图 3 基于 BERT 的联邦边云计算算法流程

Fig. 3 Process of federated edge cloud computing algorithm based on BERT

基于 BERT 的联邦边云计算方法如算法 1 所示。

算法 1 基于 BERT 的联邦边云计算方法

1. 云服务器执行:

1.1. 初始化全局训练周期 t , 局部训练时间 l , 局部梯度 θ

1.2. for $t \leftarrow 0$ to T do

$\theta_{t+1}^n \leftarrow$ 边缘更新(n, θ_t)

end for

1.3 $\theta_{t+1} \leftarrow \frac{1}{N} \sum_{n=1}^N \theta_{t+1}^n$

2. 边缘更新(n, θ_t)

2.1. for $l \leftarrow 0$ to L do

2.1.1. 将输入文本分词

2.1.2. 计算嵌入结果

2.1.3. 提取文本特征

2.1.4. 更新分类层参数

2.1.5. 生成梯度更新参数

end for

2.2 将梯度更新参数 θ_{t+1}^n 发送给云

异步更新时,运营商边缘之间的异步参数更新可能导致

参数的一致性,且可能导致模型的收敛速度不确定。异步更新模式下频繁的参数传输,尤其是在运营商数量众多、更新频率较高的情况下,会增加通信开销,消耗网络带宽和计算资源,也易导致系统不稳定或者发生死锁等问题。故采用同步更新的方式,所有运营商都在每个训练轮次结束时进行参数更新,使得训练过程更加透明和容易理解,并且更易控制训练过程中的参数同步和通信频率,确保所有运营商的模型始终保持一致。

表 1 故障检测数据

Table 1 Fault detection data

告警开始时间	告警标题	设备 ID
2019-02-05 00:01	射频单元 IR 接口异常告警	383A218145EEA7892DA45BC4B2DFCBFB
2019-02-05 00:01	射频单元 IR 接口异常告警	2216E5B350E675E20B983E9D75F6B232
2019-02-05 00:02	射频单元交流掉电告警	3C8F2AA2E939E9608CA5FE2200E87D84
2019-02-05 00:02	射频单元业务不可用告警	3C8F2AA2E939E9608CA5FE2200E87D84
2019-02-05 00:02	射频单元光模块收发异常告警	713570937709ED63AFD495B85CD3B5B3
2019-02-05 00:03	射频单元维护链路异常告警	3C8F2AA2E939E9608CA5FE2200E87D84
2019-02-05 00:03	系统时钟不可用告警	A44F8E5DAC2C7FBA9D21DCBACD123D26

原始数据由 65 万条报警标题(47Mb)和 2 万条工作单(1.2Mb)两部分组成。前者包含时间和基站的报警内容和信息,后者包括故障类别、时间和设备 id 的信息。其中故障类别共 6 类。本研究按 7:3 的比例划分训练集与测试集。

为了将数据输入 BERT 模型中,首先根据时间和设备 id 信息对报警内容和故障类别进行匹配。由于手动故障识别判断关注的是最新的报警内容,因此选择保留特定数量的最后报警内容。然后,预处理后的数据集可以被输入 BERT 模型中。

本研究还根据数据集的特性,进行了分字、分词和分句的词汇表制作。分字词汇表中有多达 21 128 个词汇,然而如此大规模的词汇表在该场景下并不能全部利用,实验数据集所涉及的字较为有限;分句词汇表仅有 81 个词汇,由于其由分句制成,颗粒度较高,不利于模型学习,故最终采纳分词词汇表;分词词汇表具有 224 个词汇。部分词汇如表 2 所列。

表 2 分词词汇表

Table 2 Token-based vocabulary

电流	机房	插错
电调	单元	槽位
功率	单板	参考源
低劣化	错帧	不足
登录	传输	回退
机柜	出现	干扰
超限	冲突	闭塞
超门限	承载	本地
基站	尝试	版本

