

分类号 _____
U D C _____

密级 _____
编号 _____



硕士学位论文

论文题目 基于短文本分类与数据融合的
铁路信号设备故障诊断研究

研究生姓名: 宋文琴

指导教师姓名、职称: 尚庆生 副教授

学科、专业名称: 管理科学与工程

研究方向: 数据分析与信息处理

提交日期: 2022年5月29日

独创性声明

本人声明所呈交的论文是我个人在导师指导下进行的研究工作及取得的研究成果。尽我所知，除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示了谢意。

学位论文作者签名： 宋文琴 签字日期： 2022.5.29

导师签名： 尚庆生 签字日期： 2022.5.29

关于论文使用授权的说明

本人完全了解学校关于保留、使用学位论文的各项规定，_____（选择“同意”/“不同意”）以下事项：

1.学校有权保留本论文的复印件和磁盘，允许论文被查阅和借阅，可以采用影印、缩印或扫描等复制手段保存、汇编学位论文；

2.学校有权将本人的学位论文提交至清华大学“中国学术期刊（光盘版）电子杂志社”用于出版和编入CNKI《中国知识资源总库》或其他同类数据库，传播本学位论文的全部或部分内容。

学位论文作者签名： 宋文琴 签字日期： 2022.5.29

导师签名： 尚庆生 签字日期： 2022.5.29

Research on Fault Diagnosis of railway Signal Equipment based on short text classification and Data Fusion

Candidate : Song Wenqin

Supervisor: Shang Qingsheng

摘要

铁路信号设备是包含电源屏、轨道电路、道岔、信号机以及各种控制设备在内的重要铁路系统安全装置,但总会由于各种各样的诸如设备质量不良、工作人员疏忽或误操作以及外部环境等内部或外部原因,出现各种类型的故障。目前的铁路信号设备故障诊断大部分还是采用较为传统的人工排查等方式,需要工作人员经验丰富且尽职尽责,存在较大的不确定性,稍有不慎设备故障就有可能导致事故或损失等不良影响。因此,如何根据现有的科学技术和设备来准确及时地诊断铁路信号设备故障是目前的研究热点,且要准确诊断出具有随机性、复杂性和多样性的铁路信号设备故障更不容易。本文的主要研究内容如下:

(1) 建立铁路信号设备故障文本数据集。针对铁路信号设备故障文本类型存在数据不均衡的问题,采用了朴素随机过采样的 SMOTE 算法对不平衡数据进行少数类故障文本的重复随机采样,由此来生成了质量较好的少数类样本,使数据集的故障类别数量整体上达到了较为均衡的状态。

(2) 提出了针对铁路信号设备故障的短文本分类模型 (ERNIE_RCNN)。由于故障文本具有长度短、多歧义、特征稀疏等特点,采用了适合处理中文短文本的 ERNIE 和 TextRCNN 复合模型来对铁路信号设备故障进行分类诊断。通过实验证明,本文提出的 ERNIE_RCNN 模型在分类精确度上要明显高于其他深度学习模型。

(3) 构建起基于短文本分类结果和专家评价的数据融合技术的故障诊断模型。根据 ERNIE_RCNN 模型的精度输出和专家评价结果分别构造 D-S 证据理论的基本概率分配值,然后将短文本分类模型和专家评价后的故障诊断结果通过 D-S 证据理论在决策级进行数据融合,最后通过实例证明了融合结果的可靠性。

本文通过将预处理后各类别数量均衡的铁路信号设备故障文本,在故障短文本分类模型和根据 D-S 证据理论的数据融合技术来对铁路信号设备故障诊断。这种将历史经验和现场专家评价相结合的方法很适合处理具有很大不确定性的故障短文本,经过实验验证,两种方法都取得了很好的诊断效果,为铁路信号设备维护人员提供了决策的参考。

关键词: 铁路信号设备 故障诊断 短文本分类 数据融合

Abstract

Railway signal equipment is an important safety device of railway system, including power screen, track circuit, switch, signal machine and various control equipment. However, there are always various kinds of failures due to various internal or external reasons, such as poor quality of equipment, negligence or misoperation of staff and external environment. At present, the fault diagnosis of railway signal equipment mostly adopts the traditional manual troubleshooting and other methods, which requires experienced and responsible staff, and there is great uncertainty. A slight careless equipment failure may lead to accidents or losses and other adverse effects. Therefore, how to diagnose the fault of railway signal equipment accurately and timely according to the existing science and technology and equipment is a research hotspot now, and it is also a difficulty to diagnose the fault of railway signal equipment accurately with randomness, complexity and diversity. The main research contents of this paper are as follows:

(1) Establish railway signal equipment fault text data set. For railway signal equipment failure problems data imbalance of text type, the simple random sampling of SMOTE algorithm to a few classes of unbalanced data fault text repeated random sampling, a better quality of afterlife became a few samples from this, the number of fault category data set as

a whole achieves a relatively balanced state.

(2) A short text classification model for railway signal equipment faults (ERNIE_RCNN) is proposed. Because the fault text has the characteristics of short length, multiple ambiguity and sparse features, ERNIE and TextRCNN composite models which are suitable for Chinese short texts are adopted to classify and diagnose faults of railway signal equipment. Experiments show that ERNIE_RCNN model proposed in this paper is better than other deep learning models in classification accuracy.

(3) Build a fault diagnosis model based on short text classification results and expert evaluation. The accuracy output of ERNIE_RCNN model and expert evaluation results were used to construct the basic reliability allocation of D-S evidence theory, and then the short text classification model and expert evaluation fault diagnosis results were fused by D-S evidence theory at the decision level. Finally, an example was given to prove the high precision and reliability of fusion results.

In this paper, the railway signal equipment fault diagnosis is carried out on the basis of the fault short text classification model and the data fusion method based on D-S evidence theory. The method of combining historical experience and field expert evaluation is very suitable to deal with the fault text with great uncertainty. Through experimental verification, both methods have achieved good diagnosis effect, which provides a reference for decision making for auxiliary railway signal

equipment maintenance personnel.

Keywords: Railway signalling equipment; Fault diagnosis; Short text classification; Data fusion

目 录

1. 前言	1
1.1 研究背景和意义	1
1.2 铁路信号设备故障诊断研究现状	2
1.2.1 铁路信号设备概述	2
1.2.2 铁路信号设备故障概述	3
1.2.3 设备故障诊断研究现状	4
1.3 短文本分类研究现状	6
1.3.1 基于单一算法的短文本分类研究现状	6
1.3.2 基于组合算法的短文本分类研究现状	6
1.3.3 基于预训练语言模型的短文本分类研究现状	7
1.4 数据融合研究现状	8
1.4.1 数据融合概述	8
1.4.2 常用的数据融合方法	9
1.5 研究内容和创新点	11
1.5.1 研究内容	11
1.5.2 创新点	12
1.6 本章小结	12
2. 相关理论研究	14
2.1 短文本分类算法	14
2.1.1 TextCNN 模型	14
2.1.2 TextRNN 模型	16
2.1.3 TextRCNN 模型	17
2.1.4 Transformer	18
2.1.5 GPT 模型	20
2.1.6 BERT 模型	20
2.1.7 ERNIE 模型	22

2.2	D-S 证据理论	23
2.2.1	D-S 证据理论基本概念	24
2.2.2	Dempster 融合规则	25
2.2.3	D-S 证据理论一般步骤	26
2.3	本章小结	26
3.	基于短文本分类的铁路信号设备故障诊断	27
3.1	数据集构建	27
3.1.1	数据预处理	27
3.1.2	不平衡数据处理	28
3.1.3	铁路信号设备故障短文本数据集构建	30
3.2	构建基于 ERNIE_RCNN 的故障短文本分类模型	30
3.2.1	模型总体结构	30
3.2.2	ERNIE 层	31
3.2.3	TextRCNN 层	32
3.3	实验结果与分析	33
3.3.1	实验评价指标	33
3.3.2	实验环境及参数设置	34
3.3.3	实验结果对比分析	34
3.4	本章小结	35
4.	基于数据融合的铁路信号设备故障诊断	36
4.1	基于 D-S 证据理论的故障诊断	36
4.1.1	D-S 证据理论的识别框架	37
4.1.2	D-S 证据理论的基本概率分配 (BPA)	37
4.1.3	根据融合规则决策	39
4.2	基于数据融合的故障诊断实例 1	39
4.2.1	确定基本概率分配值	40
4.2.2	D-S 证据理论融合结果	41
4.2.3	故障诊断决策	42
4.3	基于数据融合的故障诊断实例 2	43

4.3.1 确定基本概率分配值.....	43
4.3.2 D-S 证据理论融合结果.....	44
4.3.3 故障诊断决策.....	45
4.4 本章小结.....	45
5. 总结与展望	46
5.1 工作总结.....	46
5.2 工作展望.....	46
参考文献	48
攻读硕士学位期间从事的科研工作及取得的成果	53
致谢	54

1. 前言

1.1 研究背景和意义

随着全球铁路市场的日益壮大和快速发展,这将给铁路这种运输方式带来大发展和大繁荣,但是铁路运输系统的许多不确定性可能会对这种快速发展构成巨大挑战^[1]。我国幅员辽阔、人口众多,而铁路能够在短时间内低成本运送大量乘客,因此铁路这种运输方式在我国非常受欢迎。近年来,我国已开发建造许多条新的高速铁路,并将许多现有铁路升级为高速铁路。如今,中国的火车最高行驶速度从 200 公里/小时提高到 380 公里/小时,飙升的速度引发了人们对高速列车安全性和可靠性的担忧。

与此同时,我国铁路系统围绕安全问题已形成了电务、运输、客运、货运、供电等专业的安全监控体系数十个,并形成了 PB 量级规模各类监测数据^[2]。铁路电务系统在铁路系统中发挥着重要作用,它通过地面信号、机车信号以及道岔设备来保证和维护列车的运行。电务段的主要工作是对信号设备进行维护,让其正常工作,并对转辙装置和道岔装置进行保护,以保证铁路系统正常运行。因此,保证铁路电务系统的正常运行对于铁路的安全运行有着至关重要的作用,铁路信号设备可以说是铁路电务系统中最关键的设施,它通过传递相关信息,对列车进行组织和指挥保证了列车的安全运行,同时改善了工作人员的劳动条件,提高了铁路运行效率^[3]。近年来,铁路信号设备在运营维护过程中积累了大量的故障数据,依靠人工进行分类对于人力、物力和财力的消耗非常庞大,而且大部分的铁路信号设备故障描述都用非结构化的文本来记录,具有很强的随机性,信号设备维护人员在诊断故障时对于经验和专家知识具有很强的依赖性,这种方式存在着由于沟通不畅、耽搁处理时间而导致危害行车安全、运输秩序和财产损失的隐患。

铁路信号设备故障文本通常是由维护工作人员根据自身的语言表达习惯和故障处理经验形成的文字记录,以经典的短文本形式涵盖了故障出现的起因、位置和时刻等价值较高的信息。同时,这些记载故障的文本具有非常庞大的数量,既有电子版的形式也有纸质版的形式,但是管理和维护信号设备的工作人员并没

有充分重视并妥善处理这些有利用价值的海量数据，数据未得到有效的利用也是一种资源的损失和浪费。

因此，通过本文对铁路信号设备的故障诊断具有以下几点重要意义：

- (1) 增强铁路工作人员应对突发故障的处置能力；
- (2) 最大限度地减少故障处理时间；
- (3) 充分利用历史经验数据和现场专家评价，提高故障诊断准确性。

综上，为减轻电务系统各级人员的工作量，高效率、智能化、自动化地管控铁路信号设备维护过程，本文提出了基于短文本分类和数据融合的铁路信号设备故障诊断，通过结合目前最先进的中文预训练语言模型 ERNIE 和擅长提取文本语义特征信息的 TextRCNN 模型，构造出 ERNIE_RCNN 模型，并在已有的铁路信号设备故障文本数据训练集上训练调参，通过在测试集上的实验表明，模型能够及时帮助管理人员尽快将新的故障文本数据准确分到对应的类别。与此同时，本文还使用了数据融合的方法，把短文本分类模型的输出和专家评价结论通过 D-S 证据理论相融合，这种方法将不同来源的信息进行整合，能够有效减少决策的不确定性，能显著提高铁路信号设备故障诊断结论的准确率和可信度。

通过本文的铁路信号设备故障诊断，能在第一时间根据故障描述确定其故障类别，协助工作人员迅速定位故障并给出处理建议，加快了维修速度，有利于减少故障导致的铁路事故隐患，确保出行安全。

1.2 铁路信号设备故障诊断研究现状

1.2.1 铁路信号设备概述

铁路信号设备归属于铁路电务部门管理，它是确保、监督和把控铁路列车在正常状态状态下运行的重要设备，通过信号设备可以充分地提高铁路运输的效率。铁路信号系统主要包括了列控系统、调度系统、联锁系统、信号集中监测系统以及隧道报警系统等在内的各种监控和保障整个铁路系统安全、正常平稳运行的信号设备^[4]。通过信号设备可以向铁路工作人员发出相关指令，按照规定的信号和符号指挥铁路行车、调车，使铁路系统整体的运行效率得到提升。

随着时代的发展，大数据技术在铁路运维管理中也得到应用。范东明等^[5]

实现了大数据监测铁路信号设备的应急处置工作，戚小玉等^[6]也在大数据平台下提出了铁路信号系统专业数据的可视化交互系统。并且，现如今铁路信号系统也实现了自动驾驶和智能运维等智能应用技术，这一复杂系统的迅速发展也代表着整个铁路系统正朝着现代化、自动化、智能化的方向不断前进。

1.2.2 铁路信号设备故障概述

铁路信号设备故障的概念主要是指设备的物理意义上的缺陷，这个设备由于某种原因有可能无法按规定完成对应的功能，当然也仍有可能能够勉强完成规定的功能，但存在着安全隐患。因为复杂多变的各种原因，设备都有可能由于元器件使用寿命、材质受损、制作工艺不良和外部环境等影响因素，而发生各种类型的故障。所以，铁路工作人员应该在实际工作时，依据不同的故障类别来采取相对应的故障诊断措施，以此来最大程度上消除故障产生的危害，保障铁路系统安全有序运行。因此，对铁路信号设备采用高效、准确的铁路信号设备故障分类方法，具有重要的现实意义。

铁路信号设备内部错综复杂，随着时代的发展，铁路信号系统变得更加智能化、自动化，可视化程度也正在加强，现在已经将计算机通信技术、信号处理技术等先进的方法同信号设备融合在了一起。但由于多种多样的原因，铁路信号设备出现故障也是无法避免的，主要存在以下四个原因：

(1)质量不合格。有时组成铁路信号设备的元器件质量没达到应该的标准，有可能会在使用了一定时间后老化引起设备的故障，有时生产工艺差或者超过了使用寿命也会导致这种情况。铁路信号设备与列车行驶安全问题紧密相关，因此也与人民群众生命健康息息相关，一定要引起充分重视，必须选择品质经得起考验的铁路运行基础设备。

(2)违章操作。铁路公司的各类管理细则和应急预案是在经历过惨痛的血的教训后形成的，因此铁路工作人员必须依据相应规定来从事相关工作，如果违反应有的操作规程，这样安全就成了一纸空话。

(3)维修不当。现场维修维护的工作人员缺乏相应专业的业务素质和技能知识，所以误操作也有可能造成设备故障，导致重大损失。还有一些技术人员缺乏较强担当和责任感，或者粗心大意低估了故障的风险，认为自己已经很熟悉工

作了，对铁路信号设备的日常例行检查大而化之，或是大意疏忽而造成故障没有被及时发现并预防对应的危害。

(4) 外界原因。信号设备大部分是暴露在室外的，所以外界环境也会对其产生很大的影响，例如线路异物这个故障，常常是由于鸟或小狗等动物跑进去而造成的线路异物故障，当然有时也有施工工人或是不法分子的恶意操作造成故障。

