

学校代号 10532

学 号 S170100045

分 类 号 TU317+.1

密 级 公 开



湖南大学
HUNAN UNIVERSITY

硕士学位论文

基于深度学习理论和机器视觉技术的 桥梁上车载识别研究

学位申请人姓名 裴熠麟

培 养 单 位 土木工程学院

导师姓名及职称 周云教授

学 科 专 业 结构工程

研 究 方 向 结构健康监测

论文提交日期 2020年5月27日

学校代号：10532

学 号：S170100045

密 级：公开

湖南大学硕士学位论文

基于深度学习理论和机器视觉技术的 桥梁上车载识别研究

国家自然科学基金(51878264)

湖南省科技厅科技进步与创新项目(201912)

长沙市科技计划项目(kq1801010)

学位申请人姓名： 裴熠麟

导师姓名及职称： 周云教授

培 养 单 位： 土木工程学院

专 业 名 称： 结构工程

论文提交日期： 2020年5月27日

论文答辩日期： 2020年5月30日

答辩委员会主席： 易伟建教授

Identification research for obtaining spatiotemporal information of
vehicle loads on bridges based on the deep learning theory and
computer vision technology

by

PEI Yilin

B.E. (Lanzhou University of Technology) 2017

A thesis submitted in partial satisfaction of the

Requirements for the degree of

Master of Engineering

in

Structural Engineering

in the

Graduate School

of

Hunan University

Supervisor

Professor ZHOU Yun

May, 2020

湖南大学

学位论文原创性声明

本人郑重声明：所提交的论文是本人在导师的指导下独立进行研究所取得的研究成果。除了文中特别加以标注引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写的成果作品。对本文的研究做出重要贡献的个人和集体，均已在文中以明确方式标明。本人完全意识到本声明的法律后果由本人承担。

作者签名：

日期： 年 月 日

学位论文版权使用授权书

本学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅和借阅。本人授权湖南大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

本学位论文属于

1、保密 ，在 _____ 年解密后适用本授权书。

2、不保密 。

(请在以上相应方框内打“√”)

作者签名：

日期： 年 月 日

导师签名：

日期： 年 月 日

摘 要

作为工程结构振动领域中的反问题研究，有效识别车辆荷载对于评估桥梁结构的性能状态具有重要意义。现有测试技术大多依赖于桥梁动态称重系统(Bridge weigh-in-motion, BWIM)开展。针对其所存在的硬件设施成本较高及安装维护过程需全面或部分封闭交通等不足之处，提出了一种基于深度学习理论及机器视觉技术的桥梁上车辆荷载识别技术，为无需 BWIM 系统支撑的中小型桥梁结构性能监测研究提供新思路。本文主要从以下几方面展开研究：

(1) 提出了一种基于深度学习理论及结构特征响应提取的车辆荷载辨识方法。针对由车辆荷载所引起的桥梁结构动态加速度响应，在经时-频分析技术对其中的特征信息进行提取后，将其转化为二维平面图像输入至卷积神经网络模型中进行自主学习，用以挖掘不同激励源作用下结构响应中所隐含的分布规律及模式，从而完成对外部车载信息的判断识别。即实现了一种利用深度学习网络代替结构系统建模、仅利用输出响应便可获取输入信息的反问题识别技术。

(2) 通过开展数值模拟分析、实验室模型试验及野外现场测试，对所提出的车辆荷载识别方法的有效性进行验证。结果表明，训练后的神经网络模型可较好地实现对车辆荷载的辨识工作，且基于图像变换技术的数据增强训练方式可有效提高神经网络的辨识精度。同时，经大型自然图像集 ImageNet 预训练过的 AlexNet 模型对于数字信号图像分类工作仍具有较强的迁移学习适用性。除此之外，针对某野外试验获得了 97.21% 的测试精度，表明该方法可较好地应用于对实际桥梁结构上车辆荷载的识别研究。

(3) 建立了一种基于非接触式机器视觉技术的车辆荷载信息识别系统。在对常见车辆进行粗分类的基础上，通过统计相关物理参数，建立了车辆类型与载重情况之间的映射关系。基于所建立的大型车辆外观图像 HNU-Vehicle Dataset 数据集，利用 Faster-RCNN 模型进行迭代训练，并结合压缩感知技术，实现了直接从视频图像中识别车辆目标、预测载重区间、检测实时位置及跟踪运动状态等功能。通过分别开展实验室试验及野外试验测试，对所提方法的有效性进行了验证。

(4) 实现了一种基于非接触式摄影测量方式的车辆时空定位识别技术。通过以运营状态下的车辆目标作为参照物，利用基于平行坐标系的级联霍夫变换方法对所形成的正交消失点进行检测，完成了无需标靶的相机自标定过程。通过开展试验测试，利用相机模型对车辆荷载在桥面上的真实位置进行了识别，取得了较为满意的测试结果。除此之外，对该系统在不同测试条件下的稳定性进行了评估。

关键词：深度学习；机器视觉；摄影测量；车辆荷载识别；车辆时空定位；卷积

神经网络；压缩感知；级联霍夫变换

Abstract

As one of the typical inverse problems in structural vibration field, conducting effective distinguish to vehicle loads would play a significant role in the performance assessment of bridges. The current technology is mainly relied on the bridge weigh-in-motion (BWIM) system, which would be restricted in the applications of mid- and shorten-span bridges due to its high-cost devices and complex installation process. Therefore, a novel vehicle loads identification methodology was proposed in the manuscript based on the deep learning theory and computer vision technology, which was mainly conducted as follows:

(1) A novel vehicle loads identification methodology was proposed based on the deep learning theory and structural characteristic responses extraction. Specifically, the time-frequency analysis was employed to extract the feature patterns of bridge acceleration responses induced by the driving vehicles, and the convolutional neural network (DCNN) model was utilized to dig the potential pattern details of extracted features to achieve the system outputs identification based on captured inputs. Therefore, the solution of inverse problem could be transferred by replacing the DCNN as middle structural system, where the inputs could be further obtained by only utilizing the collected output responses.

(2) The numerical analysis, experimental and field test were conducted to further evaluate the effectiveness of proposed method, respectively. A satisfied identification accuracy was investigated according to the test results, and the performance of trained DCNN model could be further enhanced by utilizing the image processing technology to increase the amount of test samples. Meanwhile, it was also revealed that the features extracted from the natural object images dataset by DCNN could be effectively transferred into the classification field of digital signal images. Furthermore, a 97.21% identification accuracy was obtained in the ambient test, which has demonstrated that the vehicle loads information could be directly distinguished from structural responses by the proposed approach.

(3) A vehicle loads identification system was established based on the non-contact computer vision technology. Specifically, with the proposed rough-grained classification standard of common vehicles, the mapping relationship was established between vehicle types and corresponding weights interval. And the Faster-RCNN model trained by the HNU-Vehicle Dataset was utilized to detect

vehicle objects, loading condition and real-time position from monitoring videos. Furthermore, the motion trajectory of driving vehicles could also be detected by the compressive sensing technology. Experimental and field test were both conducted to evaluate the effectiveness of proposed method, respectively.

(4) A novel vehicle spatiotemporal information identification technology was achieved based on the non-contacted photogrammetry technology. The vehicle loads under driving state was selected as the calibration object, and the corresponding vanish points were detected by the parallel coordinate-based cascade Hough transform technology, which has achieved the camera calibration process without the support of targets. The effectiveness of proposed method was verified by distinguishing the actual position of vehicle loads, showing that this technology could be effectively utilized to obtain vehicle loads position even under the complex test condition.

Key Words: Deep learning; Computer vision technology; Non-contact photogrammetry technology; Vehicle loads identification; Vehicle spatiotemporal information identification; Convolutional neural network; Compressive sensing technology; Cascade Hough transform method

目 录

学位论文原创性声明和学位论文版权使用授权书	I
摘要	II
Abstract	IV
插图索引	X
附表索引	XIV
第 1 章 绪论	1
1.1 研究背景	1
1.2 车载识别技术研究进展	2
1.2.1 桥梁动态称重方法	3
1.2.2 新型车载识别方法	6
1.3 智能监测技术研究现状	8
1.3.1 深度学习技术	8
1.3.2 机器视觉技术	12
1.4 本文主要研究内容	14
1.4.1 选题依据	14
1.4.2 研究内容	15
第 2 章 基于深度学习理论的车辆荷载识别模拟研究	18
2.1 引言	18
2.2 时-频分析理论	18
2.2.1 小波变换技术	18
2.2.2 短时傅里叶变换技术	20
2.2.3 维格纳变换技术	20
2.3 深度学习理论	21
2.3.1 深度学习理论概述	21
2.3.2 卷积神经网络概述	21
2.3.3 卷积神经网络结构	22
2.4 经典卷积神经网络模型	27
2.4.1 AlexNet 模型	28
2.4.2 VGG-16 模型	28
2.5 卷积神经网络训练原理	29
2.5.1 特征信息传递	29
2.5.2 随机梯度下降	31

2.5.3 泛化能力评估	32
2.5.4 训练优化方式	33
2.6 车-桥振动简化模拟测试.....	34
2.6.1 简化模型经典解析理论	34
2.6.2 移动荷载-简支梁模型建立	38
2.6.3 移动荷载识别	38
2.7 车-桥耦合振动模拟测试.....	45
2.7.1 车-桥耦合振动理论	45
2.7.2 车-桥耦合振动测试	50
2.7.3 车辆荷载识别	56
2.8 本章小结	60
第3章 基于深度学习理论的车辆荷载识别试验研究.....	62
3.1 引言	62
3.2 试验测试方案	62
3.2.1 试验平台	62
3.2.2 试验流程	65
3.3 车辆载重识别	67
3.3.1 试验测试方案设计	67
3.3.2 特征响应数据库建立.....	69
3.3.3 卷积神经网络训练	71
3.4 行驶速度识别	74
3.4.1 试验测试方案设计	74
3.4.2 特征响应数据库建立.....	74
3.4.3 卷积神经网络训练	76
3.5 车辆类型识别	78
3.5.1 试验测试方案设计	78
3.5.2 特征响应数据库建立.....	79
3.5.3 卷积神经网络训练	80
3.6 行驶车道识别	82
3.6.1 试验测试方案设计	82
3.6.2 特征响应数据库建立.....	82
3.6.3 卷积神经网络训练	84
3.7 车辆荷载信息综合检测.....	85
3.7.1 试验测试方案设计	85
3.7.2 车辆荷载信息识别结果.....	86