4.2 模型参数设置

本节分析了 BERT 配置文件中的功能并设置了每个参数的值,具体如表 3 所列。

表 3 BERT 配置

Table 3 Configuration of BERT

参数	值	作用
注意力层抛弃概率	0.1	在注意力层中避免过度配合
隐藏层数	12	影响隐藏层的复杂性
初始化范围	0.02	随机初始化网络参数
注意力头数	12	影响表示偏差
中间尺寸	3072	影响模型推理速度与精度
最大位置嵌入尺寸	512	限制输入长度

4 仿真

本研究基于 Python 语言与 tensorflow-gpu 框架以及一系列故障检测数据,对面向轨道交通智能故障检测的联邦边云计算方法进行了仿真实验,并将其故障检测精度与部分常用故障检测算法的精度进行了对比。

4.1 故障检测数据以及数据预处理

故障检测数据部分内容如表 1 所列。

此外,通过调整学习率来改变优化器。图 4 给出了 3 种不同学习速率下训练集的准确率和损失。




图 4 不同学习率对比

Fig. 4 Comparison of different learning rates

学习速率计划从 0 升温,然后衰减到 0。把热身步骤设置为十分之一的时代。经过多次尝试发现,学习率的最佳值是 2×10^{-5} 。假设 2×10^{-5} 学习率包含了这些选择中最全面的敏感学习率区间,这意味着如果只有我们设置的学习率区间可以包含敏感区间,那么 BERT 模型的训练过程是有效的。

最终研究得到的模型结构如表 4 所列。

表 4 模型结构

Table 4 Model structure

层	输出尺寸	参数量
词嵌入	(13000,512,768)	16 226 304
位置嵌入	(13000,512,768)	393 216
前馈层	(13000,512,768)	1 536
transformer 层 1	(13000,512,768)	7 087 872
.....	(13000,512,768)	7 087 872
transformer 层 11	(13000,512,768)	7 087 872
编码器输出层	(13000,512,768)	—
全连接层	(13000,512,768)	—

4.2 仿真结果与对比

对于数据集中每个序列的每个类别,使用以下标准来评估不同模型的性能。

R^2 分数:也称为决定系数(Coefficient of Determination),是一种用于评估回归模型性能的统计指标。它表示回归模型所预测的因变量(目标变量)的方差解释比例,即模型对因变量变化的解释程度。 R^2 分数的取值范围通常在 0~1 之间,

但也可能是负数。其含义如下。

1) $R^2 = 1$: 表示模型完美拟合了数据, 因变量的变化完全由自变量解释。

2) $R^2 = 0$: 表示模型对因变量的变化没有提供任何解释, 模型的表现与简单平均值相当。

3) $R^2 < 0$: 表示模型拟合得非常差, 甚至比简单平均值的效果还差。

R^2 分数不受不同数据集的大小影响, 通过采用一种称为基线模型的第三方基准模型, 对诊断模型进行评估。 R^2 分数的计算方法如式(5)所示:

$$R^2 = 1 - \frac{\sum_{n=1}^6 (y_n - Y_n)^2}{\sum_{n=1}^6 (Y_n - \bar{Y}_n)^2} \quad (5)$$

其中, n 代表类别, Y 代表标签, y_n 是预测值, \bar{Y}_n 是平均值, R^2 分数越接近 1, 说明模型对数据的解释能力越强, 拟合效果越好。然而, R^2 分数也有其局限性, 它对过度复杂的模型可能会过高估计拟合效果, 而且对于非线性关系的数据拟合效果不佳。

ROC 曲线: 即受试者工作特征曲线, 是一种用于评估二分类模型性能的图形工具。它显示了不同分类阈值下真正例率(True Positive Rate, 也称为敏感度)与假正例率(False Positive Rate)之间的关系。ROC 曲线通常用于比较不同模型的性能或选择最佳分类阈值。

1) 横轴(X 轴): ROC 曲线的横轴表示假正例率(False Positive Rate, FPR), 计算方式为 $FPR = FP / (FP + TN)$, 其中 FP 代表假正例数, TN 代表真负例数。 FPR 衡量了模型错误地将负例分类为正例的程度。