通过如今现有的研究及文献，按照不同的铁路信号设备故障分类标准，通常可以将铁路信号设备故障分为以下类别。

(1) 按照铁路信号设备故障发生的原因可以分为：工作人员操作有误或未尽到应有的责任义务的人为故障（如线路晃车、机车空转等）和铁路信号设备质量不合格导致的非人为故障（如道岔故障、电源屏故障、信号机故障等）。

(2) 按照故障的显示形式可以分为：肉眼能轻易发现和排查的显性故障（如线路异物、接触网异物、机车主断跳闸等）和需要通过依靠检测和丰富经验才能察觉的隐蔽性故障（如接触网网压波动、机车空转等）。

(3) 按照故障发生的地点范围可以分为：发生在室内的故障（如电源屏故障等），和发生在户外的室外故障（如线路异物、接触网异物、道岔故障、线路晃车、信号机故障等）。

(4) 按照信号设备故障的状态可以分为：设备寿命到期老化和电路接触不良的断路故障和设备绝缘性丢失的短路故障。

(5) 按照故障的数量可以分为：某一个零部件且容易发现的单一设备故障，和整个电路系统或大型设备内部错综复杂的、难以寻找原因的多重故障，这种故障通常是由于旧设备的元器件老化，同时并发故障的风险也很高。

1.2.3 设备故障诊断研究现状

随着铁路系统管理人员维护意识的提高，专家学者们开始致力于设备的故障诊断研究，许多算法和理论都开始在铁路信号设备故障诊断中得以实现，但是铁路信号设备故障诊断的传统方法不仅工作量大，而且遗漏率和出错率也高，直接会对设备维护和铁路系统运行效率产生不良影响。

(1) 基于人工智能的故障诊断。随着铁路信号设备故障数据的日积月累，如今已经基本进入了智能型诊断的故障诊断阶段，许多研究人员开始从人工智能

领域研究探讨故障诊断的方式方法,例如采用机器学习算法或深度学习算法来进行辅助故障诊断。刘富钱^[7]根据不同的铁路信号设备故障的了解研究,提出了人工智能、人工神经网络分析法等故障诊断方法,以期实现铁路信号设备故障诊断的稳定高效,保障其能够稳定的工作。赵阳等^[8]针对具有极强不确定性的故障文本记录,采用主题模型提取文本特征,同时使用贝叶斯网络进行故障分类,有效克服了铁路信号车载设备故障诊断不确定性的问题。周庆华^[9]等提出了使用 Word2Vec+MCNN 复合模型来进行铁路信号设备故障分类的文本挖掘方法,与传统分类器和多池化卷积神经网络相比,此模型的分类精度更高,效果更好。杨连报^[10]根据铁路故障文本中的故障名称、位置、时刻、缘故和故障处理方式等关键信息难以提取的问题,组建了 Bi-LSTM+CRF 的复合模型来进行铁路事故故障文本特征提取。同样,数据挖掘的方法对于分析铁路信号设备故障也值得借鉴,数据挖掘能从纷繁复杂的数据中发现一些隐含的规律,来展示数据的特征从而预判事件发展的方向,最后为管理人员提供参考决策。李晓丽^[11]就运用文本挖掘技术分析海量的铁路领域相关文本数据,建立起铁路领域专业分词词典,并采用 CNN 和 attention 机制来完成文本分类任务,获得了较高的故障诊断精度。

(2) 基于专家系统的故障诊断。也有学者采用专家系统的方式进行,专家是指在某一领域的一批具有专业知识、技能和丰富经验的专业人士。铁路信号的专家系统通过综合专家知识、并根据专业知识对铁路信号故障进行分析和诊断而构成。孙旻^[12]通过构建专家智能化系统,以实时地捕捉、分析和报告铁路信号设备状态和故障,运用专家知识库对其进行故障分析与诊断,并提高维护的服务质量。王兰勇^[13]将铁路信号设备常见的故障诊断方法归纳为一个大型知识库,开发出智能故障诊断软件,确保了故障诊断的准确性和效率。袁杰等^[14]采用 D-S 证据理论将数个专家系统的结论综合,充分利用了能够获取的信息,也增强了不确定性系统故障诊断的准确性。

(3) 基于数据融合的故障诊断。数据融合方法也常用于故障诊断,学者们将数据融合应用于故障诊断主要是由于设备故障成因复杂,故障种类繁多,且诊断系统内部存在着多种噪音和误差,因此带有许多不确定性,而数据融合技术能够将多个来源的信息综合利用,充分降低结果的不确定性,对设备故障做出准确的诊断。譬如李娜^[15]采用数据融合的方法,在决策级融合 BP 神经网络输出和模

糊综合评判结果,成功实现了对户外信号设备的故障诊断,取得了较为精确的诊断结果。林水生等^[16]根据决策级的数据融合技术 D-S 证据理论将多源判别信息进行融合,提出了信号火灾的探测方法,能够提升火灾探测的及时性。

通过对以上学者们在铁路信号设备故障诊断研究的工作综述,可以发现基于人工智能技术、专家系统和数据融合技术的铁路信号设备故障诊断方法和理论已经发展得较为全面、先进和系统,可以更好地为铁路行车安全提供理论支撑和决策支持。

1.3 短文本分类研究现状

1.3.1 基于单一算法的短文本分类研究现状

随着人工智能技术的发展,短文本分类方法逐渐从传统的手工提取特征,并利用机器学习算法构建各种分类器,转变为采用深度学习算法来高效地提取特征并分类,这些分类方法大都应用了卷积神经网络(CNN)、循环神经网络(RNN)和注意力机制(attention mechanism)等深度学习技术,并且收获了比传统方法更令人惊艳的效果。Kim^[17]利用 word2vec 获得文本词向量后,加上一层卷积以提取重要特征信息,通过卷积神经网络得到分类结果,证明了无监督的词向量预训练是自然语言处理深度学习的重要组成部分。Lai^[18]引入循环卷积神经网络用于文本分类,应用循环结构来尽可能多地提取上下文信息,使用了一个最大池层,对于哪些单词在文本分类中起着决定性作用可以自动识别,因此模型可以充分获取文本中的关键成分。Johnson^[19]等采用的文本分类体系结构是一种复杂度较低、能够充分表达文本中的远距离关联性的词级深度卷积神经网络,在不增加过多计算成本的前提下增加网络的深度,可以获得较好的准确性,称之为深度金字塔 CNN。随着这些深度学习算法的兴起,逐渐攻克了浅层算法的表示能力有限等问题,但是对单一的深度学习算法做进一步地改进,可以在短文本分类任务中取得更令人惊艳的效果,例如融合多种方法来改进模型以获得更高的分类准确率。

1.3.2 基于组合算法的短文本分类研究现状

为了进一步提高深度学习模型的分类精度,一些学者通过多种模型的集成,

取长补短，有效地提高了模型在短文本分类任务上的性能。侯雪亮等^[20]通过提取关键词重新构造文本特征，将 FastText 和 TextCNN 的特性优势结合，输入到多神经网络模型中，通过融合类别向量，从而获得了优越的算法性能。冯勇等^[21]融合 TF-IDF 和 LDA 模型，用 TF-IDF 筛选词典，LDA 模型分析语料库主题以补充特征词典，使其在 FastText 模型上进行短文本分类，从而在计算输入词序列向量均值时偏向高区分度的词条，使其更适用于中文短文本分类环境。韩众和等^[22]通过融合卷积神经网络和极速学习机形成 CNN-ELM 混合模型，用于提取出更具代表性的短文本特征，有效提高了实验结果的精确率。Xu 等^[23]提出了一种名为 DE-CNN 的神经网络，用于短文本分类，它通过卷积神经网络提取前后文语义信息，然后利用注意层提取与前后文有关的语义，再将这些语义整合到文本表示中进行短文本分类。

1.3.3 基于预训练语言模型的短文本分类研究现状

随着 BERT 等预训练语言模型的兴起，大量的学者开始关注通过此类模型的组合算法来提取文本特征，获得了更高的分类准确度。付静^[24]等针对短文本的特征稀疏和语义模糊等问题，提出使用 BERT_LDA 复合模型用于短文本分类，模型通过 BERT 提取全局语义信息，LDA 扩展短文本特征表示，获得了较高的 F 值。同样，雷景生^[25]等利用 ERNIE_BiGRU 模型，在保留文本前后文信息的同时增强了字的语义补充，在新闻文本分类中表现出了良好的性能。牛玉婷^[26]等也提出了改进的 ERNIE_DPCNN 模型，使用 ERNIE 随机遮蔽部分字、短语和实体语义单元，并将在 ERNIE 层得到的词向量输入到 DPCNN 层中，实验证明了改进模型的准确率、精确率、召回率和运行时间均取得了满意的效果。根据前人的研究表明，BERT 和 ERNIE 等预训练语言模型可以利用其中的自注意机制充分提取文本和词的特征，从而有效挖掘短文本的语义信息，使得短文本分类的准确率得到有效提高。

根据上述研究综述可以看出，基于复合模型的短文本分类方法对于文本的特征提取和核心文本语义信息表达更加全面。并且，由于新兴的 BERT 等类似的预训练模型可以更加高效完整地提取短文本的上下文特征，并表示为词向量后经过微调即可送入下一模型来进一步提取文本语义信息，这避免了复杂的特征工程。

因此,在实际应用中,基于预训练模型的组合深度学习模型也会具有更高的分类准确率。综上所述,本文将考虑构建基于预训练语言模型的深度学习组合模型来完成铁路信号设备的故障短文本分类任务。

1.4 数据融合研究现状

1.4.1 数据融合概述

数据融合,也称为信息融合,指的是在一定条件下将来自多个数据源的数据进行综合、分析,以实现完成决策和评估等任务。数据融合技术首先在军事行动中使用,来对军事目标进行检测、识别、定位和跟踪。如今,数据融合技术不止局限于军事领域,通过学者们研究出的各种先进的技术,数据融合技术已经在日常生活和工作中得到了较快的发展。

近年来,研究者们通过改进数据融合技术或结合先进技术,可以实现高效地融合从多个单一信息源提取的数据,从而提高管理决策的全面性和准确性。例如,Hu 等^[27]通过提出改进的数据融合方法,建立起经验反馈机制的推理过程,以权重形式反馈给新一轮融合过程进而提高了预测的精度。路军等^[28]证明了根据朴素贝叶斯和 D-S 证据理论的数据融合方法,能够有效地提升利用多源数据来决策的正确率。万继宏等^[29]也构建了改进算法来对多传感器多目标识别,实验结果表明此数据融合算法明显提高了决策结论的精度。Wickramaratne 等^[30]描述了一个基于 Dempster-Shafer(DS)信念理论方法的软数据和硬数据融合框架,该框架非常适合于捕获更典型的软数据的模型类型和不确定规则,解决了为融合软数据和硬数据的理论合理性和计算效率框架奠定基础的问题。

并且,数据融合技术也常被用于各类故障诊断决策中,乔增乾^[31]就针对铁路货车滚动轴承故障,设计了根据神经网络和证据理论的数据融合故障诊断系统,提取了三类特征指标构造多源证据体,D-S 证据理论的基本概率指派即为神经网络诊断准确率的输出,最终诊断准确率达到了一百。田亮等^[32]也提出了一种根据证据与每个目标样本间的汉明距离来获取信度函数的方法,可以较为准确地判别故障类型并做出早期诊断故障预测。刘晓光等^[33]根据 D-S 证据理论处理不确定问题的推理思路,提高了灾害诊断决策支持方法的自学习性和可信度。王

奉涛等^[34]提出了一种依据 Dempster-Shafer 证据理论的多故障特征数据融合的故障诊断方法，增加了最终诊断决策的准确率和可靠性。

数据融合有三个不同的抽象层次，为数据级、特征级和决策级融合，分别融合原始数据、提取的特征信息和评估的局部决策信息。数据融合还有高低两种层次，决策级融合属于高层次的融合，具有通信量小、抗干扰能力强等优点。在低层次融合中最低级的融合是数据级融合，它通过融合直接观测到的传感器数据，并从融合的结果中提取信息特征和判断决策，使其损失较少的数据量。数据级融合能够提供其他融合层无法提供的细枝末节信息，具有较高的精确率，但与决策级融合相比，有着融合时间长、抗干扰性差等局限。特征级融合是对特征向量进行融合处理，压缩数据的过程，能提高图像的实时性，但是由于压缩过程中一些重要信息的丢失，将会导致图像的融合性能下降。

最后，属于高层次融合中的决策级融合，如图 1.1 所示。决策级融合先对数据进行局部决策，再在融合中心进行融合决策。由于在融合过程中会造成较大的数据丢失，所以其融合的准确率会降低，但是其有着通信量小，对传感器的依赖程度小，抗干扰能力强等优点。其中，决策级数据融合主要采用贝叶斯推断和 D-S 证据理论等方法。

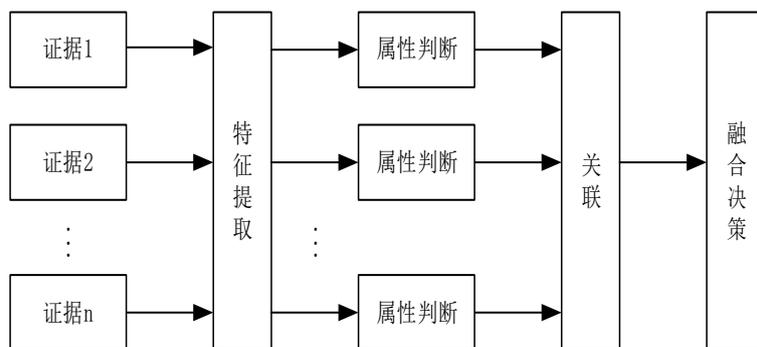


图 1.1 决策级融合

1.4.2 常用的数据融合方法

数据融合是一个综合处理多源信息的过程，复杂性较大，使用的数据融合方法要依照具体应用来确定。近些年来，数据融合技术不断发展，根据不同抽象层

次有如表 1.1 所示的几种常用数据融合方法。

表 1.1 常用的数据融合方法

数据融合方法	运行环境	信息表示	融合技术	适用范围
加权平均	动态	原始读数值	加权平均	低层数据融合
卡尔曼滤波	动态	概率分布	系统模型滤波	低层数据融合
贝叶斯估计	静态	概率分布	贝叶斯估计	高层数据融合
统计决策理论	静态	概率分布	极值决策	高层数据融合
证据推理	静态	命题	逻辑推理	高层数据融合
模糊推理	静态	命题	逻辑推理	高层数据融合
神经网络	动/静态	神经元输入	神经网络	低/高层
产生式规则	动/静态	命题	逻辑推理	高层数据融合

由于铁路信号设备故障可采用短文本分类模型和专家评价这两种单一的方法进行分别诊断做出决策，且铁路信号设备故障的描述采用的是命题的方式，因此在选用数据融合方法时可以选用静态的运行环境，通过提取来自短文本分类模型和专家评价两种信息源的数据分别作为两条证据信息，进行数据融合。而且，D-S 证据理论对于故障诊断这类具有不确定性的问题处理具有很大的优势。因此，本文考虑采用在静态运行环境中进行逻辑推理和决策级融合的 D-S 证据理论，进行铁路信号设备故障诊断决策。

