



同濟大學
TONGJI UNIVERSITY

硕士学位论文

钢筋混凝土柱失效模式分类与 压弯耦合滞回模型研究

(上海市浦江人才计划项目 编号：18PJ1410100)

(项目名称：城市建筑群结构三维滞回特性与双向动力
特征建模方法研究)

姓 名：吕欣亮

学 号：1732495

所在院系：土木工程学院

学科门类：工程

学科专业：建筑与土木工程

指导教师：任晓丹 副教授

联合导师：宁超列 助理研究员

二〇二〇年六月



同濟大學
TONGJI UNIVERSITY

A dissertation submitted to
Tongji University in conformity with the requirements for
the degree of Master

**Failure Mode Classification and P-M
Interaction Hysteretic Model of Reinforced
Concrete Columns**

Candidate: Xinliang Lyu

Student Number: 1732495

Department: School of Civil Engineering

Discipline: Engineering

Major: Architecture and Civil Engineering

Supervisor: Associate Prof. Xiaodan Ren

Joint Supervisor: Assistant Prof. Chao-Lie Ning

June, 2020

学位论文版权使用授权书

本人完全了解同济大学关于收集、保存、使用学位论文的规定，同意如下各项内容：按照学校要求提交学位论文的印刷本和电子版；学校有权保存学位论文的印刷本和电子版，并采用影印、缩印、扫描、数字化或其它手段保存论文；学校有权提供目录检索以及提供本学位论文全文或者部分的阅览服务；学校有权按有关规定向国家有关部门或者机构送交论文的复印件和电子版；在不以赢利为目的的前提下，学校可以适当复制论文的部分或全部内容用于学术活动。

学位论文作者签名：

年 月 日

同济大学学位论文原创性声明

本人郑重声明：所呈交的学位论文，是本人在导师指导下，进行研究工作所取得的成果。除文中已经注明引用的内容外，本学位论文的研究成果不包含任何他人创作的、已公开发表或者没有公开发表的作品的内容。对本论文所涉及的研究工作做出贡献的其他个人和集体，均已在文中以明确方式标明。本学位论文原创性声明的法律责任由本人承担。

学位论文作者签名：

年 月 日

摘要

近三十年来, 我国的经济化水平和城市化水平以前所未有的速度发展。随着人口向大城市的不断涌入, 城市住宅和公共建筑的数量不断增加。在这期间, 我国的建筑结构抗震设计规范经历了从无到有、从粗略到精细、从简单到丰富的过程, 这导致城市中既有建筑的抗震性能由于建造年代的不同而参差不齐。近几十年的震害调查结果表明, 那些按照旧的抗震设计规范设计和施工的建筑结构抗震性能明显不如按现代抗震设计规范设计和施工的新建筑。另一方面, 对于按现代抗震设计规范设计和施工的新建筑, 其抗震性能一般应遵循“强柱弱梁”式的抗震设计理念, 即通过构造措施防止柱铰段破坏和柱剪切脆性破坏, 在此基础上, 对梁的受弯延性破坏进行详细的分析、计算和设计。然而, 汶川地震的震害调查结果表明, 钢筋混凝土框架结构在地震作用下实际很少出现设计要求的“强柱弱梁”式破坏。这一现象表明, 虽然钢筋混凝土结构的地震损伤试验、数值模拟方法和失效理论研究已经颇为丰富, 但仍有必要深入研究钢筋混凝土结构及其构件的损伤特征、破坏机理和失效演化, 其成果一方面可对这些既有建筑及其构件的抗震性能评估和加固提供重要信息, 避免这些既有建筑在未来可能发生的地震作用下出现严重的损伤和破坏, 另一方面可为新建结构提供一定的设计指导。在这一背景下, 本文以试验数据丰富、机理研究深入的钢筋混凝土柱为研究对象, 考虑由于剪切破坏机理的复杂性导致钢筋混凝土柱弯曲失效、弯剪失效和剪切失效这三类模式的损伤特征描述和失效模式演化过程难以准确刻画和控制, 因此引入机器学习方法, 针对钢筋混凝土柱的失效模式分类和滞回特征描述开展了系列研究, 主要内容包括:

1. 利用人工神经网络分类机, 结合 PEER 数据库, 建立了钢筋混凝土柱失效模式的分类模型。在此基础上, 通过开展分类模型输入参数敏感性分析, 详细研究了钢筋混凝土柱的失效模式演化。在建立人工神经网络分类机的过程中, 发现钢筋混凝土柱的失效模式数据库存在数据偏斜的问题, 因此对这一问题进行了初步探讨。
2. 深入研究了钢筋混凝土柱失效模式数据库的偏斜数据问题, 分析了偏斜数据对机器学习分类模型的影响机理。同时, 结合主成分分析方法对数据库进行了可视化, 引入高等采样方法和数据除噪方法, 对失效模式数据库的偏斜数据进行了处理。最后, 提出利用单层决策树为基础进行分类的自适应增强 (AdaBoost) 算法, 建立了一类新的钢筋混凝土柱失效模式分类模型, 得到了更加准确的分类效果。