2) 纵轴(Y 轴): ROC 曲线的纵轴表示真正例率(True Positive Rate, TPR), 也叫敏感度或召回率, 计算方式为 $TPR = TP / (TP + FN)$, 其中 TP 代表真正例数, FN 代表假负例数。 TPR 衡量了模型正确地将正例分类为正例的程度。

3) 曲线: ROC 曲线是一个由不同分类阈值下的 TPR 和 FPR 组成的曲线。通过在不同阈值下计算 TPR 和 FPR, 可以得到一系列点, 连接这些点就形成了 ROC 曲线。

4) 随机线: 对角线上的线通常表示随机猜测, 即模型性能与随机模型相当。因此, 好的分类模型应该在 ROC 曲线上方, 而不应在 ROC 曲线下方。

5) AUC: ROC 曲线下的面积(Area Under the Curve, AUC)通常被用来度量分类模型的性能。AUC 的取值范围在 0~1 之间, AUC 值越大表示模型性能越好, 具有更高的分类准确度。AUC 等于 1 表示模型完美分类, AUC 等于 0.5 表示模型的性能等同于随机猜测。

ROC 曲线的主要优点在于它可以帮助选择最佳的分类阈值, 以平衡敏感度和特异性, 根据具体问题的需求来调整分类模型的性能。此外, ROC 曲线还适用于不平衡数据集, 其中正例和负例的比例差异较大。

ROC 曲线是一种敏感性与一种特异性的曲线图, 通常被称为假阳性率, 总结了一系列切割点的敏感性和特异性。该平面的水平坐标为 FPR, 垂直坐标为 TPR。计算 AUC 值来评估其质量。AUC 值为 ROC 曲线以下面积的大小。通常,

AUC 值的范围为 0.5~1.0, AUC 越大表示性能越好。ROC 曲线如图 5 所示。




图 5 ROC 曲线

Fig. 5 ROC curves

基于上述两个指标, 相同的数据集以及同样的训练时长, 评估并对比 BERT 模型与常见的故障检测模型, 如随机森林、线性回归模型, 如表 5 所列。

表 5 故障诊断模型对比

Table 5 Fault diagnosis model comparison

模型	测试精度	ROC 曲线下的面积	R^2 分数
线性回归	0.4044	0.3194	-0.9695
随机森林	0.6121	0.7533	-0.1299
BERT 模型	0.8648	0.8368	0.5373

如表 5 所列, BERT 模型在测试集精度、 R^2 分数以及 ROC 曲线的 AUC 面积上都有较大优势, 证明了 BERT 模型在文本故障诊断领域的优越性能。

本研究还对比了不同运营商公司单独训练故障诊断模型与合作训练联邦故障诊断模型的效果, 如图 6 所示。可以观察到 3 家运营商公司合作训练的联邦故障诊断模型的效果优于各自单独训练, 验证了本设计采用的联邦边云计算方法可以在保护各公司数据隐私的前提下, 提升故障诊断精度, 同时验证了本研究应用于轨道交通系统基于文本的故障检测任务的可行性。




图 6 是否使用联邦边云计算方法的精度对比

Fig. 6 Accuracy comparison of whether to use federated edge cloud computing method

结束语 综上所述, 本研究为轨道交通系统提供了一种全新的、数据隐私友好的并结合了先进的 BERT 模型和创新的联邦边云计算的故障检测方案。这一研究为轨道交通领域的智能故障检测带来了新的进展, 也为跨领域的数据隐私保护和分布式计算提供了启发, 未来将进行更深入的探索和创新。