3.8 野外实桥测试	87
3.8.1 工程概况	87
3.8.2 测试方案	88
3.8.3 试验测试结果	90
3.9 本章小结	92
第 4 章 基于深度学习理论及压缩感知技术的车辆检测跟踪研究	94
4.1 引言	94
4.2 车辆检测跟踪算法	94
4.2.1 目标检测理论概述	94
4.2.2 基于 Faster-RCNN 的目标检测理论	95
4.2.3 目标跟踪理论概述	99
4.2.4 基于压缩感知技术的目标跟踪理论	99
4.3 实验室试验测试	103
4.3.1 神经网络训练	103
4.3.2 车辆目标检测跟踪	105
4.3.3 环境干扰测试	106
4.4 野外试验测试	108
4.4.1 数据库建立	108
4.4.2 神经网络训练	112
4.4.3 车辆目标检测跟踪	113
4.5 本章小结	116
第 5 章 基于摄影测量技术的车辆荷载时空定位研究	117
5.1 引言	117
5.2 相机标定理论	117
5.2.1 摄影测量坐标系	117
5.2.2 相机内/外参数	119
5.2.3 相机标定方法	121
5.3 基于消失点标定的车载信息识别研究	123
5.3.1 正交消失点理论	123
5.3.2 基于平行坐标系的级联霍夫变换	124
5.3.3 相机标定流程	128
5.4 试验测试分析	130
5.4.1 试验测试平台	130
5.4.2 相机自标定模型建立	130
5.4.3 车辆时空位置识别	131

5.5 非接触式视频监测系统	133
5.6 本章小结	133
结论与展望	135
参考文献	138
致谢	151
附录 A (攻读学位期间发表的学术论文)	152

插图索引

图 1.1 桥梁垮塌事故案例	2
图 1.2 工程结构振动问题分类	3
图 1.3 桥梁动态称重系统原理示意图	4
图 1.4 桥梁动态称重系统现场安装情况	5
图 1.5 新型虚拟简支梁法识别车辆荷载信息	7
图 1.6 基于视频监控技术的桥梁结构防倾覆监测系统	8
图 1.7 基于 DCNN 网络的结构损伤识别方法	9
图 1.8 基于 DCNN 网络的钢结构锈蚀识别方法	11
图 1.9 基于 DCNN 网络的混凝土强度识别方法	11
图 1.10 基于机器视觉技术的人致冲击荷载测试方法	14
图 1.11 国家自然科学基金研究内容示意图	15
图 1.12 研究内容一流程示意图	16
图 1.13 研究内容二流程示意图	17
图 2.1 DCNN 网络基本结构	23
图 2.2 卷积层操作示意图	24
图 2.3 DCNN 网络常用激活函数	24
图 2.4 池化层操作示意图	26
图 2.5 AlexNet 卷积神经网络模型	28
图 2.6 VGG-16 卷积神经网络模型	29
图 2.7 混淆矩阵示意图	32
图 2.8 迁移学习示意图	33
图 2.9 统计模型拟合现象分类	34
图 2.10 匀速移动集中力模型	35
图 2.11 匀速移动集中质量模型	36
图 2.12 匀速移动弹簧-质量模型	37
图 2.13 移动荷载-简支梁模型建立	38
图 2.14 不同时-频分析技术提取特征响应信息对比	39
图 2.15 不同载重工况下简支梁模型响应数据库	40
图 2.16 AlexNet 模型迁移学习示意图	41
图 2.17 DCNN 网络模型训练结果	42
图 2.18 不同时-频分析技术提取特征响应信息对比	43
图 2.19 不同速度工况下简支梁模型响应数据库	44

图 2.20 DCNN 网络模型训练结果.....	45
图 2.21 车-桥耦合分析常用车辆动力学模型	46
图 2.22 车-桥耦合振动有限元模型建立.....	51
图 2.23 有限元模型位移/荷载转化示意图	52
图 2.24 路面粗糙度设置	55
图 2.25 车-桥耦合分析计算流程示意图.....	55
图 2.26 不同时-频分析技术提取特征响应信息对比	56
图 2.27 不同车型作用下桥梁模型响应数据库	57
图 2.28 DCNN 网络模型训练结果.....	58
图 2.29 不同时-频分析技术提取特征响应信息对比	59
图 2.30 不同车道行驶下桥梁模型响应数据库	59
图 2.31 DCNN 网络模型训练结果.....	60
图 3.1 实验室缩尺车-桥振动模型	62
图 3.2 实验室缩尺桥梁模型示意图.....	63
图 3.3 试验平台测点布置示意图.....	64
图 3.4 缩尺卡车模型轴重测试	65
图 3.5 测试所用三轴卡车模型	65
图 3.6 测点处加速度传感器布置情况	66
图 3.7 试验测试所用仪器设备	66
图 3.8 车载识别所用试验平台及测试工况设置	67
图 3.9 不同时-频分析技术提取特征响应信息对比	70
图 3.10 不同载重工况下桥梁模型响应数据库	71
图 3.11 DCNN 网络模型训练结果.....	72
图 3.12 图像变换技术扩充数据库规模	73
图 3.13 DCNN 网络模型优化训练结果	74
图 3.14 车速识别所用试验平台及测试工况设置.....	74
图 3.15 不同时-频分析技术提取特征响应信息对比	75
图 3.16 不同速度工况下桥梁模型响应数据库	76
图 3.17 DCNN 网络模型训练结果.....	77
图 3.18 DCNN 网络模型优化训练结果	78
图 3.19 车型识别测试所用五轴车模型	78
图 3.20 不同时-频分析技术提取特征响应信息对比	79
图 3.21 不同车型作用下桥梁模型响应数据库	80
图 3.22 DCNN 网络模型训练结果.....	81
图 3.23 DCNN 网络模型优化训练结果	81

图 3.24 车道识别所用试验平台及测试工况设置.....	82
图 3.25 不同时-频分析技术提取特征响应信息对比	83
图 3.26 不同车道行驶下桥梁模型响应数据库	83
图 3.27 DCNN 网络模型训练结果.....	84
图 3.28 DCNN 网络模型优化训练结果	85
图 3.29 车辆荷载信息综合检测系统示意图	86
图 3.30 测试样本车辆荷载信息分布情况	86
图 3.31 车辆荷载信息检测识别结果	87
图 3.32 野外测试所用桥梁结构示意图	88
图 3.33 试验测试所用加载卡车.....	88
图 3.34 试验测试所用仪器设备.....	89
图 3.35 现场试验测试概况	90
图 3.36 时-频分析技术处理下图像特征信息提取	91
图 3.37 DCNN 网络模型训练结果.....	91
图 3.38 DCNN 网络模型优化训练结果	92
图 4.1 Faster-RCNN 神经网络结构示意图	96
图 4.2 RPN 网络区域建议选取	96
图 4.3 Faster-RCNN 网络特征目标选取	97
图 4.4 基于压缩感知理论的目标跟踪原理	100
图 4.5 基于压缩感知理论的目标跟踪流程	101
图 4.6 测试所用车辆模型	104
图 4.7 车辆模型图像数据库	104
图 4.8 实验室试验所用测试平台	105
图 4.9 运动车辆目标检测跟踪效果.....	106
图 4.10 不同测试工况设置	107
图 4.11 环境干扰测试下目标检测跟踪效果分析.....	108
图 4.12 基于非接触式机器视觉技术的车辆荷载识别方法示意图.....	108
图 4.13 基于机器视觉技术的桥梁结构性能评估示意图	110
图 4.14 相关车辆物理信息统计示意图	111
图 4.15 车辆图像数据库建立思维示意图	111
图 4.16 现场拍摄方式建立车辆图像数据库	112
图 4.17 Faster-RCNN 标记车辆目标示意图	113
图 4.18 基于 Faster-RCNN 的目标检测任务示意图.....	113
图 4.19 车辆目标检测识别结果.....	114
图 4.20 野外现场测试情况	114

图 4.21 实际测试条件下车辆目标识别效果	115
图 4.22 不同测试场景下车辆目标识别效果	115
图 5.1 摄影测量原理示意图	118
图 5.2 摄影测量不同坐标系统示意图	118
图 5.3 基于一维特征尺的相机标定方法	122
图 5.4 基于二维标定平面的相机标定方法	122
图 5.5 正交消失点示意图	124
图 5.6 平行坐标系示意图	126
图 5.7 级联霍夫变换示意图	127
图 5.8 基于笛卡尔及平行坐标系的级联霍夫变换空间	128
图 5.9 基于消失点理论的相机自标定方法流程图.....	129
图 5.10 试验测试所用桥梁模型平台	130
图 5.11 桥梁上监控摄像机模型	131
图 5.12 车辆模型定位测试结果	132
图 5.13 非接触式监测系统流程示意图	133
图 5.14 车辆荷载智能化监测系统操作平台示意图.....	133

附表索引

表 2.1 车-桥耦合分析常用车辆动力学模型参数取值	46
表 2.2 模拟所用车辆模型参数取值	51
表 2.3 ISO-1972 路面粗糙等级分类标准	54
表 3.1 测试所用桥梁模型相似比参数	63
表 3.2 试验卡车模型参数取值	65
表 3.3 试验所用车辆模型轴重参数值	67
表 3.4 图像处理技术变化量值	72
表 3.5 试验所用五轴车模型参数取值	78
表 3.6 试验所用卡车参数取值	89
表 4.1 车辆数据库信息区间统计	111

第1章 绪 论

1.1 研究背景

作为连接现代化交通的咽喉命脉，桥梁结构在国民经济和社会生活中均发挥着极其重要的作用；同时，建造桥梁结构及开展必要的维护过程也是各国家基础设施建设规划中的重要环节之一，其相应代表了该国家的经济发达程度及与工程科技水平。根据相关数据统计结果可知，美国和日本现分别建成桥梁约 61.07 万及 69.81 万座^[1~2]；我国目前所拥有桥梁数量约为 84.42 万座，其中包括 77.92 万座公路桥梁和 6.5 万座铁路桥梁^[3]。

近年来，随着社会经济的不断发展，我国交通运输总量也得以迅速增长。然而，所伴随产生的车辆超载、超速及违法变道等不规范驾驶行为也日益增多，对桥梁安全情况将造成一定影响。根据相关事故分析报告及媒体报道可知，许多桥梁建成后在其服役年限还未达到十年时便已发生了严重失效，归其原因主要可能为超载车辆行驶所致。具体而言，超载车辆将对桥梁结构产生不可逆转的累积损伤，将显著影响结构承载力、并造成运营年限缩短，甚至可能导致结构发生部分或整体垮塌。