3. 在准确分类失效模式的基础上，引入 Bouc-Wen-Baber-Noori (BWBN) 模型描述不同失效模式下钢筋混凝土柱的滞回曲线，介绍了 BWBN 光滑型滞回模型的微分形式，并对模型中的形状参数、刚度退化参数、强度退化参数以及捏拢参数进行了详细的分析和讨论，通过改变参数，展示了 BWBN 的各个模型参数对滞回曲线形状的影响。基于 BWBN 模型的积分表示方法，考虑轴力对钢筋混凝土柱滞回曲线的影响，推导了一类新的压弯耦合滞回模型。最后，基于新的压弯耦合滞回模型，引入微分进化算法，并结合 PEER 数据库，开展了压弯耦合滞回模型的参数识别，给出了压弯耦合滞回模型参数的建议取值范围。

关键词：钢筋混凝土柱；失效模式；机器学习；人工神经网络；偏斜数据；滞回模型；压弯耦合效应；微分进化算法

Abstract

With the unprecedented development of economy and urbanization in China since 1994, the number of residence and public buildings in metropolis like Shanghai or Beijing is constantly increasing as the population continues to flood into large cities. China's seismic design codes have undergone a similar change as the development of economy and urbanization, which leads to the uneven seismic performance of buildings in cities due to their different construction years. The seismic survey of several major earthquakes in recent decades has shown that the seismic performance of old buildings designed and constructed in accordance with the old seismic codes is significantly worse than that of new buildings designed according to modern seismic codes. In order to prevent these old buildings from causing serious disasters in the future earthquakes, it is necessary to carry out seismic evaluation of the components of these old buildings. The failure modes of reinforced concrete columns can provide important information for such seismic assessment work.

For new buildings constructed in accordance with modern seismic codes, their seismic performance is generally designed in accordance with the concepts represented by “strong columns and weak beams”, using detailings to prevent more dangerous failures such as column hinge failure and column shear brittle failure. The codes, in turn, provide detailed seismic design and calculations for the ductile failure of the beam. However, the earthquake damage investigation of the Wenchuan earthquake has demonstrated that the concrete frame structure rarely had the “strong column weak beam” type of damage according to the design requirements. Therefore, it is necessary to conduct an in-depth study on the seismic design of reinforced concrete structural columns from the perspective of the column failure modes.

In this context, a systematic research is carried out for the failure mode and hysteretic model of reinforced concrete columns with the help of the machine learning techniques,. The main contents are as follow:

1. Based on PEER database, a prediction model for failure modes of reinforced concrete columns was established using the artificial neural network classifier, and the sensitivity of the four input parameters to the failure mode was analyzed. In the process of establishing an artificial neural network classifier, the skew data problem of the reinforced concrete column failure mode database was found, and the problem was dealt with in a naïve approach.

2. The problem of skew data of reinforced concrete column failure modes database is studied, and the mechanism of skew data affecting machine learning prediction model is analyzed. After visualizing the database with the principal component analysis, the appropriate advanced sampling method and denoising method are selected to deal with the skewed data problem of the original database. Finally, the AdaBoost algorithm based on a decision tree stump model is selected to establish a prediction model for the failure mode of reinforced concrete columns, and a better prediction performance is obtained.
3. The differential equation form of the BWBN smooth hysteretic model is briefly introduced, and the shape parameters, stiffness degradation parameters, strength degradation parameters and pinch parameters in this model are explained in detail. The effects of model parameters on the shape of the hysteresis curves are shown by changing the parameters. Then, another representation of the BWBN model, the integral representation, is introduced, and the compression-bend coupling effect is introduced under this mathematical formulation. The influence of the axial force on the hysteresis curve is included explicitly in this model.
4. Using the differential evolution algorithm, combined with the reinforced concrete column restoring force vs displacement test curve in the PEER database, the parameters of the BWBN model considering the coupling effect of compression and bending are identified.
5. Finally, further research opportunities are discussed.

Keywords: Reinforced Concrete Columns; Failure Modes; Machine Learning; Artificial Neural Network; Skewed Data; BWBN Hysteretic Model; Compression-bend Coupling Effect; Differential Evolution Algorithm