但是，D-S 证据理论作为典型的决策级的数据融合技术，在实践时仍然存在有待改善的空间，例如：如何确定各类信息源的基本概率分配值（BPA）以及如何解决证据冲突的问题等。Zhong 等^[35]提出了一种测定 BPA 的新方法，以缓解不同属性的 BPA 之间的冲突，从而避免产生违反直觉的结果。贾韧锋^[36]曾提到可以根据 m 位专家给出的评价，判断出目标发生的几率并进行相应的处理，即可得到证据的基本概率赋值。当证据间存在高度的冲突时，章巍^[37]通过采用改进 D-S 证据理论的数据融合方法，有效地解决了 D-S 证据理论中的证据冲突问题。杨晓萍等^[38]采用 Pignistic 概率函数和加权证据组合方法，来解决高冲突证据组合问题。宋香鹏等^[39]依据斯皮尔曼等级相关系数的证据合成方法，使得

改进后的算法目标辨识度得到很大提升,计算过程简便了许多,拓宽了适用范围,能够较好地处理证据间的高度冲突问题。

通过上述研究表明,基于 D-S 证据理论的数据融合技术可以有效地综合来自多个信息源的数据并合理地融合存在冲突的证据,为故障诊断等类似不确定性决策提供充分的理论基础。

1.5 研究内容和创新点

1.5.1 研究内容

根据前文的研究现状表明,采用模型集成的方法进行短文本分类对于铁路信号设备故障分类具有一定的借鉴作用,并且通过 D-S 证据理论进行数据融合的方法,能够有效地克服铁路信号设备故障文本记录的不确定性、随机性和复杂性。

因此,本文的主要研究工作是:

(1) 数据集的获取和处理。本文的原始数据来自铁路公司历史记录中的铁路信号设备故障文本库,但由于不同故障类型发生故障的次数相差较大,记载的各类故障文本数据的数量很不均衡。因此,采用 SMOTE 算法合成数量较少的部分类别样本,解决了数据类别不平衡的问题,有助于提高下一步故障诊断实验效果。

(2) 短文本分类模型构建。鉴于深度学习算法在短文本分类领域中的优越性能,本文分别结合中文预训练语言模型 ERNIE 和擅长提取文本语义特征信息的 TextRCNN 模型,提出了改进的 ERNIE_RCNN 模型来进行铁路信号设备故障短文本的分类,与其他模型进行对比实验,结果表明,本文提出的模型具有最好的分类效果。

(3) 采用数据融合的方法进行铁路信号设备故障诊断。选取 D-S 证据理论把短文本分类模型的精度输出和现场专家评价结果进行决策级数据融合,使得诊断结果更具可靠性。本文通过以上方法成功将历史诊断数据与现场专家评价诊断数据这两种不同来源的证据进行组合,大大降低了现实中故障诊断的不确定性,进而能够精确地诊断铁路信号设备的故障类型。通过自然语言处理中成熟的短文本分类算法,并结合擅长处理不确定信息的 D-S 证据理论,提高了铁路信号设

备故障诊断的准确性，并降低了诊断决策的不确定性，辅助铁路工作人员更加准确、快速地找到故障原因，及时恢复行车，保障通车效率。

本文的主要研究内容和组织框架如下图 1.2 所示。

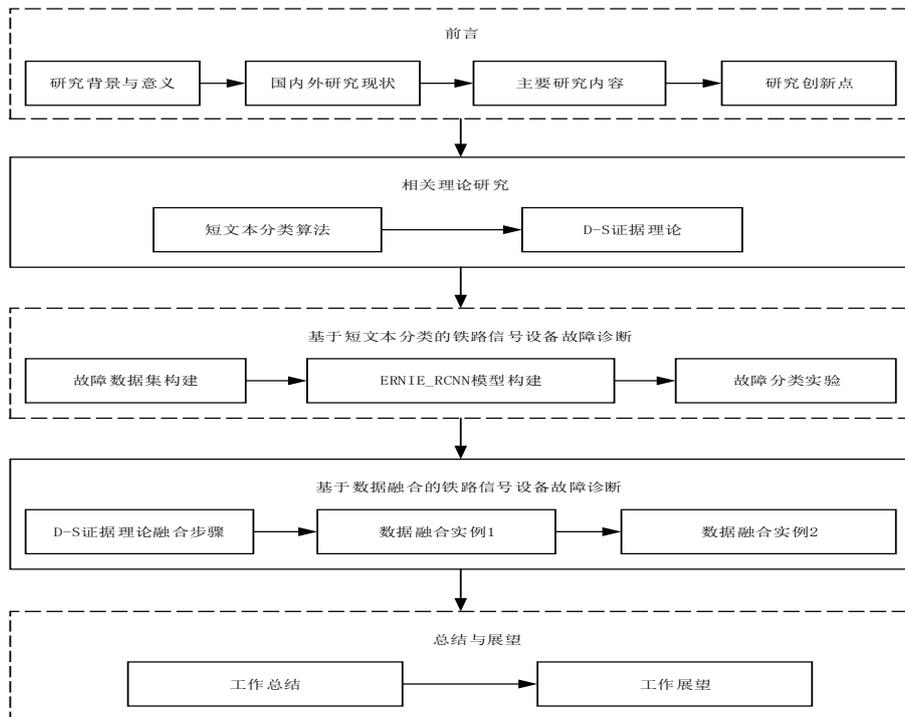


图 1.2 研究组织结构

1.5.2 创新点

(1) 将短文本分类模型应用于铁路信号设备故障诊断领域。通过集成两种先进的深度学习模型 ERNIE 和 TextRCNN，实现了铁路信号设备故障的自动分类，有利于提高铁路信号设备故障诊断的处理效率。

(2) 采用 D-S 证据理论将两类不同来源的证据信息在决策级进行数据融合，实现了短文本分类和现场专家评价这两类单一的故障诊断方法的证据组合，提高了铁路信号设备故障诊断决策的准确性和可信度。

1.6 本章小结

首先，本章阐明了对铁路信号设备故障诊断进行研究的背景与意义；然后对

前人在铁路信号设备故障诊断领域、短文本分类领域以及数据融合领域等所做的研究工作进行了总结,有助于为下一步故障短文本分类模型构建和数据融合找准切入点和着力点,提供研究的思路和依据;最后总结了文章的主要研究内容和创新点。

2. 相关理论研究

2.1 短文本分类算法

近年来,在完成短文本分类任务时最常使用的就是基于深度学习模型的方法,本章将对本文在短文本分类时参考的理论基础进行分别阐述,包括卷积神经网络模型(TextCNN),循环神经网络模型(TextRNN),循环卷积神经网络模型(TextRCNN),Transformer, GPT、BERT 和 ERNIE 等预训练模型。

2.1.1 TextCNN 模型

在自然语言处理中,传统的基于特征的模型不能为短文本分类提供足够的统计信息来达到更好的性能,而通过使用深度学习中的神经语言模型,可以让大部分工作通过该模型学习单词向量表示,并合成这些单词向量加以进行分类。卷积神经网络(CNN)最初是为计算机视觉而发明的,它使用层层卷积滤波器来提取局部特征。后来随着 CNN 的应用,在实践中证明,在自然语言处理任务中,CNN 同样可以取得引人注目的效果^[40]。

卷积神经网络是一种具有卷积计算和深度结构的前馈神经网络,如图 2.1 所示,其主要结构包含卷积层、池化层和分类层,可以依照相应的应用需求来确定每层的位置、层次次序和大小结构。在卷积层中,每个神经元都连接到相邻层中的部分神经元。卷积层可由多个特征平面组成,而特征平面由一些长方形排列的神经元组成,卷积核就是这些神经元在同一特征面中所分担的权值。在卷积层中,CNN 得到数据特征并在池化层使用下采样的方法,对特征和信息进行选择 and 过滤,这样在求取特征的平均值、最大值时可以使用聚合不同位置的特征的方法进行计算,这种处理就是池化。经过池化后的数据冗余信息降低,运算效率也会提高。最后,卷积神经网络会经过全连接层再输出,因此全连接层相当于卷积神经网络的分类器,通常使用 softmax 函数输出分类标签,这在卷积神经网络中起着关键作用。

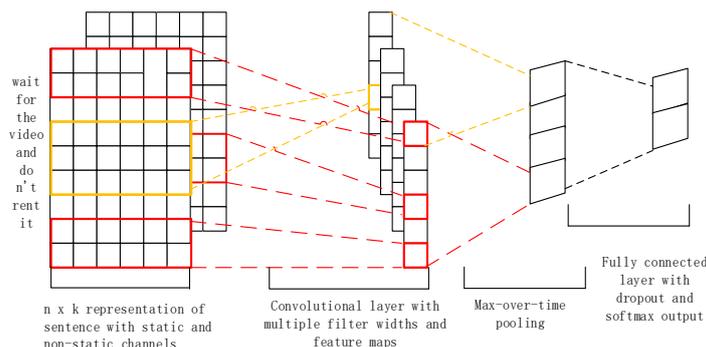


图 2.1 TextCNN 模型结构

图中的模型架构是为适应文本分类而对 CNN 架构做了一个轻微调整的变体。让 $x_i \in \mathbb{R}^k$ 是对应于句子中第 i 个单词的 k 维单词向量。长度为 n 的句子（必要时加长）表示为 $x_{1:n} = x_1 \oplus x_2 \oplus \dots \oplus x_n$ ， \oplus 是连接运算符。卷积运算涉及滤波器 $w \in \mathbb{R}^{hk}$ ，应用于 h 个字的窗口以产生新特征。然后，模型在特征映射上应用最大池化操作，并将最大值 $\hat{c} = \max\{C\}$ 作为对应于该特定过滤器的特征。池化层可以捕获文本最关键的特征，每个特征映射的值最高，这种池化方案可以对可变的句子长度进行处理。该模型通过多个不同大小的窗口来获取多个特征。这些特征形成倒数第二层，并传递给完全连接的 softmax 层，最后该层输出标签上的概率分布。

换句话说，CNN 的卷积层可以从短文本中捕捉到不同滤波器大小的不同类型的特征，并将它们转移到池化层，然后，根据最大池化层可以从短文本中提取出最重要和最具代表性的特征，来对短文本进行充分有效地表达。因此，CNN 在数据集上的短文本分类性能优于传统的基于特征的方法。

卷积神经网络模型与其他模型相比，虽然所有随机初始化单词的基线模型本身表现不佳，但将预先训练后的向量作为特征提取器后，最后的性能会得到很大幅度的提高。即使是一个带有静态向量的简单模型，其得到的结果也可以与更复杂的深度学习模型相媲美。这意味着即使在只有一层卷积的情况下，无监督的预训练向量也可以获得更好的文本分类效果，这预示着往后的自然语言处理任务均可先进行预训练模型的特征提取来达到更好的精度。

2.1.2 TextRNN 模型

循环神经网络（RNN）能够通过对输入序列的内部隐藏状态向量 h_t 递归，应用转移函数来处理任意长度的序列^[41]。RNN使用的训练算法和前馈神经网络（BP算法）原理相似，都是先前向计算每个神经元的输出值，再反向计算每个神经元的误差项值，它是误差函数对神经元的加权输入的偏导数，最后对权重进行梯度计算，将得到的结果通过随机梯度下降法对权重进行更新。

因为渐变消失问题，双向 RNN 在访问上下文信息的过去和未来范围时受到限制，因此研究人员开发了一种循环神经网络变体：长短时记忆神经网络（LSTM），LSTM 更擅长解决学习长期依赖的问题，其内部存在一个单独的存储单元，仅在必要时更新和公开其内容。LSTM 的自适应门机制可以有效克服梯度消失问题，该机制由 4 个部分组成：输入门（ i_t ）相应的权重矩阵 W_{xi} 、 W_{hi} 、 W_{ci} 、 b_i 、遗忘门（ f_t ）对应权重矩阵 W_{xf} 、 W_{hf} 、 W_{cf} 、 b_f 、输出门（ O_t ）相应权重矩阵 W_{xo} 、 W_{ho} 、 W_{co} 、 b_o 以及决定是否输入/遗忘/存储/输出的门，所有这些门都被设置为使用当前输入 x_i 、上一步生成的状态 h_{t-1} 和该单元的当前状态 C_{i-1} 来生成一些节点状态，以决定是否接受输入、遗忘先前储存的记忆以及输出稍后生成的状态。同样，LSTM 采用了 dropout 来防止模型过拟合。

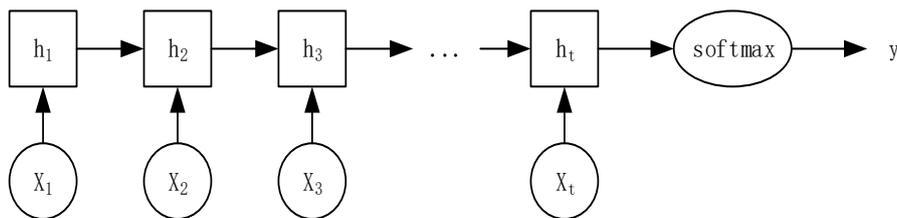


图 2.2 TextRNN 模型结构

模型结构如图 2.2 所示，通过输入被设置或填充成同样字数的文本，可以在嵌入层中对文本进行随机初始化，还可以在嵌入层中加载文本的预训练词向量，词向量的维度为嵌入尺寸(embed_size)；所有的隐层状态都是经过双向长短时记忆神经网络将前后向隐层连接在一起得到的，其中隐层的大小是隐藏尺寸(hidden_size)；然后通过全连接层得到预测的类的个数，再用 softmax 函数进行

归一化操作，以该类中的有着最大个数的类作为预测的最终结果。LSTM 对捕获长距离语义关系有着较好的效果，但由于它的递归结构问题，无法进行并行计算，导致分类运行速度慢。

2.1.3 TextRCNN 模型

循环卷积神经网络（RCNN）在进行文本分类时不需要人为设计特征，在模型中，当学习单词表示时，应用循环结构来尽可能多地捕获上下文信息，而这可以避免大部分噪声^[42]。然后，通过一个最大池化层可以自动识别在文本分类中起关键作用的词语，进而获取文本中的重要成分。

模型如图 2.3 中所示，首先使用双向循环神经网络的结构来捕获上下文语义信息。定义 $C_l(W_i)$ 为单词 W_i 的左语境，定义 $C_r(W_i)$ 为单词 W_i 的右语境。单词 W_i 的左侧上下文 $C_l(W_i)$ 使用等式(2-1)计算，其中 $C_l(W_{i-1})$ 是一个向量，它用来表示 W_{i-1} 的左侧上下文。 W^l 是一个矩阵，它可以将前后两个隐藏层的上下文进行转换。 $C_l(W_1)$ 是一个共享参数，作用于所有文档中第一个单词的左侧上下文。 W^{sl} 是用来连接前后两个单词语义的一个矩阵。