据统计资料可知，我国于 2000 年至 2012 年之间约有 150 余座桥梁结构先后发生跨塌^[4]。具体案例分析方面，2009 年，津-晋高速公路上某处匝道桥发生整体倾覆事故，并造成五辆超载卡车直接坠落；2010 年，南京市区内环西线处某钢箱梁桥发生侧翻，并造成 7 死 3 伤的严重后果；2011 年，福建省武夷山公馆大桥某处被报道发生垮塌事故，造成原因经查明为一严重超载的重型货车在桥上行驶所致；2014 年，重庆市江北区某在建立交箱梁发生侧翻，事故造成 3 死 3 伤的严重后果；2014 年，哈尔滨市阳明滩大桥引桥处某匝道发生整体垮塌，并造成了四辆货车坠落的严重事故；2015 年，粤-赣高速某匝道桥突然发生断裂，该坍塌事故导致四辆货车直接坠落；2016 年，上海市中环线高架发现桥面严重损坏现象，经分析研究后认为事故导致原因可能为超载车辆在桥面上行驶所致；2019 年，位于我国台湾宜兰县的南方澳跨海大桥发生了严重的垮塌事故；2019 年，江苏无锡 312 国道至上海方向 K135 处的锡港路上跨桥发生桥面侧翻事故，造成了 3 死 2 伤的严重经济损失及恶劣社会影响。此类安全事故在国外相关报道中也屡见不鲜：1967 年，美国银桥突然于短时间内发生了完全倒塌，事故直接导致 50 余辆正常行驶的车辆坠入俄亥俄河中，并最终造成 46 人丧生；1994 年，韩国首尔圣水大桥某桥面板发生整体坍塌事故，导致 6 辆汽车直接坠入汉江；2002 年，阿根廷南部某市

发生了一起严重的桥梁坍塌事故；2003年，印度西部达曼市的一座桥梁因车辆超载导致坍塌事故突发；2007年，美国明尼苏达州某桥梁在交通高峰期无征兆地突然发生倒塌；2014年，巴西贝洛奥里藏特市某高架桥突发垮塌事故，并造成至少2人丧生的严重后果。一些典型的桥梁垮塌事故如图1.1所示。



图 1.1 桥梁垮塌事故案例

通过上述事故案例教训可知，对车辆荷载进行有效辨识是国内外所迫需解决的热点及难点问题。目前，所使用的常规技术手段是利用称重系统记录车辆荷载作用下桥梁结构的应变响应，并经相关算法处理后，即可实现对车辆轴重、总重等信息的估计识别^[5]。该理论及系统的出现为车载信息辨识技术研究提供了有力支撑。然而，高昂的硬件设施成本却极大地制约了该动态监测系统在量大面广桥梁结构上的普及应用程度；同时，当车辆以较高速度(>40km/h)行驶时，该系统也存在着测试精度有待提高等不足之处；除此之外，该系统中相关硬件设备在安装及维修过程中通常也需要全面或部分封闭交通^[6]。因此，研发适用于量大面广桥梁、具有普适性以及方便快捷的车辆荷载识别技术，对于保证桥梁结构的安全正常运营具有极其重要的意义。

针对上述工程项目中所存在的实际需求及现有检测技术所潜在的症结之处，本文拟研究一种基于深度学习理论及非接触机器视觉技术的桥梁结构上车辆荷载快速识别方法。整个研究项目将具有“无需交通封闭”和“无需动态称重系统支持”等重要特征，可为实现桥梁快速的结构状态评估提供新思路，是实现“智能桥梁检测(Intelligent bridge inspection, IBI)”和“智慧交通系统(Intelligent transportation system, ITS)”的重要手段。

1.2 车载识别技术研究进展

如何对桥梁系统上的车辆荷载信息进行有效识别，本质上属于一类经典的工程振动问题研究。具体而言，对于一个动力学振动系统来说，其所涉及的系统输入、系统模型及系统输出等三个物理量之间是相互耦合的，三者共同构成了一个统一的封闭整体。在理论上，当已知其中任意两个系统物理量后，即可根据数学

关系求解出另外的物理量^[7]。其中，当系统输入及内部参数已知时，对其输出情况进行求解的过程通常被称为动力学正问题研究；当系统输入及输出情况已知时，对其内部参数进行求解的过程通常被称为动力学第一类反问题研究；当系统内部参数及输出已知时，对其输入情况进行求解的过程则被称为第二类反问题研究。随着相关科学研究问题的不断深入，基于动力学的工程振动问题研究在结构参数识别、物理损伤诊断及系统动力性能优化等方面得到了诸多应用(作者曾先后参与了关于振动正问题及第一类反问题方面的研究，由于篇幅原因在此不作赘述)，如图 1.2 所示。然而，受复杂自然环境及测试条件等因素限制，实际工程项目中的荷载输入信息通常难以准确获取，且有效识别外界荷载对于判断工程损伤情况、评估结构性能安全具有重要意义。因此，开展基于车辆荷载信息识别的第二类反问题研究工作是十分必要的。

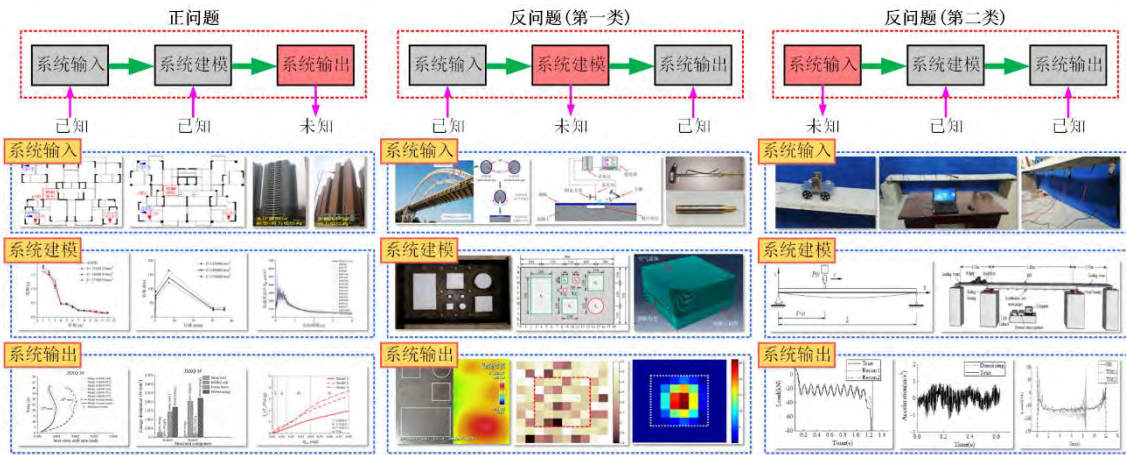


图 1.2 工程结构振动问题分类

1.2.1 桥梁动态称重方法

作为近年来所常用的一种检测装置，动态称重系统(Weigh-in-motion, WIM)已被广泛应用至道路或桥梁上所行驶车辆的荷载信息监测辨识用途当中。传统 WIM 系统通常需要在工程结构表面预先埋置压电电缆或磁性开关，用以实现对行驶车辆轴距、载重情况及行驶速度等信息的识别。从实际工程应用角度而言，WIM 系统不仅存在维护检修所需费用成本较高等问题，且在安装完成后也难以进行二次更换，在功能实用性方面相对不足。除此之外，大量研究成果表明，传统 WIM 系统的测试精度也较为有限^[8-9]。

在实际工程应用中，若将监测传感器直接安装在道路结构表面，则其在使用过程中将直接承受巨大的车轮荷载作用，从而易导致其性能退化，并缩减使用年限。同时，路面传感器在安装和维修过程中通常需要部分或全面中断交通。除此之外，由于路面传感器与车轮间相互接触的时间相对较为短暂，因此导致相应测试结果对路面的粗糙度情况较为敏感；且当传感器与结构间的接触关系发生变化

时，其测量精度也将迅速下降。因此，为提高动态称重系统性能的耐久性、并保证交通正常运营及避免测试精度降低，欧盟率先提出了无需路面传感器(Free of axle detector, FAD)的动态称重技术。其通过在桥梁结构的桥面板下方安装 FAD 传感器(如图 1.3 所示)，避免了传统路面式传感器所可能产生的诸多问题^[10]。




图 1.3 桥梁动态称重系统原理示意图

作为一种以现场实际桥梁结构作为称重载体的车辆荷载识别技术，桥梁动态称重系统(Bridge weigh-in-motion, BWIM)通过安装在桥梁底部的车轴传感器，在分析车辆荷载作用下桥梁结构所产生峰值信号的基础上，可有效实现对车辆类型、车轴数目、轴距长度及行驶速度等信息的判断识别；同时，通过利用称重传感器对车载作用下结构所产生的动力响应进行实时测量，可有效实现对车辆轴重及总重等信息的评估。与传统 WIM 系统有所不同，BWIM 系统的优势在于所涉及到的监测传感器均安装在桥梁结构底部，相应的调试及检修过程也均在桥底进行开展，因此可在不显著影响桥面交通运营情况的前提下实现对所行驶车辆荷载的识别，如图 1.4 所示。同时，这种安装方式还有效减缓了因恶劣服役环境对传感器性能所造成的损害。除此之外，通过监测因车辆荷载作用所致的实时动态响应信号，可有效获取桥梁结构的真实影响线、车载分布参数及冲击系数等信息^[11]。综上所述，BWIM 系统凭借诸多优势，现已在美国、法国、芬兰、加拿大及斯洛文尼亚等国家得以广泛应用。科学问题研究方面，国内外相关学者也对此开展了大量研究。



图 1.4 桥梁动态称重系统现场安装情况

1979 年, Moses 等^[12]基于影响线理论提出了 BWIM 系统的概念, 并成功实现了对车辆轴重的测试识别。同时研究成果还表明, 当测试传感器安装在桥梁底部时, 可有效降低车-桥接触点激励所产生动荡响应。值得说明的是, Moses 算法也成为了后来现代化商业 BWIM 系统的基本架构。

1997 年, 欧盟颁布了《欧洲动态称重指南》, 对 BWIM 系统的适用条件、标定方法及测试精度等细节要求做了统一规范^[13]。同年, 欧盟在对 BWIM 系统的测试识别精度进行大量研究的基础上, 通过启动 WAVE (Weigh-in-motion of axles and vehicles for Europe)项目^[14], 开始正式将 BWIM 系统作为检测工程实际运营车辆是否超载的重要技术之一。

2000 年, Ojio 等^[15]首次将 BWIM 系统应用至钢桁架桥梁上的行驶车辆监测问题研究当中。其通过在结构不同截面处布置多个测试传感器, 最终实现了对车辆轴距、载重及所在位置的判断识别。

2002 年, Znidaric 等^[16]通过对桥梁结构边界条件及影响线峰值进行处理, 有效实现了对弯矩影响线的解析值修正, 使测试所得结果更加符合实际情况, 极大地提高了 BWIM 系统的测试精度及适用范围。

2009 年, Kim 等^[17]为解决传统 BWIM 系统对大跨度桥梁测试精度有限这一关键问题, 提出了一种基于人工神经网络及 BWIM 装置相结合的智能检测系统。通过在某大跨度预应力混凝土简支桥梁及某大跨度斜拉桥上分别进行现场试验, 对所提方法的有效性进行了测试。

2010 年, Obrien 等^[18]基于 BWIM 监测数据和蒙特卡罗模拟结果, 有效评估了车辆交通通行密度对桥梁结构整体性能的影响程度。随后, Obrien 等^[19]又利用经 BWIM 系统测试所得的桥梁结构剪应变信号, 实现了对车辆荷载中车轴信息的