参考文献

[1] WEI X D. Urban rail transit automation system and technology

- [M]. Electronic Industry Press, 2004.
- [2] JIANG F. Research on the connection between urban rail transit and other modes of transportation [J]. Journal of North Jiaotong University, 2001(4): 108-110.
- [3] TI Y. Development status and countermeasures of urban rail transit in China [J]. Science, Technology and Economy of Inner Mongolia, 2005(6): 317-319.
- [4] XU K, ZHANG C B, CHEN Z H. Overview of rail transit fault diagnosis [C]// The 18th Annual Conference of China System Simulation Technology and its Application. 2003.
- [5] GONG Y M, CHEN X K, ZHANG G F. Information security of the urban rail transit signaling system [J]. Electronic Communication and Computer Science, 2023, 5(4): 89-91.
- [6] LIU T S, ZHU X J, XU R H. Analysis of the operation safety and reliability of the urban rail transit system [J]. Research on Urban Rail Transit, 2006, 9(1): 15-17.
- [7] SUN Y J, ZHANG S, MIAO C X, et al. Improved BP Neural Network for Transformer Fault Diagnosis [J]. Journal of China University of Mining & Technology - English Edition, 2007, 17(1): 138-142.
- [8] CHEN K W, WEI S G, SHI H B, et al. An on-board network fault diagnosis method based on machine learning: CN202211088642. 2 [P]. [2024-02-25]. <http://www2.drugfuture.com/cnpat/verify.aspx?cnpatentno=202211088642.2>.
- [9] ZHOU J B, XIAO M H, ZHU Y J, et al. Study on fault diagnosis of tractor diesel engine based on HPO-SVM [J]. Journal of Nanjing Agricultural University, 2023, 46(2): 12.
- [10] WU T J. Data-driven fault diagnosis method based on machine learning [D]. Hangzhou: Zhejiang University of Technology, 2020.
- [11] ZHANG J P, WANG L X. Simulation study on individualized diagnosis of circuit faults [J]. Computer Simulation, 2022(8): 168-170.
- [12] WANG Q, MEN X Z. Fault Diagnosis Based on Rough Sets and C4.5 dsDecision Tree [J]. Journal of Northeastern University: Natural Science, 2006, 27(10): 1138-1141.
- [13] LIU D, ZHANG Y, ZOU G Y. Fault diagnosis method, device, equipment and medium based on decision tree: CN202211667676. 7 [P]. [2023-04-27]. <http://www2.drugfuture.com/cnpat/verify.aspx?cnpatentno=202211667676.7>.
- [14] WANG X M, FU Y B, LI J T. Diagnosis diagnosis decision method for power equipment based on decision tree algorithm [J]. Automation Application, 2023, 64(12): 128-131.
- [15] ZHAO W, ZHU Y, WANG X. Combinatorial Bayes network in fault diagnosis of power transformer [J]. Electric Power Automation Equipment, 2009, 29(11): 6-9.
- [16] WANG Z Y, SONG R W, SHI H. An online diagnosis method of bearing faults based on Dynamic Bayesian network [J]. Journal of Taiyuan University of Science and Technology, 2023, 44(4): 303-308.
- [17] WANG Z H. Methods for ventilator fault diagnosis based on a Bayesian network [J]. Equipment Management and Maintenance, 2023(4): 150-151.
- [18] LIU K, YUAN Y Y. Feature extraction and clustering of short articles based on autoencoder [J]. Journal of Peking University: Natural Science Edition, 2015, 51(2): 282-288.
- [19] DEVLIN J, CHAN M W, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding [J]. arXiv:1810.04802, 2018.
- [20] DU X X, LIU Y. Research on Beijing Rail Transit Information Exchange Platform based on XML [J]. Railway Computer Applications, 2012, 21(1): 55-61.
- [21] YUE C, ZHANG K, QU S H. Application of urban information model in shield tunneling engineering [J]. Urban Rail Transit research, 2021, 24(7): 225-229.
- [22] SUN M, FU Z. A method and device for predicting short-time passenger flow of rail transit: CN202111203957. 2 [P]. [2024-02-25]. <http://www2.drugfuture.com/cnpat/verify.aspx?cnpatentno=202111203957.2>.



LI Zhi, born in 1983, postgraduate, senior engineer. His main research interests include artificial intelligence, big data mining, and tactical communication.



LIN Sen, born in 1999, postgraduate. His main research interests include urban rail transit and artificial intelligence.

(责任编辑:柯颖)