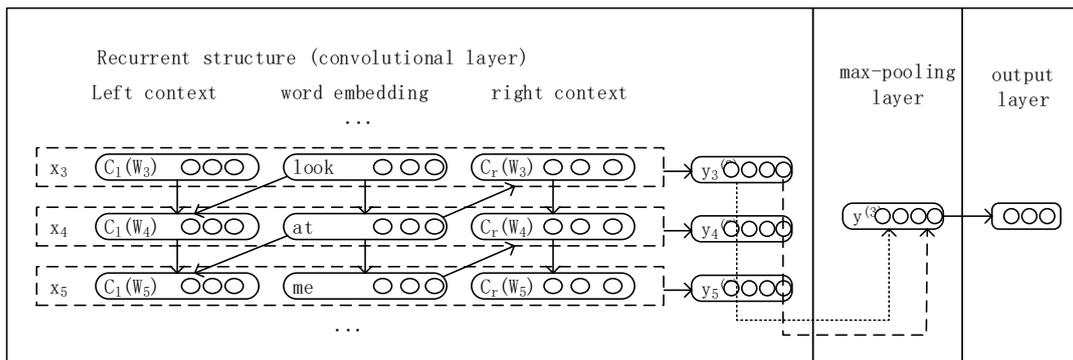


图 2.3 TextRCNN 模型结构

$e(W_{i-1})$ 是单词 W_{i-1} 的单词嵌入， W_{i-1} 是具有 $|e|$ 实值元素的密集向量。 f 是非线性激活函数。右侧上下文 $C_r(W_i)$ 以类似的方式计算，如等式(2-2)所示。文档中最后一个单词的右侧上下文共享参数是 $C_r W_n$ 。

$$C_l(W_i) = f(W^l C_l(W_{i-1}) + W^{sl} e(W_{i-1})) \tag{2-1}$$

$$C_r(W_i) = f(W^r C_r(W_{i+1}) + W^{sr} e(W_{i+1})) \quad (2-2)$$

在等式(2-3)中定义单词的表示,它是左侧上下文向量 $C_l(W_i)$ 、单词嵌入 $e(W_i)$ 和右侧上下文向量 $C_r(W_i)$ 的连接。以这种方式,与仅使用固定窗口的传统神经模型(即仅使用关于文本的部分信息)相比,使用这种上下文信息,可以更好地消除单词含义的歧义^[43]。

$$X_i = [C_l(W_i); e(W_i); C_r(W_i)] \quad (2-3)$$

循环结构可以获得文本的前向扫描和后向扫描,卷积神经网络用来表示文本,从卷积神经网络的角度来看,循环结构就是卷积层。时间复杂度为 $O(n)$ 。当得到单词 W_i 的表示后,应用线性变换和 \tanh 激活函数将结果输出到下一层。

$$y_i^{(2)} = \tanh(W^{(2)} X_i + b^{(2)}) \quad (2-4)$$

$y_i^{(2)}$ 表示语义向量,这种潜在的语义向量将一个个语义因素进行解析,最后确定出最重要的因素来表示文本。接着模型使用了一个最大池化层 $y^{(3)} = \max y_i^{(2)}$,它自动判断哪些单词在文本分类中起关键作用,以捕获文本中的关键成分。模型的最后一部分是输出层。类似于传统的神经网络 $y^{(4)} = W^{(4)} y^{(3)} + b^{(4)}$,最后,将 softmax 函数应用于 $y^{(4)}$,将输出数字转换成概率 $p_i = \frac{\exp(y_i^{(4)})}{\sum_{k=1}^n \exp(y_k^{(4)})}$ 。

使用神经网络的方法能够更有效地综合文本的语义表示,可以比使用 BoW 模型的方法受到更小的数据稀疏问题的影响,从而使其能够捕捉到更多的上下文信息特征^[44]。同时卷积框架方法比以往的神经网络方法更适用文本的语义表示。实践证明 CNN 在卷积层捕获上下文的信息,并在最大池层有着更多有区别的特征选取是其主要原因,与 CNN 相比,我们发现 RCNN 在所有情况下的表现都比 CNN 的表现要好,实验表明这是因为循环神经网络的递归结构比基于窗口的结构能更好地捕获上下文信息。

2.1.4 Transformer

Transformer 作为一个简单的网络结构,是首次提出的完全基于注意力机制的序列转换模型,其用多头自注意机制代替了编码器-解码器结构中被广泛使用的循环层,不需要重复和卷积结构,克服了 RNN 训练时间长速度慢的弊端,通

过自注意力机制达到快速并行，训练时间显著减少^[45]。并且 Transformer 可以增加非常深的深度，以深入探索 DNN 模型的性能和特点，从而提高模型训练的准确性。

Transformer 的模型结构如图 2.4 所示，对于一个编码器而言，它由若干个层数相同的层组合构成。它包含了多个子编码器，同时每一层都包括两个子层。一层是多头的自我关注机制，另一层是一个依赖于位置与前馈网络全部连接的简单层。除了完全连接外，两个子层的每个子层周围会使用剩余连接，之后会将这些子层变得更为规范和标准。与此同时为了方便每个子层周围的连接，所有子层都要输出维度数为 512 的维度。类似地，解码器与编码器的组成相似，也是由若干个层数相同的层组合构成，但是与编码器不同的是解码器的编码层存在着第三个子层，这一层是多头关注编码器输出的机制。第三层的周围每个子层的连接方式与编码器的两个子层的连接方式是一样的，也将这些子层变得规范和标准。同时，修改解码器堆栈中的自我关注子层，以避免影响后续位置。

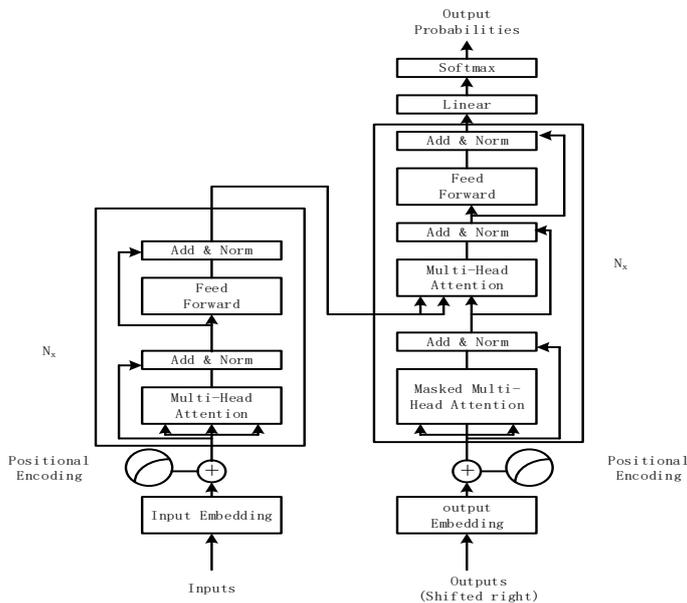


图 2.4 Transformer 的模型结构图

因为 Transformer 模型没有循环和卷积结构，所以在编码器和解码器堆栈底部的输入嵌入中添加了“位置编码”来标记位置信息。另外模型使用了自注意机制，使得模型每层的计算复杂度显著降低，且实现了并行化计算，也解决了长距

离依赖的问题。

2.1.5 GPT 模型

单从模型结构上来看,如图 2.5 所示,GPT 和 Transformer 的解码器结构几乎一模一样,只是它去了解码器中的一个多头自注意模块。GPT 模型最大的特点就是采用了 Transformer 的解码器来提取文本的语义特征,可以捕捉更长距离的语义信息,同时计算速度也比循环神经网络快,易于并行化,因此在执行文本分类任务时获得了令人惊艳的效果。但与 BERT 模型相比,不足之处在于它只参考前文信息来预测单词,而不考虑后文的语义信息,即是一个单向的预训练语言模型。

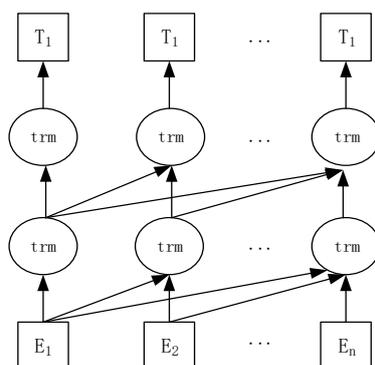


图 2.5 GPT 模型结构

GPT 包括预训练和微调两个阶段。在预训练阶段主要是无监督学习,通过不带标签的语料库来预训练语言模型,采用 Transformer 作为特征提取器,同时每步只需考虑左侧的上下文语义信息来进行推断;接着,在有监督学习的微调阶段,直接选取最后一层 Transformer 最后一个时间步的输出向量,然后在其后面接一层 softmax 全连接层,即可得到最后的预测标签概率。GPT 模型经过微调可以在有监督的自然语言处理任务上进行迁移学习,并且在庞大的监督语料时,以无监督学习方式学习文本的表示也使性能得到了显著提升^[46]。

2.1.6 BERT 模型

2018 年 Google 发布的 BERT(来自 Transformers 的双向编码器表示)预训练模

型，在自然语言处理发展史上具有里程碑式的意义。BERT 模型与 Word2Vec 等模型不一样的是，Word2Vec 模型的目标是获得单个词的语义信息，而 BERT 作用于获得整个文本的语义信息，将其综合起来进行表示，并且还能够直接微调文本的语义表示，然后应用在具体的 NLP 任务中^[47]。作为新兴的预训练语言模型，不同于 GPT 采用 Transformer 的解码器结构，BERT 是通过 Transformer 的编码器模块构建的，将 ELMo 和 GPT 二者的优点完美结合：能够同时提取上下文的文本信息和通过多个 Transformer 编码器完成特征提取任务。

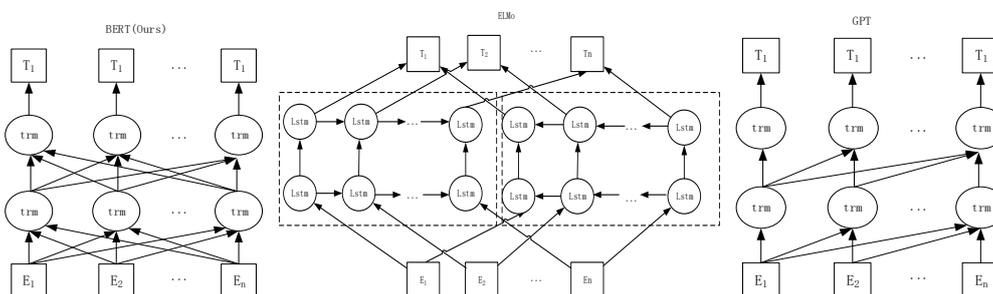


图 2.6 BERT、ELMo、GPT 模型对比图

从图 2.6 也可以看出，ELMo 使用的是双向长短时记忆网络作为语言模型进行预训练，GPT 是采用单向的 Transformer 预训练模型，而 BERT 模型博采众长，采用了双向的 Transformer 在预训练时提取文本特征，使得模型既能够同时捕捉到前后文的语义信息，又提高了模型提取特征的能力。

BERT 在对模型进行训练之前，先对文本进行分词操作；此时 BERT 预训练语言模型的输入中，已经包含了文本中的单词本身信息、每句的单词前后顺序信息和句子的先后信息；然后随机将 15% 的单词遮掉，再在其中选择 80% 的单词 Mask 掉，10% 的时间采用随机单词替换，10% 的时间保持单词不变；再然后在进行 Embedding 操作后送入 Transformer 层提取语义信息；最后对 Transformer 的输出进行归一化后输出最终预测的结果。

同时，BERT 还会随机屏蔽语句里面部分比例的单词，并预测所有被屏蔽的词汇，而且，BERT 能够预测两个句子是否相邻，来建立二者间的关联关系，这是传统语言模型所无法捕捉到的。它通过 masked 语言模型来进行对预训练的深度双向表示，仅仅需要一个额外的输出层，就能够实现对预先训练好的 BERT 模

型加以微调，来为各种任务(如翻译和分类)建立了最先进的模型，而不用在特定任务时再对结构做出重大调整。因此，这种特殊的预处理方案有助于 BERT 在各种关键的自然语言处理数据集上以较大的优势超越许多优秀的模型。

2.1.7 ERNIE 模型

ERNIE 模型是百度提出的一种关于知识增强的语义表示模型，在中文短文本分类任务中该模型可以得到更好的运用。与 BERT 模型相比，ERNIE 模型可以将处在同一个单元中的可以组成短句或实体的词全部盖住，而不是简单的只遮住一个词或字符的模型^[48]。通过 ERNIE 模型会提高我们使用的模型的上下文知识推理能力，主要原因是该模型会在训练中学习有关于实体和短语的先验知识。与 GPT 和 BERT 等预处理模型一样，ERNIE 使用多层 Transformer 作为基础编码器，使其侧重于当前单词，并通过它本身的自注意机制去获得上下文的语义知识。其中，ERNIE 模型对所有层 Transformer 共同调节来实现预训练的语言双向表示，每个 Transformer（由前馈网络层和自注意力层组成）的输出表示为：

$SubLayer_{output} = LayerNorm(x + (SubLayer(x)))$ ；而自注意力层的输出表示为： $Attention_{output} = Attention(Q, K, V) = Softmax(\frac{QK^T}{\sqrt{d_k}})V$ 。其中： Q 、 K 、 V 是输入字向量矩阵， d_k 是输入向量的维度^[26]。

另外，ERNIE 还构建了一种知识掩蔽策略，这种策略它并不直接对知识进行增加嵌入，而是将单词、短语和实体层次知识整合到语言表达之中，ERNIE 称其为多阶段的知识掩蔽策略。实践证明，经过三阶段的研究学习，会得到一种语义信息丰富、易于进入下一个阶段模型的新的词语表征形式。

在处理中文文本任务中，BERT 会对其中文字进行预测建模，但很难表示出更大的完整的语义单元。例如，对信 [mask]机，紧急制 [mask]停车，[mask] 电信息等词，BERT 模型可以根据字之间的搭配，轻松推断出被遮盖字的信息，但没有显式地对语义概念单元（如信号机、紧急制动停车、变电信息）和相应的语义关系建模。而 ERNIE 模型却能够学习到完整概念的语义表示，因为其分别对词、短语、实体等语义单元进行了遮盖。ERNIE 模型对比 BERT 模型的优势在于 ERNIE 的语义表示能力更加强大，主要原因是不同于 BERT 学习研究原始的

文本语义，ERNIE 直接学习语义单元的先验知识，之后对这些语义单元进行建模处理，建模后的模型的会比原始模型有着更强的语义表示能力。

ERNIE 和 BERT 模型结构区别如图 2.7 所示，如果是 BERT 模型，通过共现 [石]与[庄]的局部信息，即可判断出[家]字，模型没有学习与[石家庄]相关的知识。而 ERNIE 根据词与实体的表达进行学习，模型就能对[石家庄]与[河北]的关系进行建模，学到[石家庄]是[河北]的省会以及其旧称是[石门]。

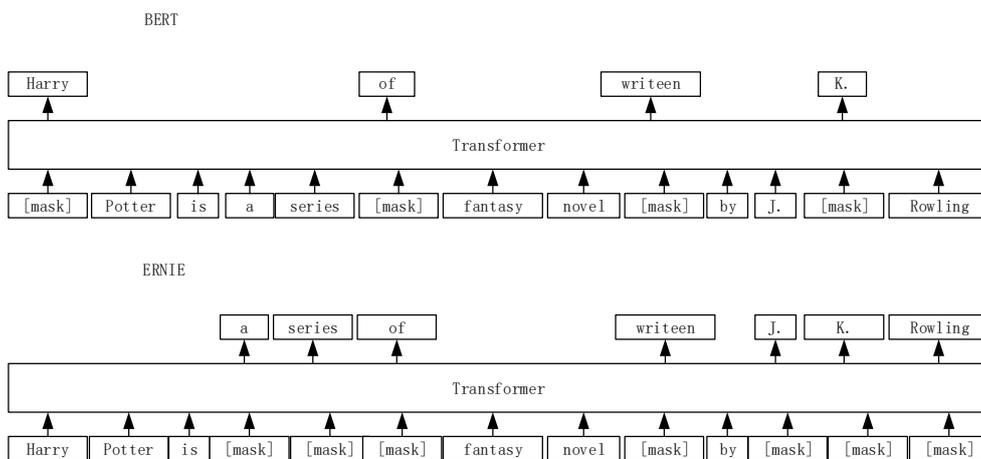


图 2.7 BERT 与 ERNIE 模型对比

因此，通过比较可以发现 ERNIE 能够在基于上下文知识推理上表现的更为优秀。

2.2 D-S 证据理论

在实际应用中，大部分多元信息或多源数据都存在着很强的不确定性，因此数据融合主要是针对对不确定信息的建模、剖析及处理。现在，不确定性建模方法主要有：D-S 证据理论、概率论、可能性理论、模糊集理论和粗糙集理论等。而实质上，D-S 证据理论是对概率论的一种推而广之，把概率论中的基本事件空间拓展转换成基本事件的幂集空间，而且在此基础上顺利成立了基本概率指派函数。与原来传统的概率论相比，D-S 证据理论不但可以充分表达出随机性和不确定性，而且还可以表达出不完全信息和主观的不确定性信息。