判断识别。

2012年, Gonzalez等^[20]通过沿桥长方向布置多个称重传感器, 利用监测所得结构应变响应值对 BWIM 系统测试方程中所存在的病态项进行了合理消除, 有效地实现了对车辆实际轴重情况的求解。

2013年, Buro等^[21]通过采用基于 Tikhonov 正则化理论的求解方法, 完成了对行驶车辆实际轴重稳定解的推导。研究表明, 当车辆荷载的动力效应越显著时, 该方法的收敛效率将随之降低。

2013年, Zhao等^[22]为解决传统 BWIM 理论仅能对车辆荷载纵向分布情况进行识别这一问题, 提出了可考虑车载横向分布效应的二维 Moses 算法。其通过利用桥梁结构各测点处的应变响应值, 对传感器所在位置处的结构影响线进行求解, 进而实现了对行驶车辆荷载信息的测试识别。同时, Zhao等^[11]通过利用经现场试验标定过的桥梁结构影响线, 有效地提高了 BWIM 系统在车辆行驶速度、载重情况及轴距信息等方面的识别精度。

2016年, Bao等^[23]通过展开野外试验测试, 利用 BWIM 系统测试所获得的外加荷载下桥梁结构的剪应变响应信号, 实现了对车辆实际轴重情况的判断识别。

2016年, 赵华等^[24]经数值模拟研究发现, 小波变换能够对车轴经过称重传感器时所产生动态信号的不连续变化斜率进行有效放大。在此基础上, 通过对野外桥梁开展现场测试, 验证了采用小波变换技术的 BWIM 系统能够较好地实现对车辆行驶速度的辨识。除此之外, 对于车轴传感器所得的结构响应信号, 也可利用最小 Shannon 熵值法及对车轴信息进行识别。

1.2.2 新型车载识别方法

如前述章节中所讲, 尽管许多学者围绕着 BWIM 系统开展了大量研究, 但在实际应用中, 高昂的硬件设施成本一定程度上仍制约了该系统在量大面广桥梁结构上的普及程度; 同时, 该系统还存在着多轴车轴重识别较低、适用桥型有限等不足之处。因此, 研发一种新型桥梁上车辆信息识别技术具有重要意义。

2010年, Deng等^[25]通过分析桥梁的实时应变响应, 经反算后得到施加在结构上的外部荷载, 进而提出了一种利用桥梁影响面获取车辆动态荷载时程响应的方法。同时, 通过开展野外实桥试验测试, 对所提方法的可行性进行测试。结果表明, 该方法可较好地考虑桥梁惯性力对结构响应的影响, 且能够将车辆重量的识别误差控制在 3%以内。

2013年, Bao等^[26]考虑到重载货车在桥面上的分布情况具有空间稀疏性特性, 故提出了一种基于压缩感知理论的斜拉桥上运营重载货车分布情况识别方法。在建立车-桥耦合模型、利用影响线理论实现车载与拉索索力之间线性映射关系的基础上, 利用压缩感知理论对索力测点进行随机选取, 并通过引入稀疏约束的方式

实现了对车载分布信息的获取。

2016年, Ojio 等^[27]研发了一种基于非接触式摄影测量技术的 cBWIM 系统, 通过利用安装在桥梁上方的监控摄像头对车辆的运动过程进行记录, 并利用 Lukas-Kanade 光流法实现了对车辆所在位置及轴距信息的识别; 同时, 通过利用额外的摄像头对桥梁结构上的螺栓振动情况进行捕捉, 并基于此实现了对桥梁挠度的测量。

2016年, He 等^[28]通过将布置在桥梁结构主梁上的 4 个测点虚拟成一根简支梁, 提出了一种可用于实现对车辆行驶速度、轴距及轴重识别的虚拟简支梁法, 如图 1.5 所示。该方法不仅能够较好地消除因主梁边界条件不确定性对测试结果造成的影响, 还有效提高了对车辆轴重的测试识别精度。




图 1.5 新型虚拟简支梁法识别车辆荷载信息

2017年, Lydon 等^[29]通过利用光纤传感器, 研发了一种可用于车轴识别的 Nor-BWIM 系统, 并在保证获得准确应变响应信号的基础上, 有效缓解了噪声对测试信号的影响程度。

2018年, Algoji 等^[30]提出了一种利用声学信号进行车辆所在位置及行驶速度等信息识别的新方法, 并通过开展野外实桥试验对所提方法的有效性进行测试。其通过在桥梁入口及出口位置处的伸缩缝附近分别安置麦克风传感器, 对车轴经过伸缩缝时结构所产生的声波信号进行采集分析, 从而获得相应的车轴信息。

2019年, 朱全军等^[31]针对车辆进入(驶出)简支桥梁时刻对结构支座反力影响较大这一特点, 提出了一种利用桥梁支座反力进行车辆轴重识别的新方法。在求得车轴所在位置的基础上, 利用实测支座反力对车辆轴重进行计算, 从而较好地避免了传统 BWIM 系统需要高昂硬件设施支持这一不足之处。

2019年, Dan 等^[32]通过监测实际运营车辆荷载信息, 建立了一套桥梁结构防倾覆预警系统。整个系统分为动态称重子系统和视频监控子系统两部分。其中, 通过称重系统对车辆的速度、轴重及轴距等信息进行识别, 并利用视频监控实现对车辆所在位置的识别, 从而得到实际运营车辆荷载在桥梁结构上的实时分布情况。通过结合结构有限元分析结果, 即可得出桥梁结构发生倾覆时的极限抗倾覆力矩, 如图 1.6 所示。

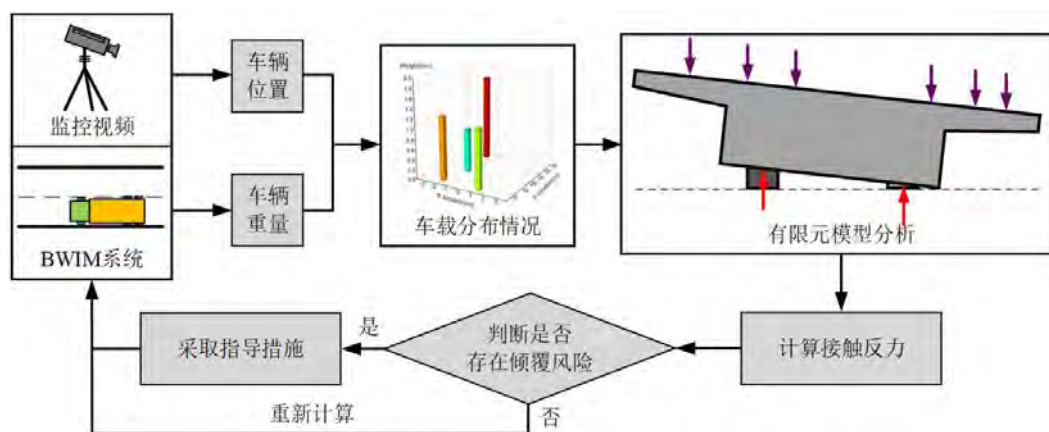


图 1.6 基于视频监控技术的桥梁结构防倾覆监测系统

1.3 智能监测技术研究现状

结构健康监测技术(Structural health monitoring, SHM)最早兴起于 20 世纪末,是指利用现场所设的无损传感系统对结构整体行为进行实时监测,并通过分析特征响应等方式实现对结构损伤程度及定位的判断识别,从而有效反演结构实际承载力及可靠性,最终为建筑结构的养护维修、损伤预警提供依据和指导^[33]。另一方面,随着计算机科学技术的不断发展,近年来以人工智能技术为依托的科学问题研究得以实现创新突破。其中,在结构健康监测领域,各国学者们已开始尝试通过机器学习方法对监测数据中所隐含的结构本质行为规律进行探索,希望通过深度学习理论,能够有效分析传统函数解析模式中所难以解决的结构特征模式。除此之外,基于机器视觉技术的结构健康监测研究凭借其“非接触式传感”、“无需破坏结构”及“测试成本低廉”等优点,开始逐渐成为人们所关注的热点。

1.3.1 深度学习技术

作为信息社会高速发展的科技产物,“大数据”(Big data)凭借其信息量丰富、增长率高及形式多样化等诸多特点,已开始逐渐在各工程实践及科技研究领域展现出独特优势。与传统人工学习行为相比,基于大数据的机器智能学习方式在提升计算规模、降低计算成本方面具有独特优势,因而有效地推动了相关产业的智能化建设进程。

随着计算机科学技术的不断发展与创新突破,近年来以人工智能技术为依托的自然科学研究得以迅速发展。2017年,国务院颁布《新一代人工智能发展规划》白皮书,开始着重将人工智能提升至国家战略发展目标层次。作为人工智能领域内所取得的重要成绩,深度学习(Deep learning)技术现已在语音识别、机器视觉、图像分析等众多研究领域得以广泛应用^[34]。目前,深度学习技术在土木工程领域内的应用主要集中在混凝土表面裂缝识别、钢结构表面锈蚀识别、道路表面病害识别以及交通流实时预测等方面^[35],所涉及到的神经网络模型主要包括深层卷

积神经网络(Deep convolutional neural network, DCNN)、深度置信网络(Deep belief network, DBN)和深层循环神经网络(Deep recurrent neural network, DRNN)等, 相关学者也据此开展了大量研究^[36]。

2012年, 徐珊珊等^[37]通过设计基于渐进式学习方式的 DCNN 网络模型, 对木材的缺陷程度进行了分析。测试结果表明, 该计算方法不仅能够达到较高的识别精度, 且计算效率较高, 同时在鲁棒性测试方面也表现出了较为优异的性能。

2013年, Catbas 等^[38]针对因结构不确定性因素所可能导致的有限元分析误差问题, 搭建了基于 Levenberg-Marquardt 算法的人工神经网络, 并将其应用至工程结构的可靠度问题研究当中。

2017年, Abdeljaber 等^[39]将 DCNN 网络应用至工程结构的损伤问题研究当中。通过以某平面钢框架为例进行计算, 成功地从该结构的响应中自主提取出对损伤工况较为敏感的信号特征, 并最终实现了对损伤所在位置及累计程度的判断识别。

2017年, Lin 等^[40]通过开展数值模拟计算, 利用简支梁模型建立了不同损伤工况下的结构特征响应数据库, 并将各测点处的信号响应输入至 DCNN 网络中进行迭代训练, 最终实现了对结构损伤位置的判断识别, 且获得了较高的测试精度, 如图 1.7 所示。