除此之外，D-S 证据理论面向数据融合还给予了有说服力的 Dempster 组合

规则，此规则具有结合律与交换律等优秀的特性，融合之后能在最大程度上减小系统的不确定性。这些优秀的性能，使如今 D-S 证据理论在数据融合的理论研究以及工程实践上都受到人们前所未有的持久关注。

2.2.1 D-S 证据理论基本概念

Dempster-Shafer 理论简称为 D-S 证据理论，刚开始是一个通过上下限概率来解决多值映射问题的理论，之后为了让其能够有效处理不确定性问题，Dempster 的学生 Shafer 将信任函数和似然函数的概念引入到证据理论当中。D-S 证据理论的基本概念主要包括：识别框架、基本概率赋值、信度函数、似真度函数等。

(1) 设 $\Theta = \{\theta_1, \theta_2, \dots, \theta_n\}$ ，为一个由 n 个两两互斥元素组成的有限且完备的论域集合，那么这些两两互斥的基本元素组成的集合 Θ 就被称为识别框架 (Frame of Discernment, FoD)。

(2) 设 Θ 为识别框架，如果函数 m 是一个从集合 $2^\Theta \rightarrow [0,1]$ 的映射， A 表示识别框架 Θ 的任意子集，记作 $A \in 2^\Theta$ ，且满足

$$\begin{cases} m(\phi) = 0 \\ \sum_{A \in 2^\Theta} m(A) = 1 \\ m(A) \geq 0, \forall A \in 2^\Theta \text{ 且 } A \neq \emptyset \end{cases} \quad (2-5)$$

则称 m 为基本概率赋值 (Basic Probability Assignment, BPA) 函数，也称基本可信度分配函数， $m(A)$ 就被视作准确分配给 A 的信度， A 是集合 2^Θ 中任一组成元素。

(3) 设 m 为识别框架 Θ 上的基本概率分配函数，函数 $\text{Bel}: 2^\Theta \rightarrow [0,1]$ 有

$$\text{Bel}(A) = \sum_{B \subseteq A} m(B), \forall A \subseteq \Theta \quad (2-6)$$

则称函数 Bel 为识别框架 Θ 上的信度函数 (Belief Function, BF)。

(4) 设 m 为识别框架 Θ 上的基本概率分配函数，函数 $\text{Pl}: 2^\Theta \rightarrow [0,1]$ 有

$$\text{Pl}(A) = \sum_{B \cap A = \phi} m(B) = 1 - \text{Bel}(\bar{A}), \forall A \subseteq \Theta \quad (2-7)$$

则称函数 Pl 为识别框架 Θ 上的似真度函数 (Plausibility Function, PF)。其中, $\bar{A} = \Theta - A$, 为命题 A 的补集。基本概率指派、信度函数和似真度函数三者之间的关系为: $Bel(A) \leq m(A) \leq Pl(A), \forall A \subseteq \Theta$ 。因此, $Bel(A)$ 和 $Pl(A)$ 分别表示对命题 A 的支持程度的上限和下限, 如图 2.8 所示。

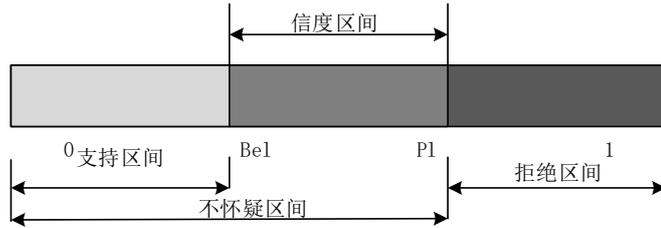


图 2.8 命题的信度区间表示

其中, 信度函数和似真度函数的性质如下:

- (1) $Bel(\phi) = Pl(\phi) = 0$
- (2) $Bel(\Theta) = Pl(\Theta) = 1$
- (3) $Bel(A) + Bel(\bar{A}) \leq 1$
- (4) $Pl(A) + Pl(\bar{A}) \geq 1$
- (5) $Bel(A) + Pl(\bar{A}) = 1$
- (6) $Pl(A) \geq Bel(A)$
- (7) 对于 $\forall A, B \in 2^\Theta$, 如果 $A \subseteq B$, 则 $Bel(A) \leq Bel(B)$

2.2.2 Dempster 融合规则

在智能决策系统中, 常常需要对一个事件拥有的多条证据进行融合, 以便做出全面的判断。在此基础上, Dempster 提出了一种融合规则, 通过计算两个及两个以上证据的基本概率赋值以获得融合结果。这个规则被称为 Dempster's combinational rule, 即 Dempster 融合规则。

设同一个识别框架 Θ 上的两两独立的证据 E_1 和 E_2 , 其基本概率赋值函数分别

是 m_1 和 m_2 ，则这两个证据进行合成 $m = m_1 \oplus m_2$ 的合成规则如公式 2-8 所示， \oplus 为证据融合的符号。

$$m(A) = \begin{cases} 0 & A = \emptyset \\ \frac{1}{1-k} \sum_{A_i \cap B_j = A, A_i, B_j \subseteq 2^\Theta} m_1(A_i) m_2(B_j) & A \neq \emptyset \end{cases} \quad (2-8)$$

式中， $k = \sum_{A_i \cap B_j = \emptyset} m_1(A_i) m_2(B_j)$

$k \in [0,1)$ 叫做冲突系数，用来表示两条证据之间冲突的大小。

2.2.3 D-S 证据理论一般步骤

(1) 对于需要融合的数据样本进行分析和研究，得到数据融合后可能出现的所有命题，以构建 D-S 证据理论所需的识别框架。

(2) 在构建好的识别框架中，为每一个命题分配证据，并获取对应的基本概率分配函数。

(3) 根据 D-S 证据理论的信任度函数和似然函数，获取识别框架中每个命题的信任度。

(4) 最后，根据 D-S 证据理论合成规则合成各个命题的信任度，依照合成的结果做出决策。

2.3 本章小结

本章首先对在短文本分类领域分类效果较好和精度较高的卷积神经网络、循环神经网络、Transformer 以及多个预训练语言模型进行了分别阐述，然后对决策级数据融合技术 D-S 证据理论的概念、融合规则和融合步骤进行相关阐述。本章节的理论研究对下文构造故障短文本分类模型和数据融合决策研究，奠定了强有力的理论基础。

3. 基于短文本分类的铁路信号设备故障诊断

随着各种零部件设备的结构构造越来越复杂,功能日益增多,以及自动化程度也变得更高。但是,由于长期高负荷地不间断运行,设备质量不良以及外界因素等各种原因,设备总会出现这样那样的故障,导致设备难以有效实现预期功能,甚至可能发生严重的危害或事故,造成财产等损失^[49]。由此可见,故障诊断在现在的工业生产中起着关键作用,对故障诊断的研究具有很强的社会现实意义。

本章主要研究铁路信号设备故障数据集的构建和短文本分类模型的效果验证,通过将预处理后的铁路信号设备故障数据集放入不同的短文本分类模型中,经过实验对比结果表明,本文提出的 ERNIE_RCNN 模型具有很好的铁路信号设备故障诊断精度。

3.1 数据集构建

3.1.1 数据预处理

本文拟构建一个专门的铁路信号设备故障短文本数据集,从而实现对常见铁路信号设备故障的精准诊断。然而,铁路信号设备故障文本大部分是维修手册、图集等形式,目前网上还无法获取到铁路信号设备领域的故障文本数据集。因此,对于本文来说,构建专门的铁路信号设备故障数据集是极为重要的一部分,这在很大程度上决定了故障诊断实验的准确性。而且,铁路信号设备故障的产生具有很强的随机性特点,受天气、环境、人为等多重因素的影响,铁路信号设备故障类型复杂多样,不同的维修人员对同一种故障具有不同的描述方式^[50],因此建立一个统一完善的铁路信号设备故障短文本数据集是一个巨大的挑战。

考虑到故障出现的频次和故障所引起的影响,本文选择了十种常见铁路信号设备故障进行研究。本研究使用的数据是来源于在兰州铁路局和青藏铁路公司收集的原始数据,初始数据集共收集到约 10000 条铁路信号设备故障短文本。

对原始数据集的数据预处理主要为以下三步。

(1) 数据清洗。筛选出描述不清和带错别字的文本,对文本进行去标点符号和不必要的空格,将一些多余的、影响分类效果的部分去掉;

(2) 类别匹配。选取数据集中数据量最完善的十个故障类别，因为是有监督的分类，所以匹配各原始文本的故障类别，然后分别定义每种故障类型相对应的类别号；

(3) 文本过滤。将文本长度控制在 25 个字符以内，对超过 25 个字符的文本做截断处理，从而降低运行内存，提高短文本分类的效率。

本文构建的铁路信号设备故障数据集的部分文本示例如表 3.1 所示，本文的研究数据主要抽取了包括变电信息、接触网异物、线路异物、外部环境、车载信息、电力信息、防洪巡视、机车空转、紧急制动停车和紧急制动试验等在外的十种常见铁路信号设备故障类型，每种故障类型的文本描述样本数量都在 500 到 2000 条之间，并且每条文本的字数都在 6 到 25 个字符之间。

表 3.1 铁路信号设备的故障类别示例

铁路信号设备故障短文本	类型 (class)	类别号
E_1 : “接触网 3 下 4 上跳闸，重合成功，下行 TR 故障。”	变电信息	0
E_2 : “支柱接触网保护线挂枯草，不影响行车。”	接触网异物	1
E_3 : “两线间有一只死鸟，不影响行车。”	线路异物	2
E_4 : “施工便道，6、7、8#墩之间堆积弃土。”	外部环境	3
E_5 : “车次号无法注册。计划在前方车站重启 CIR 设备。”	车载信息	4
E_6 : “开关跳闸，合闸成功。”	电力信息	5
E_7 : “防灾系统报警：小时雨量达到出巡警戒值。”	防洪巡视	6
E_8 : “下行线机车有空转。”	机车空转	7
E_9 : “撞异物，紧急制动。”	紧急制动停车	8
E_{10} : “进行紧急制动试验，要求上线检查。”	紧急制动试验	9

3.1.2 不平衡数据处理

在收集铁路信号设备故障文本数据时，发现不同故障类型出现的次数差异较大，即数据集各个类别的样本量极不均衡。例如像线路异物、接触网异物、车载信息、外部环境、电力信息等故障类别出现的概率远远大于防洪巡视、机车空转、

列控、线路晃车等故障出现的概率。各故障类别数据不平衡的问题，使得模型难以捕获少数类样本信息或模型学习不充分，造成分类结果准确率低下，从而影响整个实验的分类效果。

从数据角度出发的不平衡数据集的处理方法主要有：朴素随机过采样（上采样）和朴素随机欠采样（下采样），使用这两种方法来重构少数类样本，使得不同类别的文本数据量相对均衡一些。

(1) 上采样。是通过在少数类样本中随机采样以使新的样本数量增多的方法，但如果少数类样本的特征少，容易引起过拟合的问题。代表算法主要有 SMOTE 算法、ADASYN 算法等。

(2) 下采样。是从大多数样本中随机抽取少数样本，并与原本的少数类样本进行结合，成为一个新的训练数据集的方法。下采样有两种方法，一种是放回去的采样，另一种是不放回去的采样。在大多数类别的样品被抽取后，不会重复地抽取未放回去的样品。代表算法有 EasyEnsemble、BalanceCascade 和 NearMiss 等。

本文选用 SMOTE 算法来处理不平衡故障数据集。如图 3.1 所示，在少数类中，SMOTE 算法首先计算每一个样本点 x_i 和其他样本点的欧式距离，得到最近的 k 个近邻，即首先使用 KNN 算法对每一个样本点 x_i 进行距离计算；然后再根据样本不平衡比例设置一个采样比例以确定采样倍率，对于每一个少数类样本 x ，从其 k 近邻中随机选择若干个样本，假设选择的近邻为 \hat{x}_i ；最后，对于每一个随机选出的近邻 \hat{x}_i ，分别与原样本按照 3-1 中的公式构建新的样本。

$$x_{new} = x + rand(0,1) * (\hat{x}_i - x) \quad (3-1)$$

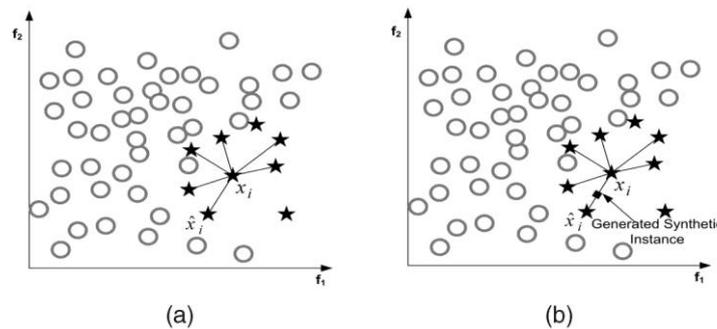


图 3.1 SMOTE 算法图

最终，通过 SMOTE 算法成功生成了较高质量的少数类样本，使得整个数据集的样本数量达到了基本平衡，为后面的铁路信号设备故障类型分类实验和数据融合都奠定了良好的数据基础。

3.1.3 铁路信号设备故障短文本数据集构建

通过上述的数据预处理和对不平衡数据进行上采样操作后，最终构建了一个具有十个类别，每个类别 1500 条故障文字描述，共计 15000 条的常见铁路信号设备故障短文本数据集，其中每条文本的字符数均在 25 以内。

3.2 构建基于 ERNIE_RCNN 的故障短文本分类模型

3.2.1 模型总体结构

如表 3.1 所示，铁路信号设备的故障文本存在长度短、特征词难抽取、故障描述的用语不规范以及少数文本噪音等特点^[51]。因此，为了增强模型的信息特征表达能力，提高文本分类的精度，本文融合 ERNIE 和 TextRCNN 模型，提出了改进的 ERNIE_RCNN 模型，由 3 个部分组成，分别为 ERNIE 层、TextRCNN 层和 softmax 层，整体结构如图 3.2 所示。

(1) ERNIE 层。由于 ERNIE 是以字为单位作为模型的输入，并且已有的研究已经证明，基于字的中文自然语言处理任务能够得到比基于词更好的结果，其原因在于分词的同时也会引入一定的误差。因此，直接将预处理后的训练数据输入 ERNIE 预训练模型进行文本特征提取，得到句子级的词向量表示。

(2) TextRCNN 层。将 ERNIE 模型的输出作为 TextRCNN 层的输入，TextRCNN 采用双向长短时记忆神经网络来进一步提取句子中每个单词的上下文信息，通过这层可以捕获更加精确的文本语义信息。

(3) softmax 层。通过 softmax 层来进行最终的分类，在进行多分类任务过程中，最终的模型预测结果通过使用概率值来表示，然后在 softmax 层将神经元的输出映射到 (0,1) 区间内，最后在 (0,1) 区间内选取概率值最大的输出节点即为模型预测结论。