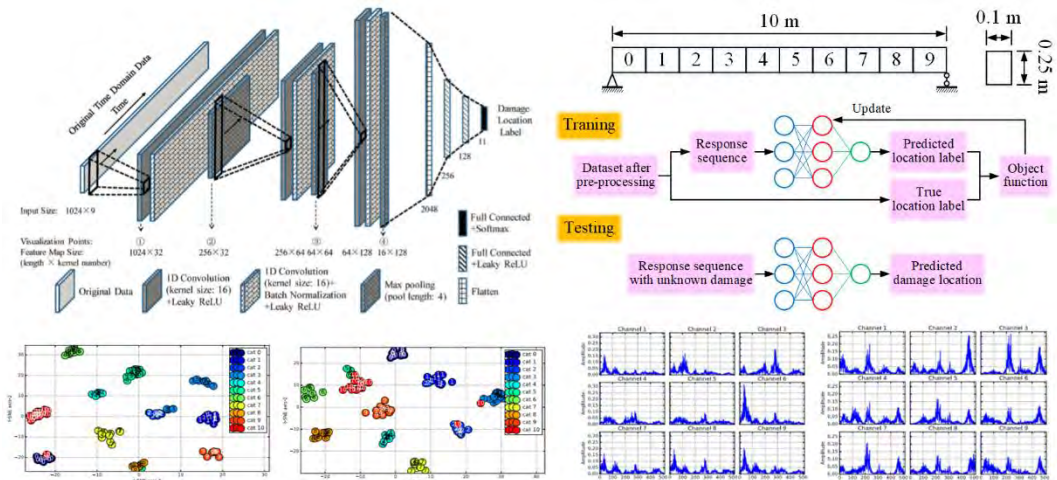


图 1.7 基于 DCNN 网络的结构损伤识别方法

2017年, Gopalakrishnan 等^[41]利用迁移学习技术, 将经大型自然数据集 ImageNet 预训练过的深度学习模型应用至对沥青水泥缺陷损伤图像的训练学习任务当中, 并最终实现了一种对交通路面破损程度的自动检测与分类技术。

2017年, Cha 等^[42]利用 DCNN 网络对混凝土结构表面裂缝进行了测试识别, 其中针对所测试的图像未进行任何人为特征提取工作。试验结果表明, DCNN 网络能够对图像中裂缝等特征信息进行自主识别学习, 从而可实现对裂缝所在位置的判断识别; 且该方法在光照、阴影等复杂情况下也能保持较好的识别效果。

2017年, Tan 等^[43]为充分利用深度学习理论及传统机器学习方法各自具备的独特优势, 通过将 DCNN 网络与基于高斯算法的受限玻尔兹曼机器相结合, 建

立了一种混合机器学习算法；并通过现场试验测试的方式，实现了对短时交通状况的预测评估。

2018年，王达磊等^[44]利用深度学习网络实现了一种针对钢结构表面锈蚀情况的检测方法。其通过对锈蚀图像进行语义分割，较好地解决了对锈蚀程度的量化评估。

2018年，冯微等^[45]针对经车辆撞击后桥墩损伤程度评估这一问题，在推导损伤等级计算公式、建立损伤判断模型的基础上，利用 DBN 网络实现了对桥墩损伤程度的判断分析。试验结果表明，该方法与传统机器学习算法相比计算效率更高。

2018年，Wang 等^[46]分别利用两种 DCNN 神经网络模型，对包含砌体结构不同损伤情况在内的大型图像数据库进行训练，最终实现了对某历史建筑砖石砌体结构的性能检测工作。测试结果表明，该方法对砖石完整、破裂、风化及剥落等四类状态的平均检测精度达到了 94.3%，可较好地应用至类似工程结构的检测任务当中。

2018年，薛亚东等^[47]基于 DCNN 网络提出了一种地铁隧道损伤新型检测方法。其在利用视频拍摄建立隧道损伤图像数据库的基础上，通过优化 DCNN 神经网络的卷积核，对样本库进行了分类训练，并最终获得了准确率超过 95%的测试结果。

2018年，沙爱民等^[48]针对路面损伤识别检测问题，通过利用 DCNN 网络对路面损伤图像数据库进行了分类训练。试验结果表明，当测试图像的像素分辨率高于 70pixel 时，该方法对裂纹、坑槽等损伤工况具有较好的测试效果，能够有效提高检测技术的实施效率及识别精度。

2018年，Wu 等^[49]利用 DCNN 网络对某单自由度线性系统、单自由度非线性系统及多自由度三层钢框架的动力响应依次进行了分析，并与传统多层感知器算法(Multilayer perceptron, MLP)的检测效果进行了对比。测试结果表明，该方法能够较好地实现对结构特征响应的行为预测，且与传统 MLP 方法相比对噪声具有更强的鲁棒性。

2018年，Chen 等^[50]针对钢结构损伤检测问题，利用 DCNN 网络实现了对某核电站塔筒表面裂纹所在位置的识别。试验结果表明，该方法不仅拥有较好的计算效率及检测精度，同时对于细小裂纹图像也具有较好的识别效果。

2018年，Atha 等^[51]利用 DCNN 网络对钢结构表面的锈蚀情况进行检测识别，并分析了不同色调空间、滑动窗尺寸等因素对检测效率的影响程度，如图 1.8 所示。试验结果表明，经 YCbCr 色调处理后神经网络的识别精度较经 RGB 色调处理后要好，同时尺寸较小的滑动窗对锈蚀损伤区域的处理效果更加良好。



图 1.8 基于 DCNN 网络的钢结构锈蚀识别方法

2018 年，徐秀丽等^[52]基于声学检测理论，在建立经钢筋混凝土梁传播后声学信号特征响应数据库的基础上，利用 DBN 网络对结构的损伤情况进行训练分析。试验结果表明，该方法能够减小噪声等环境因素对测量效果的影响程度，且相较于传统 Back-Propagation 神经网络具有更高的测试精度。

2019 年，Jang 等^[53]提出了一种基于数码显微镜拍摄成像及深度学习理论的新型无损检测技术，通过利用手持式数码显微镜建立标准圆柱体混凝土试件表面微观结构图像数据库的基础上，建立了其与相应构件抗压强度之间的映射关系。同时，通过利用三种 DCNN 神经网络(AlexNet、GoogLeNet 及 ResNet)对数据库依次进行了分类训练，如图 1.9 所示。试验结果表明，混凝土表面微观结构与其抗压强度之间具有一定关联性，且基于 ResNet 网络模型的测试识别效果相对较好。

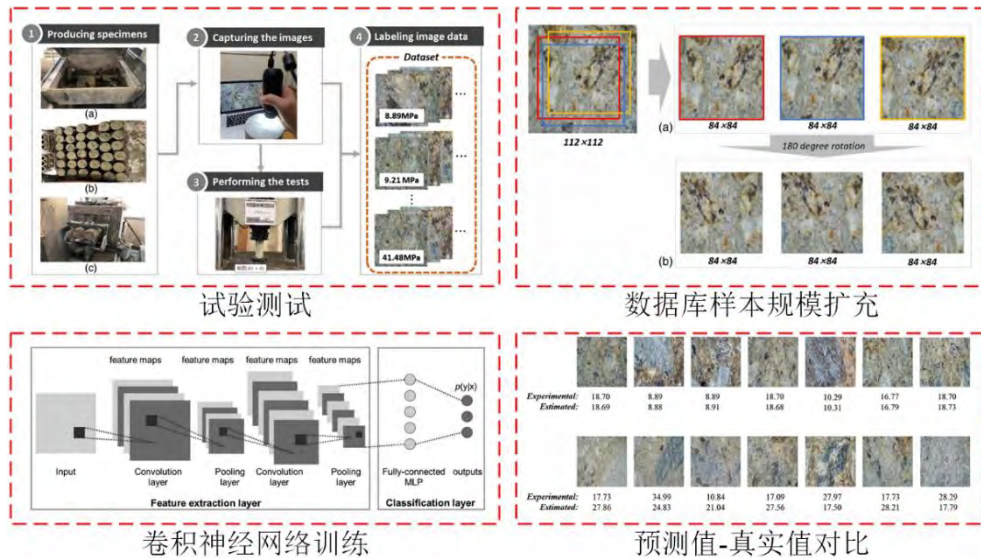


图 1.9 基于 DCNN 网络的混凝土强度识别方法

在基于深度学习理论的车辆荷载识别研究方面，相关学者也开展了系列研究工作。例如在 2015 年，Chen 等^[54]通过将 DCNN 网络与概率神经网络相结合，实现了一种从监控交通视频中有效获取车辆信息的技术手段。试验结果表明，该方法在不同视频传输比特率下的检测效果均较为理想，可有效缓解因网络信号不稳定等因素所可能导致的误差影响。

2017年, Yu等^[55]在实现对常见小型轿车进行细分类的基础上,建立了包含174008例样本在内的车辆外观图像数据库。在利用DCNN模型对数据库进行分类训练后,有效实现了对车辆类型的判断识别。同时,通过将Faster region-based convolutional neural network (Faster-RCNN)网络与Bayesian模型相结合,成功地完成了对图像中目标小轿车的自主检测功能。

2017年, Zhang等^[56]实现了一种基于深度学习理论的车辆交通流密度评估技术,通过以无人机作为拍摄媒介对交通状况进行实时拍摄,并利用Faster-RCNN网络对所得视频图像中的车辆目标进行检测,从而为交通状况分析提供数据支持。

2020年, Jian等^[57]提出了一种基于深度学习算法及影响线理论的交通状况评估技术。其通过深度学习算法实现了对车辆类型及轴数的检测任务,且在遮挡、光照变化等情况下也能有较好的识别效果。同时,通过影响线理论及摄影测量技术对目标车辆的行驶速度、载重情况等信息进行了获取。现场测试结果表明,该车辆荷载识别技术可为桥梁结构的性能安全评估及维修方案的制定提供有效支持。

1.3.2 机器视觉技术

近年来,随着计算机硬件设备及相关理论依据的不断发展,基于机器视觉技术的结构健康监测研究得以迅速突破。其凭借非接触式测量、测试精度较高及可实时监测等诸多优点,已开始逐渐成为相关领域内的研究热点。大量学者也据此开展了系列研究。

2009年, Zaurin等^[58]提出了一种基于计算机视觉技术的新型桥梁结构监测技术。通过利用边缘背景模型,有效实现了从视频图像中对车辆目标的分类、检测及跟踪等功能。

2012年, Catbas等^[59]通过利用机器视觉技术对摄像头所拍摄的视频信息进行逐帧分析,进而实现了对桥梁上行驶车辆类型及所在位置的判断识别。在此基础上,通过结合传统传感器监测结果,有效提取了结构单位响应影响线,并最终实现了对桥梁损伤情况的检测评估。

2015年, 宋宏勋等^[60]在利用两台摄像机确定图像信息映射关系的基础上,对经倾斜拍摄后的物体图像进行变换计算,并将其与垂直拍摄情况下所得的图像进行互相关分析,最终实现了对路面损伤裂缝的快速检测识别。

2016年, 董传智等^[61]提出了一种基于机器视觉技术的桥梁结构健康监测系统,通过利用灰度模板匹配算法、颜色模板匹配算法及均值漂移追踪算法等技术,对结构的动态位移进行了实时监测;同时,通过结合材料力学相关理论,对钢缆的索力进行了有效识别。实验室试验测试表明,该方法具有较高的识别精度。

2016年, Chen等^[62]提出了一种基于非接触式机器视觉技术的大跨桥梁车辆时空分布位置确定方法。在利用BWIM系统对车辆载重等信息进行识别的基础上,

通过利用背景差分法,对视频拍摄所得桥面上运营车辆图像进行模板匹配,并利用粒子滤波技术实现了对车辆运动轨迹的实时跟踪。

2016年,Santos等^[63]研发了一种适用于悬索桥振动情况评估的机器视觉系统。该系统基于非接触式摄影测量的运动模型动态信息捕捉技术,通过利用双目摄像机建立了四个非共面跟踪点,最终实现了对结构振动情况的测试识别。

2016年,Ye等^[64]针对传统结构动位移测量方法所存在的诸多问题,建立了一套基于机器视觉技术的非接触式测量系统,主要涉及了灰度模式匹配算法(Grayscale pattern matching, GPM)、彩色模式匹配算法(Color pattern matching, CPM)和均值漂移跟踪算法(Mean shift tracking, MST)等方法。通过开展现场试验测试,对某拱桥在车辆荷载作用下的影响线进行了识别。

2017年,Khuc等^[65]针对某大型体育场馆结构性能评估问题,建立了一种基于非接触式机器视觉技术的结构健康监测系统。通过采用改进关键点匹配算法,较好地实现了对结构位移的实时测量,进而可完成对结构振动情况的分析评估。测试结果表明,该系统能够较好实现对此体育馆的性能评估,可应用至类似工程结构的健康监测问题研究当中。

2017年,Feng等^[66]研发了一种基于非接触式机器视觉技术的结构位移摄影测量传感器,并通过开展试验测试对该仪器的性能进行测试。结果表明,该传感器具有测试量程大、测量精度高、测试同步性好等优点。

2017年,Feng等^[67]研发出一种基于机器视觉技术的非接触式电缆索力测量传感器,通过采用亚像素匹配算法,较好地实现了对多根电缆动态响应的同步测量评估。

2018年,Lydon等^[68]提出了一种基于非接触式机器视觉技术的桥梁挠度测量方法。通过利用多个无线相机对某桁架桥的挠度进行测试,并分析了结构位移响应与外界荷载之间的映射关系。

2018年,Khuc等^[69]提出了一种基于机器视觉技术的结构损伤评估方法,在利用摄像机非接触式拍摄实现车辆荷载输入及结构响应输出测量的基础上,成功建立了结构单位位移影响面,并最终实现了对结构损伤程度的评估判断。

2018年,Luo等^[70]实现了一种名为InnoVision的新型视频图像处理技术。通过对某大型桥梁的振动情况进行测试,表明该方法具有分辨效果好、鲁棒性强等诸多优点,可较好地应用至基于机器视觉的结构位移监测研究当中。

2018年,Tian等^[71]提出了一种基于视觉测量技术的人致冲击荷载反演方法。在利用高速相机拍摄人体运动图像后,采用粒子图像测速方法实现了对人致荷载的反演。通过对某人行桥开展现场试验测试,对所提方法的有效性进行了验证,如图1.10所示。试验结果表明,该方法无需在人体上安装传感器等设备,具有非接触式监测、方便快捷、节约测试成本等优点。

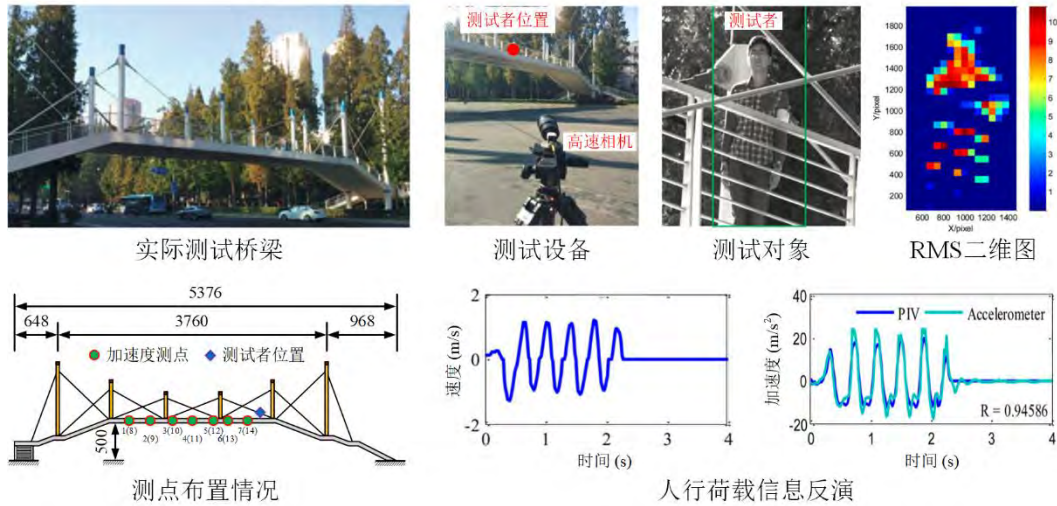


图 1.10 基于机器视觉技术的人致冲击荷载测试方法

1.4 本文主要研究内容

1.4.1 选题依据

本文的选题依据来源于国家自然科学基金项目--《基于非接触式机器视觉监测技术与区间仿射算法的桥梁结构影响面反演》。该项目针对传统 BWIM 系统硬件设施高昂、车辆时空定位精度有待提高和桥梁结构变形测试依赖外加物理标靶等不足之处，拟计划基于深度学习理论、摄影测量方式及区间仿射算法等技术，开展基于非接触式机器视觉监测技术与区间仿射算法的桥梁结构影响面反演研究。通过利用摄像机拍摄桥面上车辆的运营状况及车载作用下桥梁的变形情况，实现对桥梁结构性能状态的评估。该项目充分利用了非接触式机器视觉识别技术在桥梁健康监测中“快速实施”、“操作简便”及“全局测量”等优势，尝试开发了一种“无需交通封闭”、“无需接触式传感”和“无需 BWIM 系统支持”的智能监测技术，为进行桥梁状态快速评估的机器视觉识别系统提供重要技术支撑。该项目主要研究内容的概念流程图如图 1.11 所示，主要包含以下四个方面：

(1) 基于深度学习理论的车辆类型识别及轮载区间估计。在建立常见车辆类型图像数据库的基础上，利用深度学习方法实现对运营状态下车辆类型的识别；并通过统计大中型车辆的出厂信息，确定对应车辆类型的轴重及总重区间分布情况，从而实现对运营车辆轮载情况的估计分析。

(2) 基于平行坐标系三维空间坐标转换的车辆时空定位。拟计划通过级联霍夫变换及平行坐标系转换等技术，完成三维空间实际几何物体与平面几何尺寸图像之间的矩阵转换关系；并通过非接触式摄影测量技术，通过视频拍摄等方式，实现对车辆在桥面上所在位置、行驶速度等信息的辨识。

(3) 基于快速视网膜关键点追踪的桥梁结构动位移识别。拟计划通过相机标

定方法，在实现像素坐标系与物理坐标系之间转换关系的基础上，进行无标靶标记情况下的结构时程动位移响应识别；并在建立桥梁结构有限元模型的基础上，探讨利用动位移替代动应变进行车辆动态称重的可行性。

(4) 基于区间矩阵仿射算法求逆的桥梁结构影响面反演。根据车辆载荷矩阵中各元素的区间分布特征，通过将不确定变量以仿射变量形式表示，并在建立矩阵方程的基础上，对桥梁影响面的精确区间进行求解；同时，通过建立多个样本工况，对结构影响面的区间进行求解，最终获得桥梁影响面的真实解。




图 1.11 国家自然科学基金研究内容示意图

1.4.2 研究内容

基于上述基金项目，本文主要围绕研究问题一和研究问题二中的相关内容，开展了基于深度学习理论及机器视觉技术的车辆荷载识别技术研究。拟计划通过本项目的研究工作，在对车辆荷载信息(如载重、速度、类型、运动轨迹及实时位置等)进行有效识别的基础上，提供一种“无需交通封闭”和“无需 BWIM 系统支持”的桥梁快速有效评估新思路，从而为实现“智能桥梁”和“智慧交通”提供重要技术支持。

针对研究问题一，拟计划通过开展基于图像识别的机器学习问题研究，即利用深度学习算法挖掘不同激励源作用下结构响应中所隐含的分布规律及模式，实现输出信息获取-神经网络训练-输入信息获取的技术流程，从而为解决结构健康监测研究领域中与大数据及图像识别有关的传统难题提供新思路。整个研究环节示意图如图 1.12 所示，具体包括以下内容：

(1) 为利用 DCNN 网络在图像识别领域所具备的特有优势，将车载作用下桥梁结构所产生的信号响应转化为图像识别问题进行机器学习，并利用深度学习算法探索其中所隐含的结构本质规律，从而避免利用传统函数解析方式对特征信号进行求解。技术路线方面，拟计划采用时-频分析技术进行信号预处理，并通过对比不同方法处理下结构特征响应的提取效果，探索适用于该类型科学问题研究的数据处理方法。

(2) 通过分别开展有限元数值模拟分析、试验室缩尺模型试验及野外现场试验测试等方式，对所提基于深度学习理论及结构特征响应提取的桥梁上车辆荷载信息识别方法的可行性及有效性进行评估。通过设置不同的测试工况，在建立结构特征响应数据库的基础上，利用深度学习网络实现对运营车辆的载重情况进行预测，并探讨该方法对行驶速度、车辆类型及行驶车道等其他信息识别的可行性。

(3) 为获取较为准确的车载识别精度，通过设置不同的训练方式，评估相应深度学习模型在数据集上的性能表现。同时，通过开展迁移学习方式，探究经大型自然图像数据集 ImageNet 预训练过的神经网络模型在该类型数字信号图像识别问题研究上的适用性。