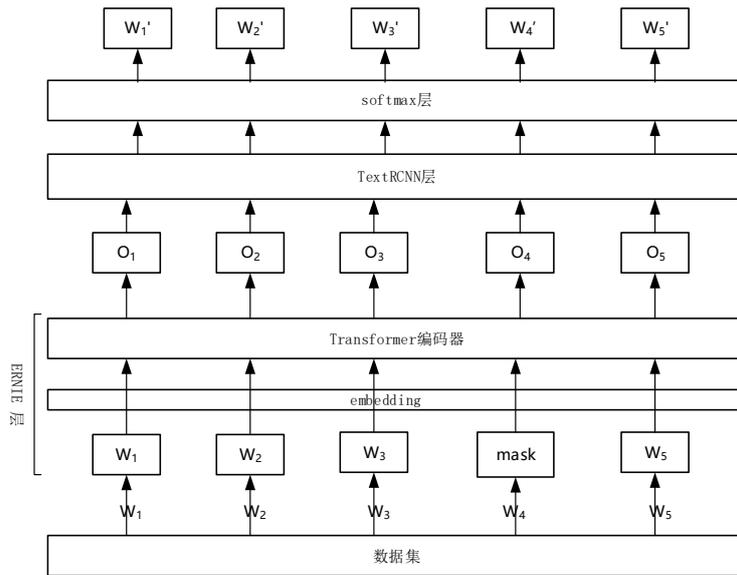


图 3.2 ERNIE_RCNN 模型

3.2.2 ERNIE 层

ERNIE 在各种中文自然语言处理任务上明显优于以往的先进方法，ERNIE 被设计为学习通过知识掩蔽策略增强的语言表示，包括实体级掩蔽和短语级掩蔽，屏蔽了短语和实体等单位，以便从这些单位隐含地学习句法和语义信息。

ERNIE 层的结构和 BERT 模型类似，如图 3.3 所示，首先对文本进行字、词、实体等不同粒度的切分，然后将输入的向量 $[E_1, E_2, \dots, E_n]$ 进行 Mask 操作，再进行 Embedding 文本向量化表示后，放入 Transformer 多层编码器中，输出包含了文本全部上下文信息的词向量表示 $[T_1, T_2, \dots, T_n]$ 。

与 BERT 模型结构有所不同的是，ERNIE 层分为 transformer 编码和知识整合两个部分，ERNIE 的前 6 层 Transformer 编码层与 BERT 的结构相同，但在第 7 层自定义知识融合层 BertLayerMix，首次对经过对齐的实体向量和指称项向量求和，并将其分别传输给知识编码模块和文本编码模块，在剩下 5 层自定义知识编码层 BertLayer，分别对经过融合了两者信息的实体序列和文本序列使用自注意力机制编码。即模型的前 5 层是文本编码器，后面的 7 层编码层则构成了知识编码器。

ERNIE 层的作用主要是经过 Transformer 的编码器来抽取输入短句的特征表示，将文本数据转化为词向量表示，词向量分别包含了字嵌入、短语嵌入和位置嵌入，从而把文本中的每个字转化为一维向量，然后将语句切段并序列化表示，最后通过位置嵌入表示出句子的词序信息。经过预训练后的模型能够充分地学习文本的词法和语义信息，为准确进行铁路信号设备故障文本分类奠定良好的基础。

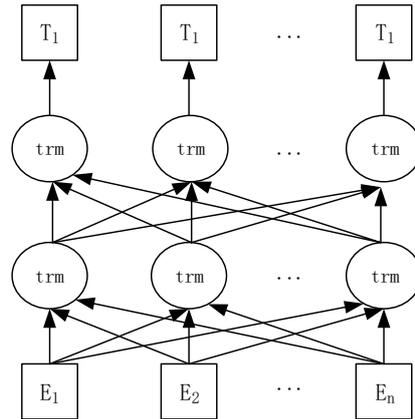


图 3.3 ERNIE 模型结构

3.2.3 TextRCNN 层

模型的 TextRCNN 层主要分为六个部分：输入层、卷积层、拼接层、池化层、全连接层、输出层。模型总体结构如图 3.4 所示。

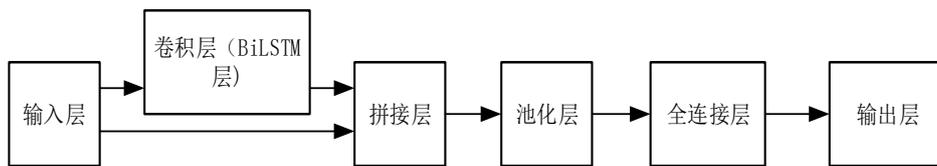


图 3.4 TextRCNN 模型结构

第一层是输入层，将 ERNIE 预训练模型输出的词向量特征表示矩阵 X 作为 TextRCNN 模型的 embedding 层输入模型。第二层是卷积层，卷积层包含了 BiLSTM 双向循环神经网络结构，通过前向隐层和后向隐层的组合拼接，能够得到所有时刻的隐层状态，即获得文本信息的前向扫描和后向扫描，这样捕捉的前

后文语境信息有助于获取更精准的语义。第三层是拼接层，embedding 层与卷积层的输出可以通过拼接形成新的语义向量，并使用 relu 函数进行非线性激活，其

计算公式为： $f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$ 。第四层是最大池化层，取每层特征值中得分最

大的值，来判断出哪些单词在文本分类时起着决定性作用，以确定文本中的重要成分。第五层是全连接层，提取整合有价值的信息后，通过 softmax 操作获得分类结果的概率分布。第六层是输出层，给出文本分类的结果。

3.3 实验结果与分析

在实验时，将已经进行过数据预处理和不平衡数据处理的铁路信号设备故障短文本数据集分为训练集、验证集和测试集，数据量比例为 3:1:1，即训练集 9000 条，验证集 3000 条，测试集 3000 条。

3.3.1 实验评价指标

本文的铁路信号设备故障短文本分类实验主要选用精确率 P (Precision)、召回率 R (recall) 和 F_1 值作为模型的评价指标，公式定义为： $P = \frac{TP}{TP+FP}$ ， $R = \frac{TP}{TP+FN}$ ， $F_1 = \frac{2 \times P \times R}{P+R}$ 。其中，混淆矩阵如表 3.2 所示，TP 表示真正例，即真实值为正例且被分类器预测为正例的样本数，FP 表示假正例，即真实值为反例却被分类器预测为正例的样本数。

表 3.2 混淆矩阵

		预测值	
		正例(True)	反例(False)
真实值	正例(True)	TP(True Positive)	FN(False Negative)
	反例(False)	FP(False Positive)	TN(True Negative)

3.3.2 实验环境及参数设置

本文实验的测试环境是在 Windows10 系统下进行，使用的 CPU 是 Intel(R) Core(TM) i5-7200U CPU @ 2.50GHz，内存 8GB，编程语言为 Python3.7，开发工具为 Anaconda，应用 Pytorch1.1 框架，tqdm，sklearn，tensorboardX。实验统一使用 utf-8 编码。详细的实验模型参数设置如表 3.3 所示。

表 3.3 实验模型参数设置

模型参数	详情
Batch size	128
Epoch	3
Pad size	32
学习率	5e-5
ERNIE hidden_size	768
LSTM hidden_size	256
激活函数	relu 函数

3.3.3 实验结果对比分析

分别将前文预处理完成的同一铁路信号设备故障数据集放入 ERNIE_RCNN、BERT、ERNIE、TextRCNN 等四个模型中进行分类，得到不同模型分类结果，如下表 3.4 所示：

表 3.4 模型分类结果对比

模型	精确率 (%)	召回率 (%)	F_1 值 (%)
ERNIE_RCNN	91.36	91.02	91.19
BERT	89.84	89.18	89.51
ERNIE	90.02	89.32	89.67
TextRCNN	86.57	85.14	85.85

从表 3.4 可以看出，将铁路信号设备故障短文本数据在各个深度学习模型上实验，结果表明 ERNIE_RCNN 模型分类整体效果都要显著高于其余的三个模型，且 BERT 模型和 ERNIE 模型分类效果也明显优于 TextRCNN 模型，这是

由于基于 Transformer 的双向编码器表示模型特点之一是具有很好的特征表示能力，而短文本分类效果的好坏关键在于特征表示^[52]。因此，实验证明，使用将知识整合到预训练语言模型的方法结合 TextRCNN 模型进行短文本分类具有更好的中文短文本分类效果，即本文构造的 ERNIE_RCNN 模型能够用于铁路信号设备故障诊断，并且能够取得理想的结果。

3.4 本章小结

本章实现的重点在于构造出了效果好、精度高的铁路信号设备故障短文本分类模型，并在专门的铁路信号设备故障数据集上进行了实验验证。首先，对原始的铁路信号设备故障数据进行初步的筛选和清洗，然后利用 SMOTE 算法对不平衡数据进行了重采样操作，从而使不同类别的故障文本数据数量达到了基本均衡，进而提高故障短文本分类的效果。接下来，介绍了本研究所使用到的 ERNIE_RCNN 模型，分别详细阐述说明了 ERNIE 层和 TextRCNN 层的模型结构和特征优势。最后，将故障文本数据在此模型上进行短文本分类对比实验，验证了本文所提出的 ERNIE_RCNN 短文本分类模型可以在铁路信号设备故障诊断研究中取得理想的分类精度和诊断效果。

4. 基于数据融合的铁路信号设备故障诊断

铁路信号设备故障类型众多,包含一定的不确定性,因而根据单一的故障诊断方法得出的结论可靠性有待提高^[53],并且现场专家评价诊断中对证据的可信度赋值存在着一定的主观性,也会导致推理结论的可靠性降低。因此,本文将采用数据融合的决策级融合技术 D-S 证据理论,将短文本分类和专家评价这两种单一的故障诊断方法进行数据融合,从而增强故障诊断系统的准确性。

4.1 基于 D-S 证据理论的故障诊断

D-S 证据理论很擅长处理不确定的推理问题,而故障诊断系统中存在大量的不确定性,因此采用 D-S 证据理论来处理故障诊断中的不确定性是一个很好的选择。例如,在故障模式分类中,各故障模式数据可能存在着不同程度的重复,如同样是表现为振动信号的异常,但对于旋转机械来说却可能是不同的故障模式,这是因为电子设备的某一器件发生故障都有可能致其相邻各个器件的特征电信号异常等^[54-56]。对于这些相互重叠的数据,如果只应用单一的诊断方法进行故障诊断,将很有可能出现故障误判现象,从而诊断精度和可靠性不能满足实际需求,也就无法辅助管理人员做出精准决策^[57-58]。而 D-S 证据理论对具有不确定性、两类故障模式之间存在重叠数据的故障模式识别问题,具有较好的识别效果。应用根据 D-S 证据理论的数据融合方法,能很好地处理诊断系统内的不确定性,可以将多个不同来源的信息通过组合规则进行融合,从而精准判断设备存在的故障。因此,它在故障诊断领域得到了广泛的应用。

通过数据融合技术将从短文本分类方法中提取的历史经验数据与现场专家评价结果,用 D-S 证据理论融合得到故障诊断结论,利用 ERNIE_RCNN 模型较强的学习能力、良好的抗干扰能力以及优秀的鲁棒性,来增加铁路信号设备故障诊断决策的准确性^[59]。根据短文本分类模型和专家评价的诊断结果做相应的处理来分别得到两个证据的基本概率分配值,这种方法不仅有效解决了 D-S 证据理论中如何构建基本概率分配函数的难点,同时也避开了合成规则的缺陷。这种定性和定量信息的融合,能充分提高故障诊断的效率^[60]。具体的数据融合步骤如图 4.1 所示。

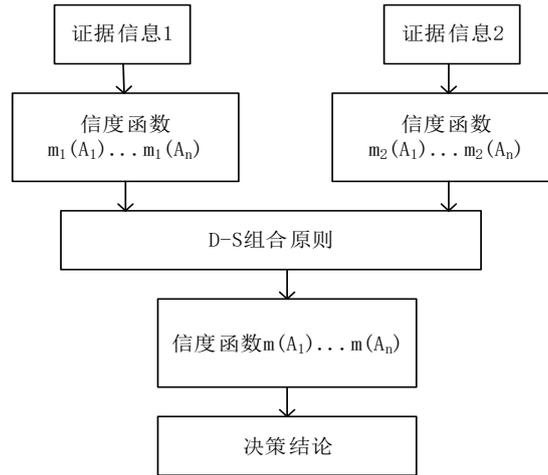


图4.1 D-S证据理论数据融合步骤流程图

4.1.1 D-S 证据理论的识别框架

通过对铁路信号设备故障类型的历史记录进行统计,将平时出现故障次数最多的前十种铁路信号设备故障类型设为本次故障诊断系统的识别框架,即 $\Theta = \{\theta_1, \theta_2, \theta_3, \theta_4, \theta_5, \theta_6, \theta_7, \theta_8, \theta_9, \theta_{10}\}$, 分别为: 变电信息、接触网异物、线路异物、外部环境、车载信息、电力信息、防洪巡视、机车空转、紧急制动停车和紧急制动试验等十种铁路信号设备故障类型,故障类型之间两两独立,此识别框架表示了铁路信号设备会发生的所有故障类型。

4.1.2 D-S 证据理论的基本概率分配 (BPA)

设识别框架 $\Theta = \{\theta_1, \theta_2, \dots, \theta_{10}\}$, 该框架幂集下的 BPA 函数,是由待检模式得到的一组诊断证据,表示待检模式与档案库中各故障样板模式匹配后得到的对各故障的支持程度。本文将短文本分类模型 ERNIE_RCNN 模型的精度输出结果和现场专家评价作为生成基本概率指派的依据。

(1) 根据短文本分类模型输出构造 BPA。由于短文本分类模型 ERNIE_RCNN 采用 softmax 函数输出各故障类型的分类结果,且 softmax 将多个神经元的输出映射到了(0,1)区间内,即各个故障类型的 F_1 值之和为 1,这符合基本概率分配的构造规则,因此可以直接用短文本分类模型的输出结果作为一个证

据体来构造 BPA，即采用每个故障类型的概率输出来构造 D-S 证据理论的基本概率分配值 $m_1(A_i)$ ，如表 4.1 所示。其中 BPA 的值处于 0 和 1 之间，因此 $m_1(A_1) + \dots + m_1(A_{10}) = 1$ 。

表 4.1 根据短文本分类模型的 BPA

	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6	θ_7	θ_8	θ_9	θ_{10}
$m_1(A_i)$	$m_1(A_1)$	$m_1(A_2)$	$m_1(A_3)$	$m_1(A_4)$	$m_1(A_5)$	$m_1(A_6)$	$m_1(A_7)$	$m_1(A_8)$	$m_1(A_9)$	$m_1(A_{10})$

(2) 根据专家评价确定 BPA。设有 m 位专家，对于某一待识别的命题，专家 i 判断目标 $\theta_j (j = 1, 2, \dots, n)$ 发生的概率为 $p_i(\theta_j) (i = 1, 2, \dots, m)$ ，不能确定该类别的概率为 $p_i(\omega)$ 。每一位专家的判断满足： $\sum_{j=1}^n p_i(\theta_j) + p_i(\omega) = 1$ 通过对 m 位专家给出的评价进行处理，就可以得到证据 2 的基本概率分配 $m_2(A_i)$ ，如表 4.2 所示。

表 4.2 根据专家评价确定 BPA

	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6	θ_7	θ_8	θ_9	θ_{10}
$p_1(\theta_j)$	$p_1(\theta_1)$	$p_1(\theta_2)$	$p_1(\theta_3)$	$p_1(\theta_4)$	$p_1(\theta_5)$	$p_1(\theta_6)$	$p_1(\theta_7)$	$p_1(\theta_8)$	$p_1(\theta_9)$	$p_1(\theta_{10})$
...
$p_i(\theta_j)$	$p_i(\theta_1)$	$p_i(\theta_2)$	$p_i(\theta_3)$	$p_i(\theta_4)$	$p_i(\theta_5)$	$p_i(\theta_6)$	$p_i(\theta_7)$	$p_i(\theta_8)$	$p_i(\theta_9)$	$p_i(\theta_{10})$
$m(\theta_i)$	$m(\theta_1)$	$m(\theta_2)$	$m(\theta_3)$	$m(\theta_4)$	$m(\theta_5)$	$m(\theta_6)$	$m(\theta_7)$	$m(\theta_8)$	$m(\theta_9)$	$m(\theta_{10})$
$m_2(A_i)$	$m_2(A_1)$	$m_2(A_2)$	$m_2(A_3)$	$m_2(A_4)$	$m_2(A_5)$	$m_2(A_6)$	$m_2(A_7)$	$m_2(A_8)$	$m_2(A_9)$	$m_2(A_{10})$