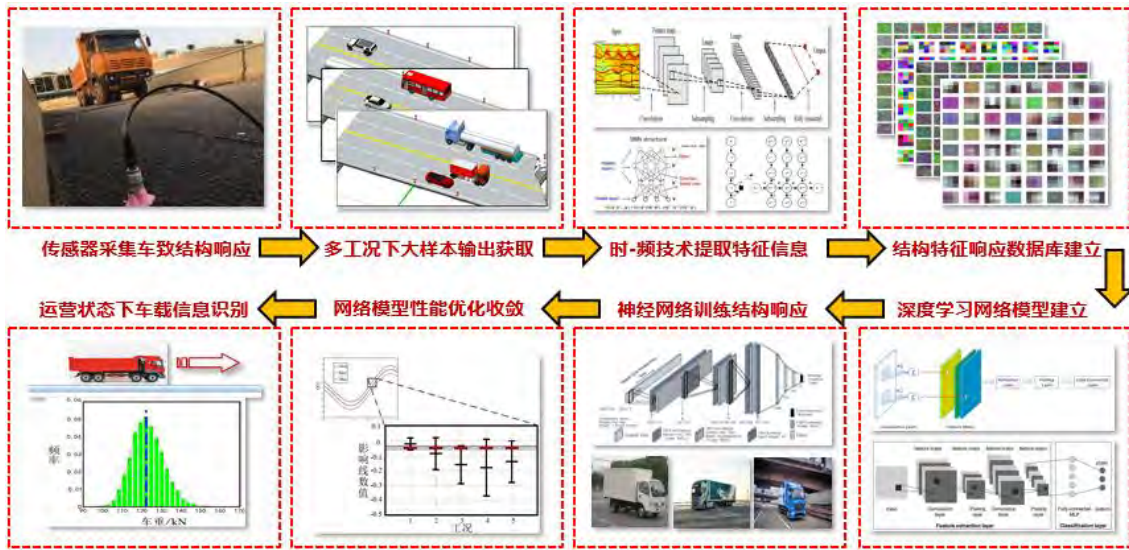


图 1.12 研究内容一流程示意图

针对研究问题二，拟计划针对 BWIM 系统所无法普及的量大面积的桥梁结构，通过摄像机非接触式拍摄视频的方式，采用机器视觉技术实现对车辆目标、载重区间、轨迹跟踪及时空定位等信息的直接辨识。整个研究环节的示意图如图 1.13 所示，具体包括以下内容：

(1) 为实现基于视频拍摄方式的运动车辆目标智能化监测系统，拟提出一种基于深度学习理论及压缩感知技术的运营车辆目标检测跟踪方法。在建立车辆外观图像数据库的基础上，通过分别开展实验室试验和野外试验，对所提方法的可行性进行验证。同时，通过设置不同的环境测试工况，对该基于机器视觉的车辆目标监测系统的鲁棒性进行评估。

(2) 为实现基于非接触式摄影测量方式的车辆荷载信息识别技术，建立了适用于交通道路的监控摄像机标定模型。同时，针对现有摄影测量技术所存在的需人工部分参与等不足之处，采用基于平行坐标系的级联霍夫变换，利用正交消失点之间的相互约束性完成相机标定工作，建立了视频图像坐标系与物理世界坐标系之间的映射关系，为基于摄影测量方式的车辆目标信息识别提供支撑。

(3) 通过开展试验研究，对基于摄影测量方式的车辆荷载时空定位识别技术的有效性进行评估。在利用基于平行坐标系的级联霍夫变换方式完成相机标定工作后，利用相关相机模型对车辆在桥面上的真实位置进行了获取。同时，通过设置不同的测试工况，探讨该方法在不同使用环境中检测效果的稳定性。

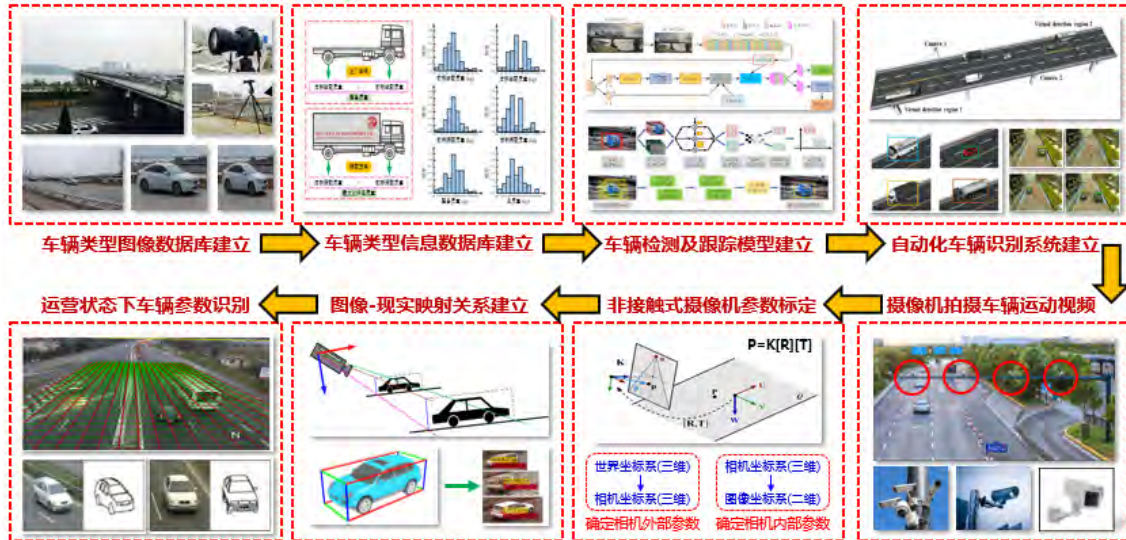


图 1.13 研究内容二流程示意图

第 2 章 基于深度学习理论的车辆荷载识别模拟研究

2.1 引言

针对现有 BWIM 系统在车辆荷载信息识别问题上所存在的硬件设施成本高、安装及维护过程需全面或部分封闭交通等不足之处，提出了一种基于深度学习理论及结构特征响应提取的桥梁上车载信息辨识方法。本章在首先对时-频分析技术、深度学习概念及车-桥动力学理论等相关内容进行介绍的基础上，针对桥梁结构上运营车辆荷载识别问题，分别建立了简支梁-移动荷载及车-桥耦合振动有限元分析模型，并经计算后建立了结构动态响应数据库。在此基础上，通过时-频分析技术对信号响应中所潜在的特征信息进行提取，并利用 DCNN 网络模型对其进行迭代训练，从而实现运营车辆信息的预测辨识。

2.2 时-频分析理论

在工程结构振动反问题识别研究方面，分析过程中所需处理的结构响应信号通常会表现出非平稳的特性；同时，对于以车-桥耦合振动系统等为代表的时变结构体系而言，传统的经典模态分析理论可能将无法对其进行充分有效的解读^[72]。因此，选择合适的数据分析方法在该类型科学问题研究中具有重要意义。作为信号处理领域内的重要技术手段之一，时-频分析技术(Time-frequency analysis)与传统时域或频域分析方法有所不同，其可同时在时间及频率域内对信号的能量强(密度)等信息进行表达；在此基础上，该类技术还能够对任意时刻下时变结构的瞬态频率幅值进行计算。除此之外，对于经时-频分析技术处理所得的二维平面功率谱，不仅能够更加全面地反映结构系统内部的特征规律，并且基于图像的数据表现形式也更适合人脑进行直观判断分析^[73]。目前，时-频分析技术已被国内外众多学者应用至对非稳态及时变信号的科学问题研究当中。通常情况下，所涉及到的技术手段主要包括小波变换(Wavelet transform, WT)、短时傅里叶变换(Short-time Fourier transform, STFT)及维格纳变换(Wigner-Ville transform, WVT)等。

2.2.1 小波变换技术

作为一种有效的数据分析方法，WT 变换通常被用于分析具有不同尺度/分辨率的非平稳信号^[72]。该技术通过伸缩、平移运动等方式，可依次完成对原始信号的多尺度细化考虑，在实现对信号低频部分处细分频率间隔、高频部分处细分时间间隔处理效果的基础上，有效满足了对信号各分量进行自适应分析的需求。作

为其中一种高效的时-频分析手段，连续小波变换(Continuous wavelet transform, CWT)通常对输入信号响应的格式类型无特殊要求，即位移、速度及加速度等信号均可进行变换分析。同时，凭借其卓越的时-频定位能力，CWT 变换在工程结构健康监测领域内得到了极大的关注。具体而言，CWT 分析对原始输入信号的变换过程可定义为^[72]：

$$CWT_{\psi}(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt \quad (2.1)$$

其中， a 表示伸缩因子， b 表示平移因子， $x(t)$ 表示预先假定的时间序列， $\psi(t)$ 表示小波母函数(Mother wavelet)。通常情况下，小波母函数的缩放形式由参数 a 控制，其在时间轴上的平移情况则由参数 b 控制。除此之外，小波母函数还应满足以下准则：

$$\int_{-\infty}^{\infty} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty \quad (2.2)$$

其中， $\hat{\psi}(\omega)$ 表示 $\psi(t)$ 经傅里叶变换后的转换形式， ω 表示结构的频率。

若令 $\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right)$ ，则式(2.2)可转化为：

$$CWT_{\psi}(a, b) = \int_{-\infty}^{\infty} x(t) \psi_{a,b}(t) dt \quad (2.3)$$

值得注意的是，CWT 变换的核心环节在于选择合适的小波基函数(Wavelet basis function)，这将直接影响到信号处理过程的准确性和特征信息提取的有效性。一般情况下，常用的小波基函数主要包括 Morlet、Haar 及 Meyer 等。然而，目前在小波基函数选取方面并没有一套规范的标准流程，通常大多依赖于人工经验判断。根据相关学者研究成果建议，基于 Morlet 基函数的 CWT 分析方法在提取结构动态响应信号的特征模式方面具有更加理想的效果^[72]。具体而言，Morlet 小波基函数是一类呈平方指数衰减形式的余弦信号，且具有显式的解析方程。基于 Morlet 基函数的 CWT 变换表达式可具体表示如下：

$$CWT_{\psi}(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi^*\left(\frac{t-b}{a}\right) dt = \langle x(t), \psi_{a,b}(t) \rangle \quad (2.4)$$

其中， $\psi^*(t)$ 表示 $\psi(t)$ 的复共轭。具体而言，Morlet 小波基函数为一单频复正弦函数，其在时/频域内的函数表达式为：

$$\psi(t) = \frac{1}{\sqrt{\pi f_b}} e^{\frac{-t^2}{f_b}} e^{2\pi j f_c t}, \quad \psi(af) = e^{-\pi^2 f_b (at - f_c)^2} \quad (2.5)$$

其中， f_b 表示带宽参数， f_c 表示小波中心频率。据此，可推导求得 Morlet 小波基函数在时/频域内的计算间隔，分别表示为：

$$\Delta t_i = a_i \Delta t_{\psi} = \frac{f_c f_s \sqrt{f_b}}{f_i} \frac{1}{2}, \quad \Delta f_i = \frac{1}{a_i} \Delta f_{\psi} = \frac{f_i}{f_c f_s 2\pi \sqrt{f_b}} \quad (2.6)$$

其中, Δt_ψ 表示 Morlet 小波基函数的时域分辨率, Δf_ψ 则表示 Morlet 小波基函数的频域分辨率。

总体而言, 经 CWT 分析后所得的功率谱图不仅能够较好地时间、频率及幅值等方面对非平稳振动系统的时-频局部特性进行描述, 而且还可通过平移/伸缩窗函数的方式对信号的细节信息进行考虑, 是一种较为理想的数据分析工具^[72]。

2.2.2 短时傅里叶变换技术

作为一种高效的时-频分析方法, STFT 变换通过使用具有时间窗属性的傅立叶变换, 可实现对非平稳信号的分析处理^[74]。具体而言, 在选择一个可在时/频域内移动变化的窗函数后, 能够将整个时域计算过程划分为多个具有相似尺度的时间间隔; 对于经拆分后的各间隔区间, 可认为相应的信号响应均伪平稳(或近似平稳)地分布于其中。通过对其依次进行傅里叶变换, 即可计算得到各不同时刻下的功率谱。具体而言, 基于 STFT 变换的原始信号处理过程可表示如下^[74]:

$$STFT_x(\tau, f) = \int_{-\infty}^{\infty} x(t)h(t - \tau)e^{-2\pi jft} dt \quad (2.7)$$

其中, τ 表示分离采样时间的的时间间隔, f 表示傅里叶变换过程中的计算频率, $h(t - \tau)e^{-2\pi jft}$ 则表示 STFT 的基函数。

在实际计算过程中, STFT 功率谱图中时间/频率分辨率均由窗口的尺寸进行决定, 且相应分辨率的数值均随窗口长度的减小而增大。同时, 对于实际计算过程中的非稳态信号, 大窗口通常适用于处理低频信号, 小窗口则适用于处理高频信号^[74]。但值得注意的是, 由于 STFT 的处理窗口具有尺度不变性, 即在各分析过程中相应的计算宽度将保持不变, 故 STFT 变换本质上还是无法较好地满足非稳态信号对频率变化情况的需求。

2.2.3 维格纳变换技术

作为一种有效的时变频谱信号分析技术, WVT 变换被定义为信号中心协方差函数的傅立叶变换^[74]。该技术不仅能分别在时/频域内保持较高的计算分辨率, 还能够较好地反映信号的瞬时频率信息。作为一种典型的二次型变换技术, WVT 分析对于某信号 $x(t)$ 的处理过程可表示为^[74]:

$$WVT_x(t, f) = \int_{-\infty}^{\infty} x_a(t + \frac{\tau}{2})x_a^*(t - \frac{\tau}{2})e^{-2\pi jf\tau} d\tau \quad (2.8)$$

其中, $x_a(t)$ 表示原始信号 $x(t)$ 经分析处理后所得的信号, $x_a^*(t)$ 表示处理信号 $x_a(t)$ 的复共轭。

总体而言, WVT 变换具有平移不变性、边界有界性以及可叠加性等诸多优点, 且能够获得较高的时-频分辨率, 是一种有效的数据分析手段^[74]。但值得注意的是, 针对具有多分量或复杂调制规律的信号, WVT 变换却不能较好地对其产生

的交叉项干扰影响进行有效处理。即在实际应用过程中，大量的交叉项可能将遮掩或严重干扰信号的自身项，从而易混淆原始信号中所潜在的固有特征信息。

2.3 深度学习理论

作为近年来人工智能领域内所取得的重要突破，以深度学习为代表的机器学习方式开始逐渐在图像识别、视频分析及语言处理等领域表现突出。其通过建立可用于自主学习的神经网络，以模拟人类大脑中神经元传递机制的方式对数据进行分析解释^[75]，已逐渐在相关科学问题研究工作中发挥重要作用。

2.3.1 深度学习理论概述

从本质上来讲，深度学习是一种对物体固有特征进行自主提取学习的计算方法，其通过利用一系列非线性模型对原始数据进行分析处理，从而使其转化为具有更高层次的抽象表达，以挖掘数据分布形式的特征表示。若所进行的转换组合足够多，理论上具有任何复杂程度的函数结构都可被训练掌握^[47]。深度学习理论凭借其鲁棒性及容错能力较强等诸多优势，已开始逐渐在图像识别、物体检测及语义分割等领域内得到高度重视。其中，对于图像识别问题而言，传统机器学习计算方法通常是利用各种特征提取器，通过对原始图像中的边缘、纹理等特征信息进行提取并处理，进而实现对图像类型的判断识别。然而，该类型方法通常需要人为事先地对图像中物体的特征信息进行标记，故对于大样本情况下的分类任务将非常难以完成。但是，深度学习理论凭借其强大的逐层分解对象及自主学习特征等功能，可在无需依赖人类先验知识辅助的前提下来进行样本特征提取，有效缓解了这一局限困境。

与传统机器学习方法相比，基于深度学习理论的图像识别技术通常被认为具有以下优势：(1)深度学习理论可自主进行特征提取，具有计算效率高、可执行性强等特点；(2)深度学习算法可使用高性能 GPU 图像处理器进行并行运算，计算效率远超传统方法；(3)深度学习理论所设置的新型分类器，可通过实时反馈信息的方式提升图像特征提取效率；(4)深度学习理论可充分利用相关大数据研究成果，具有较强的可拓展性。

2.3.2 卷积神经网络概述

在现有深度学习理论的众多实现算法中，DCNN 神经网络凭借其在图像分类领域具备的卓越性能，已成为深度学习方法中的经典算法之一。概括而言，DCNN 网络是一类包含卷积计算功能的深度前馈神经网络，具有强大的表征学习能力 (Representation learning)，能够依据阶层顺序实现对输入信息的平移不变性分类 (Shift-invariant classification)；其通过多次非线性变换，可实现对数据特征的自主

捕获学习，从而有效地避免了传统人为手动对特征进行标记的繁琐步骤^[76]。除此之外，针对不同类型的图像识别任务，可通过增加网络层个数等方式相应提升神经网络模型的学习能力。关于 DCNN 网络的研究历程方面，1968 年，Hubel 等^[77]仿照动物视觉神经细胞首先提出了“感受野”这一概念，其通过仿生学理论设计了神经网络模型，并将其用以对自然物体进行学习和识别，为后续神经网络模型的发展奠定了重要基础；1980 年，Fukushima 等^[78]提出了具有一定自主学习能力的神经元模型，且该模型也被认为是神经网络的最初框架结构；1995 年，Lecun 等^[79]设计了一种简易的卷积神经网络模型，并通过开展手写数字识别任务对其实用性进行了测试，且最终经测试后获得了较为满意的识别效果。然而，这一时期的卷积神经网络仅适用于开展数据集规模较小的图片识别任务，对于大型数据库上的测试效果仍有待提高。另一方面，由于原始的卷积神经网络模型在测试阶段需对大量物理参数进行设置，且模型训练过程中所消耗的时间代价也十分巨大；加之当时计算机等硬件辅助设置条件较为落后，导致卷积神经网络的发展历程受到一定停滞。直到 2006 年，由 Hinton 等^[80]率先实现了针对 DCNN 网络的渐进训练技术，即通过将前一网络层的训练结果作为后一网络层的特征输入进行迭代训练，从而有效解决了测试精度优化问题；同时在 2012 年，Krizhevsky 等^[81]通过分别引入 Dropout 迭代理论、非线性激活函数及随机平移扰动等概念，使得 DCNN 网络的性能在真正意义上取得了巨大突破，并开始被大量应用至图像识别分类领域内的相关科研问题当中。例如对于人脸识别任务，于 2013 年所提出的 DeepFace^[82]、DeepID^[83]等算法均取得了超过 97% 的测试识别率，其中对于网络层数量扩充了的 DeepID2+ 模型更是实现了 99.47% 的准确率^[84]，远远超过了人类肉眼视觉的辨识范围。在医学研究领域，Cruzroa 等^[85]通过利用深度学习方法对癌变细胞和正常细胞进行自主识别，并获得了在 90% 以上的准确率。在目标检测领域中，以 Faster-RCNN 等为代表的 DCNN 网络模型也表现出了优异的测试效果。

2.3.3 卷积神经网络结构

网络结构组成方面，DCNN 网络中各单层网络均将前一网络层的输出结果作为后一网络层的输入信息进行计算，并在经反复迭代嵌套后即可构成 DCNN 网络模型。通常情况下，典型的 DCNN 网络模型主要由输入层、卷积层、池化层(下采样层)、全连接层和输出层等部分构成^[86]，如图 2.1 所示。其中，卷积层和池化层的数量通常设置为若干个，并通过交替设置形成卷积层-池化层-卷积层-池化层的循环模式，以实现对本样本特性信息的充分获取。网络层功能方面，输入层主要是将所测试对象经转化处理后生成相应信息输入至网络模型中；卷积层和池化层则主要负责对物体的特征信息进行提取；全连接层将主要对所提取到的特性信息按照预设情况进行系统性分类；输出层则是将网络模型经训练后的结果进行有序

输出。




图 2.1 DCNN 网络基本结构

(1)卷积层(Convolutional layer, CONV layer)。卷积层通常被用来对所训练对象的特征信息进行提取。通常情况下，卷积层由多个特征面(Feature map)组成，其中每个特征面均由多个神经元构成，且各神经元通过卷积核(即权值矩阵)与前一网络中特征面上的局部区域进行连接^[86]。当输入对象为图像信息时，神经网络可通过卷积操作实现对图像中特征信息的提取工作。其中，低阶卷积层主要负责对图像中的低阶特征信息(如线条、边缘等)进行提取，而高阶卷积层则将实现对图像固有特征信息的辨识提取。通常情况下，各单个卷积层中均包含有 2^n 个特征映射关系组，且 DCNN 网络将通过设置多个卷积层的方式来实现对图像中深度特征信息的提取。

模型参数设置方面，卷积核大小、滑动步长和填充方式等三种操作将共同影响卷积层中输出特征图的尺寸大小。其中，特征图的尺寸将随卷积核纵横向规格大小的增加而减小，且随滑动步长的增大而降低；另一方面，可通过采用填充方式对输入图像的尺寸进行虚拟扩充，从而减缓相应特征图在卷积计算过程中所产生的尺寸收缩现象。具体的填充操作设置方面，常用的填充方法主要包括零值填充、重复边界填充等类型。根据填充目的及所涉及到的网络层数，可将其分为四类^[86]：(1)有效填充。即卷积核仅可搜索所扫描特征图中拥有完整感受野的信息位置，以使得所输出特征图的像素与输入层中保持一致；(2)半填充。即通过大量填充操作以保证输入层和输出层中的特征图尺寸相同，但该操作也相应地容易造成输入像素中靠近边界的部分对特征图信息的敏感程度产生降低；(3)全填充。即通过足够多的填充操作，使得特征图中每个方向上像素点被访问的次数均相同。(4)任意填充。即通过人为设定的方式进行参数填充，该填充方式的处理效果通常介于有效填充和全填充之间。

运算设置方面，卷积操作将基于卷积核在原始图像上的滑动扫描结果，通过对所经过的各区域依次进行卷积运算，从而获取对应的特征图信息。其中，各卷积层中的输出特征图尺寸大小 O_{map} 需满足^[86]：

$$O_{map} = \frac{I_{map} - R}{s} + 1 \quad (2.9)$$

其中， I_{map} 表示卷积层中所输入特征图的规格大小； R 表示对应卷积核的尺寸大小；