其中：

$$\begin{cases} m(\theta_i) = \frac{1}{m} \sum_{i=1}^m p_i(\theta_j) \\ m(\omega) = \frac{1}{m} \sum_{i=1}^m p_i(\omega) \end{cases} \quad (4-1)$$

$$m_2(A_i) = \frac{m(\theta_i)}{\sum_{i=1}^{10} m(\theta_i)} \quad (4-2)$$

式中 $m(\theta_i)$ 表示由待识别命题中识别目标 θ_i 发生的基本概率分配, $m(\omega)$ 表示由待识别命题不能判断出目标的基本概率分配, $m_2(A_i)$ 表示根据专家评价确定的基本概率指派。

4.1.3 根据融合规则决策

利用证据组合规则将短文本分类模型输出和专家评价两个证据组合, 得到融合后的新证据 $m(A_i)$, 如表 4.3, 根据融合之后的结果选取信任度最大的命题即可实现故障的诊断决策。

表 4.3 基于 D-S 证据理论融合的新证据

	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6	θ_7	θ_8	θ_9	θ_{10}
$m(A_i)$	$m(A_1)$	$m(A_2)$	$m(A_3)$	$m(A_4)$	$m(A_5)$	$m(A_6)$	$m(A_7)$	$m(A_8)$	$m(A_9)$	$m(A_{10})$

$$m(A_i) = \begin{cases} 0 & A = \emptyset \\ \frac{1}{1-k} \sum_{A_i \cap A_j = A, A \subseteq 2^\Theta} m_1(A_i)m_2(A_j) & A \neq \emptyset \end{cases} \quad (4-3)$$

式中, k 为对应的归一化因子, $k = \sum_{A_i \cap A_j = \emptyset} m_1(A_i)m_2(A_j)$ 。

4.2 基于数据融合故障诊断实例 1

下面以在兰州铁路局和青藏铁路公司收集到的历史数据(如工作人员记录的各种铁路信号设备故障描述)和现场数据(专家评价)为例, 采用 D-S 证据理论进行决策级数据融合, 以证明数据融合技术能够充分提高单一诊断技术的精确率和可信度。根据已有的识别框架 $\Theta = \{\theta_1, \theta_2, \theta_3, \theta_4, \theta_5, \theta_6, \theta_7, \theta_8, \theta_9, \theta_{10}\}$, 将短文本分类模型的输出结果和专家评价结果进行融合实验, 实验步骤如下。

4.2.1 确定基本概率分配值

(1) 根据短文本分类模型输出构造 BPA。短文本分类模型的输出如下表所示,对证据体 1 进行基本概率分配本质上是描述对证据体的信任程度,根据短文本分类模型输出的诊断精确率,并保留小数点后三位小数,对证据 1 进行概率分配如表 4.4 所示。

表 4.4 基于短文本分类模型输出的基本概率分配值

	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6	θ_7	θ_8	θ_9	θ_{10}
$m_1(A_i)$	0.914	0.013	0.011	0.004	0.002	0.015	0.015	0.016	0.005	0.005

经过短文本分类模型的初步诊断表明,当前铁路信号设备故障数据的故障类别是 θ_1 ,即“变电信息故障”,但是不确定程度较高。

(2) 根据专家评价确定 BPA。铁路局存在四个管理层级,分别为电务处、电务段、车间和工区,这四个管理层级分别设有工程师监测铁路信号设备状态,发生故障时每个层级的工程师对故障类型进行判断构成了专家意见,综合这四个层级的专家意见即为根据专家评价结果确定基本概率分配值。设在识别框架 $\Theta = \{\theta_1, \theta_2, \theta_3, \theta_4, \theta_5, \theta_6, \theta_7, \theta_8, \theta_9, \theta_{10}\}$ 中,有 4 位专家 $i(i = 1, 2, 3, 4)$ 判断目标 $\theta_j(j = 1, 2, \dots, 10)$ 发生故障的几率为 $P_i(\theta_j)$,不能确定该类别的几率为 $P_i(\omega)$ 。设在识别框架中,对某一铁路信号设备故障的专家评价结果如表 4.5 所示,通过将各位专家的诊断结果进行平均即可得到表中的 $m(\theta_i)$ 。

表 4.5 基于专家评价的故障诊断结果

	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6	θ_7	θ_8	θ_9	θ_{10}
$P_1(\theta_j)$	0.80	0.10	0.14	0.09	0.02	0.22	0.10	0.15	0.11	0.05
$P_2(\theta_j)$	0.42	0.09	0.09	0.19	0.10	0.68	0.19	0.09	0.16	0.21
$P_3(\theta_j)$	0.81	0.10	0.06	0.15	0.10	0.09	0.11	0.11	0.09	0.17
$P_4(\theta_j)$	0.90	0.09	0.11	0.10	0.02	0.12	0.09	0.10	0.10	0.10
$m(\theta_i)$	2.93	0.39	0.40	0.53	0.23	1.11	0.48	0.46	0.46	0.53

下表 4.6 是将四位专家评价的综合处理结果 $m(\theta_i)$ 进行归一化，归一化结果即为证据 2 的基本概率分配值 $m_2(A_i)$ 。

表 4.6 基于专家评价的基本概率分配值

	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6	θ_7	θ_8	θ_9	θ_{10}
$m_2(A_i)$	0.39	0.05	0.05	0.07	0.03	0.15	0.06	0.06	0.06	0.07

经过现场专家评价阶段的初步诊断，根据专家评价的基本概率分配值可以判断本次故障文本描述的故障类别是 θ_1 ，也就是“变电信息”这一故障的可能性最大。从表 4.5 中可以看到第二位专家的故障诊断结论 $P_2(\theta_j)$ 与其余三位专家存在一些分歧，其诊断结果显示出 θ_6 的可信度最高，具体数值为 0.68，而其余专家诊断结果均是 θ_1 的可信度最高，在通过一系列的平均、归一化等综合处理后，可以发现，最终依然是 θ_1 被赋予了最高的基本可信度值为 0.39，如表 4.6 所示。因此，本实例表明通过基本概率赋值可以融合证据内部的冲突，得到最终一致的专家评价故障诊断结果。但是，根据专家评价这一单一的故障诊断方法依旧存在着一定的主观性和不确定性，还需要结合其他诊断方法做进一步的确认。

4.2.2 D-S 证据理论融合结果

采用 D-S 证据理论将短文本分类模型输出和专家评价结果进行决策级融合，融合结果如表 4.7 所示。其中 $m_1(A_i)$ 和 $m_2(B_j)$ 分别是根据短文本分类和专家评价得到的基本可信度，通过 Dempster 组合规则，根据两个证据信息的基本概率分配值可以得到对应的归一化因子 k。计算过程如下：

$$\begin{aligned}
 k &= \sum_{A_i \cap B_j = \emptyset} m_1(A_i)m_2(B_j) \\
 &= 0.914*(0.05+0.05+0.07+0.03+0.15+0.06+0.06+0.06+0.07) \\
 &\quad + 0.013*(0.39+0.05+0.07+0.03+0.15+0.06+0.06+0.06+0.07) \\
 &\quad + 0.011*(0.39+0.05+0.07+0.03+0.15+0.06+0.06+0.06+0.07)
 \end{aligned}$$

$$\begin{aligned}
 &+ 0.004*(0.39+0.05+0.05+0.03+0.15+0.06+0.06+0.06+0.07) \\
 &+ 0.002*(0.39+0.05+0.05+0.07+0.15+0.06+0.06+0.06+0.07) \\
 &+ 0.015*(0.39+0.05+0.05+0.07+0.03+0.06+0.06+0.06+0.07) \\
 &+ 0.015*(0.39+0.05+0.05+0.07+0.03+0.15+0.06+0.06+0.07) \\
 &+ 0.016*(0.39+0.05+0.05+0.07+0.03+0.15+0.06+0.06+0.07) \\
 &+ 0.005*(0.39+0.05+0.05+0.07+0.03+0.15+0.06+0.06+0.07) \\
 &+ 0.005*(0.39+0.05+0.05+0.07+0.03+0.15+0.06+0.06+0.06) \\
 &= 0.64
 \end{aligned}$$

计算得出 k 后，根据 Dempster 组合规则公式即可算出证据合成后的信度。

以 θ_1 为例，计算得出 θ_1 数据融合后的信度如下。

$$\begin{aligned}
 m(A) &= \frac{1}{1-k} \sum_{A_i \cap B_j = A, A_i, B_j \subseteq 2^\theta} m_1(A_i)m_2(B_j) \\
 &= \frac{1}{1-0.64} * 0.914 * 0.39 \\
 &= 0.982
 \end{aligned}$$

表 4.7 D-S 证据理论决策级融合结果

	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6	θ_7	θ_8	θ_9	θ_{10}
$m(A_i)$	0.982	0.002	0.002	0.001	0.000	0.006	0.003	0.003	0.001	0.001

4.2.3 故障诊断决策

根据表 4.7 的融合结果，选取可信度最大的命题，即 θ_1 作为本次故障诊断的决策结果。从表 4.5、表 4.6 和表 4.7 可以看出，经过 D-S 证据理论融合之后故障诊断的可靠程度和精确度都得到了提高：本次融合实例中 θ_1 的可信度从短文本分类模型的 0.914 以及专家评价综合结果的 0.39 提高到了 0.982，诊断效果理想。

因此，通过数据融合结果证明，D-S 证据理论是一种有效的决策级数据融合方法，可以充分增强铁路信号设备故障诊断的可靠性，从而给铁路信号设备故障诊断提供更为合理的决策。

4.3 基于数据融合的故障诊断实例 2

同样，设现有识别框架 $\Theta=\{\theta_1, \theta_2, \theta_3, \theta_4, \theta_5, \theta_6, \theta_7, \theta_8, \theta_9, \theta_{10}\}$ ，根据短文本分类结果和专家评价分别确定这两条证据的基本概率分配值，然后根据 D-S 证据理论融合规则得出最终故障诊断结果。

4.3.1 确定基本概率分配值

(1) 根据短文本分类模型输出构造 BPA。由于通过短文本分类模型训练得到的是根据累积的铁路信号设备故障数据中提取的历史经验，所以其基本概率分配也可以直接根据短文本分类模型输出得到的。因此，根据短文本分类模型输出的诊断结果，保留小数点后三位小数，对证据体进行概率分配如表 4.8 所示。

表 4.8 基于短文本分类模型输出的基本概率分配值

	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6	θ_7	θ_8	θ_9	θ_{10}
$m_1(A_i)$	0.897	0.007	0.003	0.011	0.004	0.067	0.002	0.005	0.003	0.001

(2) 根据专家评价确定 BPA。通过本次实例 2 中故障描述的专家评价来确定第二个证据信息的基本概率分配，如表 4.9 所示。

表 4.9 基于专家评价的基本概率分配值

	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6	θ_7	θ_8	θ_9	θ_{10}
$P_1(\theta_j)$	0.08	0.20	0.08	0.14	0.13	0.78	0.11	0.09	0.09	0.04
$P_2(\theta_j)$	0.84	0.31	0.10	0.06	0.07	0.08	0.14	0.07	0.14	0.06
$P_3(\theta_j)$	0.01	0.10	0.14	0.08	0.05	0.89	0.08	0.12	0.12	0.11
$P_4(\theta_j)$	0.92	0.07	0.23	0.11	0.07	0.05	0.03	0.01	0.21	0.09
$m(\theta_i)$	0.46	0.17	0.14	0.10	0.08	0.45	0.09	0.07	0.14	0.08
$m_2(A_i)$	0.26	0.10	0.08	0.05	0.05	0.25	0.05	0.04	0.08	0.04

根据专家评价结果计算出的基本概率分配值可以看出， θ_1 和 θ_6 的值分别是

0.26 和 0.25, 这是因为专家们的意见不统一, 专家 1 和专家 3 判断目标 θ_6 发生故障的概率最大, 而专家 2 和专家 4 却判断 θ_1 发生的概率最大, 因此这两处都存在着发生故障的可能性, 即专家评价方法内部存在证据冲突, 仅仅凭借专家评价这一单一的诊断方法无法判断出实际发生故障的类型, 需要依靠数据融合技术做进一步的确认。

4.3.2 D-S 证据理论融合结果

采用 D-S 证据理论将短文本分类模型概率输出和实例 2 中的专家评价结果进行决策级融合, 融合结果如表 4.10 所示。其中 $m_1(A_i)$ 和 $m_2(B_j)$ 分别是根据短文本分类和专家评价得到的基本可信度, 通过将两个证据信息的基本可信度可以得到对应的归一化因子 k。根据 D-S 融合公式, 计算过程如下:

$$\begin{aligned}
 k &= \sum_{A_i \cap B_j = \emptyset} m_1(A_i)m_2(B_j) \\
 &= 0.897*(0.10+0.08+0.05+0.05+0.25+0.05+0.04+0.08+0.04) \\
 &\quad + 0.007*(0.26+0.08+0.05+0.05+0.47+0.05+0.04+0.08+0.04) \\
 &\quad + 0.003*(0.26+0.10+0.05+0.05+0.47+0.05+0.04+0.08+0.04) \\
 &\quad + 0.011*(0.26+0.10+0.08+0.05+0.47+0.05+0.04+0.08+0.04) \\
 &\quad + 0.004*(0.26+0.10+0.08+0.05+0.47+0.05+0.04+0.08+0.04) \\
 &\quad + 0.067*(0.26+0.10+0.08+0.05+0.05+0.05+0.04+0.08+0.04) \\
 &\quad + 0.002*(0.26+0.10+0.08+0.05+0.05+0.47+0.04+0.08+0.04) \\
 &\quad + 0.005*(0.26+0.10+0.08+0.05+0.05+0.47+0.05+0.08+0.04) \\
 &\quad + 0.003*(0.26+0.10+0.08+0.05+0.05+0.47+0.05+0.04+0.04) \\
 &\quad + 0.001*(0.26+0.10+0.08+0.05+0.05+0.47+0.05+0.04+0.08) \\
 &= 0.75
 \end{aligned}$$

计算得出 k 后, 根据 Dempster 组合规则公式即可算出证据合成后的信度。

同样, 以 θ_1 为例, 计算得出其融合后的信度分配值如下。

$$m(A) = \frac{1}{1-k} \sum_{A_i \cap B_j = A, A_i, B_j \subseteq 2^\theta} m_1(A_i)m_2(B_j)$$

$$= \frac{1}{1-0.75} * 0.897 * 0.26$$

$$= 0.924$$

表 4.10 D-S 证据理论决策级融合结果

	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6	θ_7	θ_8	θ_9	θ_{10}
$m(A_i)$	0.924	0.003	0.001	0.002	0.001	0.067	0.000	0.001	0.001	0.000

4.3.3 故障诊断决策

根据表 4.10 的融合结果可以看出本次发生故障可能性最大的命题为 θ_1 ，因此将“变电信息”作为本次故障诊断的决策结果。经过 D-S 证据理论融合之后故障诊断的可靠程度和精确度都得到了提高：本次融合实例中 θ_1 的可信度从短文本分类模型的 0.897 以及专家评价综合结果的 0.26 提高到了 0.924，虽然在专家评价时存在证据内冲突，但是使用 D-S 证据理论将短文本分类和专家评价结果进行数据融合后，冲突得以解决，因此通过数据融合技术可以显著降低故障诊断时的不确定性。

4.4 本章小结

本章首先介绍了不同层次的数据融合技术，以及数据融合的常用方法，由于 D-S 证据理论能降低铁路信号设备故障诊断的不确定性，因此确立了使用决策级融合的 D-S 证据理论作为此次数据融合的方法。下一步，确定了 D-S 证据理论所需使用的铁路信号设备故障类别识别框架，然后依照短文本分类模型的输出和专家评价结果进行基本概率分配值计算和确定，最后根据 D-S 证据理论的诊断决策规则计算出最终的故障类别诊断决策结果。分别通过两个实例表明，基于 D-S 证据理论的数据融合方法大大减小了单一故障诊断方法的不确定性，并且证据冲突也得到了化解。

5. 总结与展望

5.1 工作总结

围绕铁路的信号设备故障诊断，本论文主要提出了基于短文本分类，以及融合短文本分类模型输出和专家评价结果的数据融合方法研究，使用了铁路公司的实际数据进行故障诊断实验，证明了两种方法的有效性。

论文主要完成了以下研究工作：

(1) 针对收集到的铁路信号设备故障文本具有长度短、特征稀疏且多歧义的特点，阐述了目前常用的几种短文本分类方法，并选取了擅长处理中文文本的 ERNIE 模型作为故障文本的特征提取预训练模型，以及能在最大程度上减少短文本含义的歧义的 TextRCNN 模型用于进一步地提取每一个句子中的前后文信息，从而建立起 ERNIE_RCNN 模型用于铁路信号设备的故障分类。

(2) 由于铁路信号设备故障发生次数的差别较大，因此原始数据的故障类别数量很不平衡，本文采用了 SMOTE 算法对数量较少的样本类别进行重采样操作，增加了少数类样本的数量，使不同故障类别的数量达到了基本均衡，有效解决了数据不平衡的问题。

(3) 为了降低故障诊断的不确定性，特采用了决策级的数据融合技术 D-S 证据理论，将铁路信号设备故障短文本的 ERNIE_RCNN 模型的输出结果和专家评价结果分别作为两种信息源来构造各自的基本可信度分配函数，最终通过两个具体实例的融合结果表明，基于 D-S 证据理论的数据融合不但大大提高了铁路信号设备故障诊断的精确度，而且也提高了最终决策的可靠性。

5.2 工作展望

本文针对铁路信号设备进行故障诊断时，提出了短文本分类和数据融合的两种故障诊断方法，且均取得了一定的研究成果。但由于时间有限，本文研究依然存在以下不足，有待继续深入研究和完善。

(1) 由于铁路信号设备故障的类型多种多样，此次研究只是选取了少部分的故障类型，研究不够透彻深入。后续研究可以增加故障类型的覆盖率或更加深

入地探究每个故障设备产生故障的原因,将故障的产生原因和故障建立某种联系,使故障诊断更加精细化。

(2) 短文本分类模型在故障诊断方面还未做到独当一面和万无一失,智能化程度依旧不足,仍然需要工作人员进行确认和监督。随着信息技术的不断发展,期待后续研究可以发现诊断精度更高、效果更好的模型,这也是故障诊断领域的提升空间所在。

(3) 虽然本文的数据融合取得了较好的效果,但后续研究仍可以尝试其他的基本概率分配构造方法,例如融合多个传感器的测量结果的方法等,进而构建效率更高的数据融合故障诊断系统。

参考文献

- [1] 宫云光. 铁路信号系统中道岔转换设备故障监测与诊断分析[J]. 电脑知识与技术, 2019, 15(33):249-250.
- [2] 郭建波, 赵勇, 齐照东. 铁路事故研究现状及应用[J]. 工业安全与环保, 2005, 31(3):49-51.
- [3] 魏韬. 铁路信号联锁故障诊断及具体应用[J]. 智能交通, 2021:139-140.
- [4] Papadopoulos Y, Mcdermid J A. The potential for a generic approach to certification of safety critical systems in the transportation sector[J]. Reliability Engineering & System Safety, 1999,63(1):47-66.
- [5] 范东明, 张兵建, 黄蒙涛. 基于大数据的智能监测电务故障应急管理研究[J]. 铁路通信信号工程技术, 2020, 17(4):1-2.
- [6] 戚小玉, 杨东盛, 李平, 刘敏, 刘彦军. 基于大数据平台的铁路电务专业数据可视化交互系统[J]. 中国铁路, 2021:117-119.
- [7] 刘富钱. 铁路信号设备故障诊断方法探讨[J]. 电子技术与软件工程, 2016, 023(011):56-57.
- [8] 赵阳, 徐田华. 基于文本挖掘的高铁信号系统车载设备故障诊断[J]. 铁道学报, 2015, 37(8):56-57.
- [9] 周庆华, 李晓丽. 基于 MCNN 的铁路信号设备故障短文本分类方法研究[J]. 铁道科学与工程学报, 2019, 16(11):2860-2864.
- [10] 杨连报. 铁路事故故障文本大数据分析关键技术研究及应用[D]. 北京: 中国铁道科学研究院, 2018:3-4.
- [11] 李晓丽. 基于文本挖掘的铁路信号设备故障分类研究[D]. 兰州: 兰州交通大学, 2020:20-21.
- [12] 孙旻. 铁路信号设备故障诊断专家系统相关技术研究[D]. 青岛: 青岛大学, 2009:34-35.
- [13] 王兰勇. 铁路信号设备故障诊断专家系统[D]. 吉林: 吉林大学, 2015:4-5.
- [14] 袁杰, 王福利, 王姝, 赵露平. 基于 D-S 融合的混合专家知识系统故障诊断方法[J]. 自动化学报, 2017, 43(9):1581-1582.

- [15]李娜. 基于信息融合的铁路信号设备故障诊断方法研究[D]. 兰州: 兰州交通大学, 2013:22-26.
- [16]林水生, 卫伯言, 杨海芬, 熊勇, 朱磊基, 于良. 引入新数据源的 D-S 融合检测方法[J]. 电子科技大学学报, 2021, 50(6):861-862.
- [17]Kim Y. Convolutional neural networks for sentence classification [C]Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Doha, Qatar: Association for Computational Linguistics,2014:1746-1751.
- [18]Lai S W, Xu L H, Liu K, et al. Recurrent Convolutional Neural Networks for Text Classification [C]//Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence. ACM, 2015: 2267-2273.
- [19]Johnson R, Zhang T. Deep Pyramid Convolutional Neural Networks for Text Categorization[EB/OL] Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics. 2017:565-567.
- [20]侯雪亮, 李新, 陈远平. 基于多神经网络混合的短文本分类模型[J]. 计算机系统应用, 2020, 29(10):9-19.
- [21]冯勇, 屈渤浩, 徐红艳, 王嵘冰, 张永刚. 融合 TF-IDF 和 LDA 的中文 FastText 短文本分类方法[J]. 应用科学学报, 2019, 37(03):378-388.
- [22]韩众和, 夏战国, 杨婷. CNN-ELM 混合短文本分类模型[J]. 计算机应用研究, 2019, 36(03):663-667+672.
- [23]Xu J, Cai Y, et al. Incorporating context-relevant concepts into convolutional neural networks for short text classification[EB/OL]. 2020: 42-53.
- [24]付静, 龚永罡, 廉小亲, 顾龙浩. 基于 BERT-LDA 的新闻短文本分类方法[J]. 计算机应用, 2021, 2:128-129.
- [25]雷景生, 钱叶. 基于 ERNIE_BiGRU 模型的中文文本分类方法[J]. 上海电力大学学报, 2020, 36(4):329-330.
- [26]牛玉婷, 陈伯琪, 陈彬. 基于改进 ERNIE-DPCNN 模型的中文文本分类[J]. 江苏师范大学学报, 2021, 39(1):47-48.
- [27]Hu B, Shen B, Liu Q. An Experience-Feedback Algorithm of D-S Evidence Theory[C]. International Conference on Information Science and Computer Applications.2013:226-231.

- [28]路军,王梓耀,余涛.基于朴素贝叶斯和 D-S 证据理论的多时空数据融合[J]研究与开发.2019,11:27.
- [29]万继宏,刘后铭.一种高性能目标识别融合算法[J].电子科技大学学报.1995,24(2):137.
- [30]Wickramaratne T. L, Premaratne K, Murthi M N, et al. Belief theoretic methods for soft and hard data fusion[C]. In 2011 IEEE International Conference on Acoustics, Speech and Signal Processing. 2011:2388-2391.
- [31]乔增乾.基于信息融合的铁路货车滚动轴承故障诊断系统研究[D].北京:北京交通大学,2020:15-20.
- [32]田亮,常太华,曾德良,刘吉臻.基于典型样本数据融合方法的锅炉制粉系统故障诊断[J].热能动力工程,2005,20(2):163-164.
- [33]刘晓光,胡学钢.D-S 证据理论在决策支持系统中的应用[J]计算机系统与应用,2010,19(10):112-113.
- [34]王奉涛,马孝江,朱泓,王志鹏.基于 Dempster Shafer 证据理论的信息融合在设备故障诊断中应用[J].大连理工大学学报,2003,43(4):471-473.
- [35]Zhong S, Liu X, Shen Z. Study on the Basic Probability Assignment Based on Grey Relational Analysis and Gaussian Membership. IEEE Access, 2021(9):26556-26567.
- [36]贾韧锋.D-S 证据理论在海洋环境安全态势评估中的应用[D].哈尔滨:哈尔滨工程大学,2016:24-26.
- [37]章巍.基于 D-S 证据理论的数据融合方法设计与实现[D].北京:北京邮电大学,2018:4-5.
- [38]杨晓萍,廉伟健,李孟杰,钱志鸿.基于 Pignistic 概率函数和相关系数的证据组合方法[J].通信学报,2019,40(3):1-7.
- [39]宋香鹏,肖建于,吴克凤,伏明兰.解决冲突证据合成问题的改进 D-S 证据理论算法[J].湖北民族大学学报.2021,39(2):180.
- [40]Liu P, Qiu X, Huang X. Recurrent neural network for text classification with multi-task learning[EB/OL]. arXiv preprint arXiv:1605.05101.2016:2873-2879.
- [41]和志强,杨建,罗长玲.基于 BiLSTM 神经网络的特征融合短文本分类算法[J].

- 智能计算机与应用, 2019, 9 (02) :21-27.
- [42]陶志勇, 李小兵, 刘影, 刘晓芳. 基于双向长短时记忆网络的改进注意力短文本分类方法[J]. 数据分析与知识发现, 2019, 3 (12) :21-29.
- [43]Zhou P, shi W, et al. Attention-based bidirectional long short-term memory networks for relation classification[EB/OL]. Proceedings of the 54th annual meeting of the association for computational linguistics (volume 2: Short papers). 2016:207-212.
- [44]李文慧, 张英俊, 潘理虎. 改进 biLSTM 网络的短文本分类方法[J]. 计算机工程与设计, 2020, 41 (03) :880-886.
- [45]Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[EB/OL]. (2017-06-12). arXiv:1706.03762.
- [46]Radford A, Narasimhan K, Salimans T, et al. Improving language understanding by generative pre-training[EB/OL].(2018)[2021-5-21].
- [47]Devlin J,Chang M W,Lee K,et al.Bert: Pre-training of deep bidirectional transformers for language understanding[EB/OL]. arXiv:1810.04805.
- [48]Sun Y, Wang S H, Li Y K, et al. ERNIE: Enhanced representation through knowledge integration[EB/OL]. (2019-04-19). arXiv:1904.09223.
- [49]李雄平. 高速铁路轨道设备病害的原因分析与整治对策[D]. 北京:中国铁道科学研究院, 2015:5-6.
- [50]汲磊举. 大数据环境下动车组故障关联关系分析关键技术研究与应用[D]. 北京:北京交通大学, 2016:8-9.
- [51]刘敬学, 孟凡荣, 周勇, 刘兵. 字符级卷积神经网络短文本分类算法[J]. 计算机工程与应用, 2019, 55 (05) :135-142.
- [52]雷明珠, 邵新慧. 短文本分类模型的优化及应用[J/OL]. 计算机应用研究, 2021:1-6.
- [53]李承连. 铁路信号设备故障诊断方法发展趋势探析[J]. 中国新通信, 2021, 23 (01) :161-163.
- [54]靳忠福. 高速铁路全电缆贯通线精确故障定位关键技术分析[J]. 铁道科学与工程学报, 2021, 18 (03) :596-604.

- [55] 姜海莲. 铁路机车车辆运行故障监测诊断技术 [J]. 湖北农机化, 2020(18):147-148.
- [56] 孙旭升, 周刚, 于洋, 李凤宇. 机械设备故障预测与健康管理的综述 [J]. 兵工自动化, 2016, 35(01):30-33.
- [57] 李向前. 复杂装备故障预测与健康管理的關鍵技术研究 [D]. 北京: 北京理工大学, 2014.
- [58] 彭宇, 刘大同, 彭喜元. 故障预测与健康管理的技術综述 [J]. 电子测量与仪器学报, 2010, 24(01):1-9.
- [59] 王国薇, 黄浩, 周刚, 胡英. 集成学习在短文本分类中的应用研究 [J]. 现代电子技术, 2019, 42(24):140-145.
- [60] 李嘉菲, 周斌, 刘大有, 胡亮, 王峰. 海量信息融合方法及其在状态评价中的应用 [J]. 软件学报, 2014, 25(9): 2026-2036.

攻读硕士学位期间从事的科研工作及取得的成果

参与课题：

甘肃省自然科学基金项目“深度学习在高原夏菜质量分级中的应用研究”
(21JR1RA283)

发表论文：

[1]宋文琴,尚庆生,巩晴.旅游评论短文本的改进 ERNIE-RCNN 模型分类[J].宜宾学院学报,2021,21(12):53-56.

致谢

随着毕业论文的完成，我的学生生涯也即将告一段落。漫漫十九载求学路，路的那头是一个期待着每周一清晨升旗仪式的少先队员；路的这头已是渴望为国家和社会做贡献的中共党员、硕士毕业生。

我感叹时光匆匆，好像昨天才踏入兰财的校门，而今天就要准备毕业。读研三年，我不仅增长了知识才干，心态上也更加成熟，懂得了立场不同会带来观点的不同，也更加能够全面地看待问题，提高了透过现象看本质和独立思考的能力。如今的我，多了一分沉着和冷静，少了一丝不安和慌张，我相信凭借着“衣带渐宽终不悔，为伊消得人憔悴”的韧性与毅力，我定能翻过高山、越过大海，不惧人生挑战。

当然，我的成长成熟离不开我的老师、室友和实验室小伙伴的关心与帮助。首先，我要感谢我的导师：尚庆生老师，感谢您三年来对我的谆谆教诲和耐心指导。由于我本科的专业与现在的研究方向差异较大，在做研究时经常迷茫困惑，但每次向老师请教时他都从未对我有过批评和不满，总是用最温和的话语指导我、纠正我的不足，让我感到醍醐灌顶、受益匪浅。老师用他谦和儒雅的处世态度、严谨求实的工作作风、开阔敏锐的思维深深地启迪着我和师妹师弟们，因此我们遇到困难也不再犹豫退缩，而是勇敢地迎接挑战。

然后，我要感谢我的三个可爱的室友，我们在同一个空间共同生活了三年，了解彼此的生活习惯，感谢你们包容我早起时不小心发出的声音，也感谢你们在我入睡时特意调小的音量，更要感谢你们在我崴脚时对我的无微不至的帮助，感谢你们陪我度过这段最美好的时光。

同时，我也要感谢每天与我一起学习进步的实验室好友，感谢你们的陪伴、理解与包容，我们曾一起畅谈未来人生规划、互相激励，一起漫步校园、分享喜怒哀乐，一起吃遍兰州美食、看遍兰州美景，我们一起度过了许多快乐的时光，是此生都难忘的时光。

最后，我要感谢支持我学业的父母和爷爷奶奶以及所有给过我帮助和关心的亲朋好友，没有你们就没有我的今天，祝你们：万事顺意，吉星高照！