目录页

摘要.....	I
ABSTRACT.....	III
目录页.....	V
第 1 章 绪论.....	1
1.1 研究背景.....	1
1.2 抗震设计规范的发展变迁.....	3
1.2.1 研究探索初期阶段	4
1.2.2 工业试行阶段	4
1.2.3 全面实践阶段	5
1.3 汶川地震和玉树地震的震害分析.....	6
1.3.1 汶川地震的震害分析	6
1.3.2 玉树地震的震害分析	8
1.3.3 反思和讨论	9
1.4 失效模式研究.....	10
1.4.1 Setzler 和 Sezen 判断准则	10
1.4.2 基于简化桁架模型的概率指标	11
1.4.3 失效模式经验指标	11
1.4.4 失效模式研究中存在的问题	12
1.5 滞回模型研究.....	12
1.5.1 滞回模型研究新进展	12
1.5.2 滞回模型研究中存在的问题	13
1.6 本文的主要研究思路和内容.....	14
第 2 章 基于机器学习的失效模式分类.....	15
2.1 确定关键输入参数.....	16
2.1.1 剪切和弯曲强度公式讨论	17
2.1.2 四个关键输入参数的定义	18
2.2 试验数据库.....	19
2.2.1 原始试验数据库	19
2.2.2 偏斜数据的处理	21
2.3 神经网络分类机的构建.....	24
2.3.1 神经网络分类机理论	26

2.3.2 隐藏层结构的确定	30
2.3.3 规则化参数的确定	32
2.3.4 数据量大小的确定	35
2.4 分类机的预测效果和参数敏感性分析	36
2.4.1 预测精度和混淆矩阵	36
2.4.2 参数敏感性分析	38
2.5 本章小结	40
第 3 章 失效模式分类中的偏斜数据问题	41
3.1 偏斜数据的影响和常用处理方法	41
3.1.1 偏斜数据的不利影响	42
3.1.2 常用处理方法	44
3.2 原始数据库处理	47
3.2.1 SMOTE 类算法	47
3.2.2 除噪声和高等欠采样方法	50
3.2.3 原始数据库前处理流程	51
3.3 增强类算法	56
3.3.1 增强类算法简介	57
3.3.2 AdaBoost 算法应用	58
3.4 预测效果与对比讨论	59
3.5 本章小结	60
第 4 章 基于 BWBN 的压弯耦合滞回模型	61
4.1 BWBN 滞回模型简介	63
4.1.1 微分方程形式	63
4.1.2 参数分析讨论	67
4.2 建立压弯耦合滞回模型	69
4.2.1 滞回模型的积分表示	69
4.2.2 引入压弯耦合效应	71
4.2.3 常轴力与变轴力滞回曲线对比分析	73
4.3 压弯耦合滞回模型参数识别	74
4.3.1 参数识别问题阐述	76
4.3.2 微分进化算法简介	76
4.3.3 参数识别结果讨论	78
4.4 本章小结	83
第 5 章 结论和展望	84

5.1 结论.....	84
5.2 展望.....	85
附录 神经网络分类机采用的数据库.....	86
参考文献.....	91
致谢.....	97
个人简历、在读期间发表的学术论文与研究成果.....	98

第1章 绪论

1.1 研究背景

新中国成立以来，在工业化和城市化两大引擎的强力推动下，中国经济长期保持高速增长。经济的快速发展进一步推动了城市的快速建设和城市人口的快速增长。从1949年到2018年，我国的城市人口占总人口的比例从10.6%增长到59.6%^[1]。为了满足大量涌入城市人口的居住、生活需求，大量的住宅和公共建筑如雨后春笋般涌现。以上海为例，2017年的建筑业总产值达到6426.42亿元，与2016年相比增长了6.3%；房屋建筑施工面积达到41197.49万平方米，与2016年相比增长了14.4%；竣工面积8066.54万平方米，与2016年相比增长了7.8%；总建筑面积6412.31万平方米，与2016年相比增长了19.62%^[2]。图1.1展示了新中国成立以前的上海外滩与现代上海外滩的对比。可见，建筑密度大、高层以及超高层建筑多是现代上海外滩建筑群的一大特点（图1.1）。



(a) 1880年的上海外滩



(b) 现代上海外滩

图 1.1 新中国成立前后上海外滩对比

这些住宅和公共建筑的建造和施工离不开建筑结构抗震设计规范的指导和支持。建筑结构的设计和建造，在满足承载能力极限状态要求的同时，还要保证结构的安全性、整体性、正常功能的使用性和耐久性。然而，在此期间，随着我国经济的稳定、快速发展，我国的建筑结构设计规范也经历着从无到有、从粗略到精细、从简单到丰富的长足发展^[3]。因此，城市化的突飞猛进，建筑结构抗震设计规范的不断调整，不可避免地导致了海量既有建筑结构抗震性能的参差不齐。目前，在我国中低抗震设防烈度地区的既有钢筋混凝土结构中，有很大一部分结构不能满足现行的抗震规范要求^[4]。其中的钢筋混凝土柱，通常存在箍筋过少或箍筋间距过大的问题，在地震作用下容易发生剪切破坏，进而导致不能承受楼板传来的竖向荷载，从而使得整个结构发生倒塌^[5]。因此，对于这些既有建筑中的非抗震钢筋混凝土柱，有必要开展抗震性

能评估。对于评估结果为高风险的构件，有必要开展简单、有效的加固改造工作，使之满足现行的抗震设计规范要求，以求在遭遇地震作用时减小整个结构发生倒塌的可能性，避免过大的经济损失和人员伤亡^[6]。

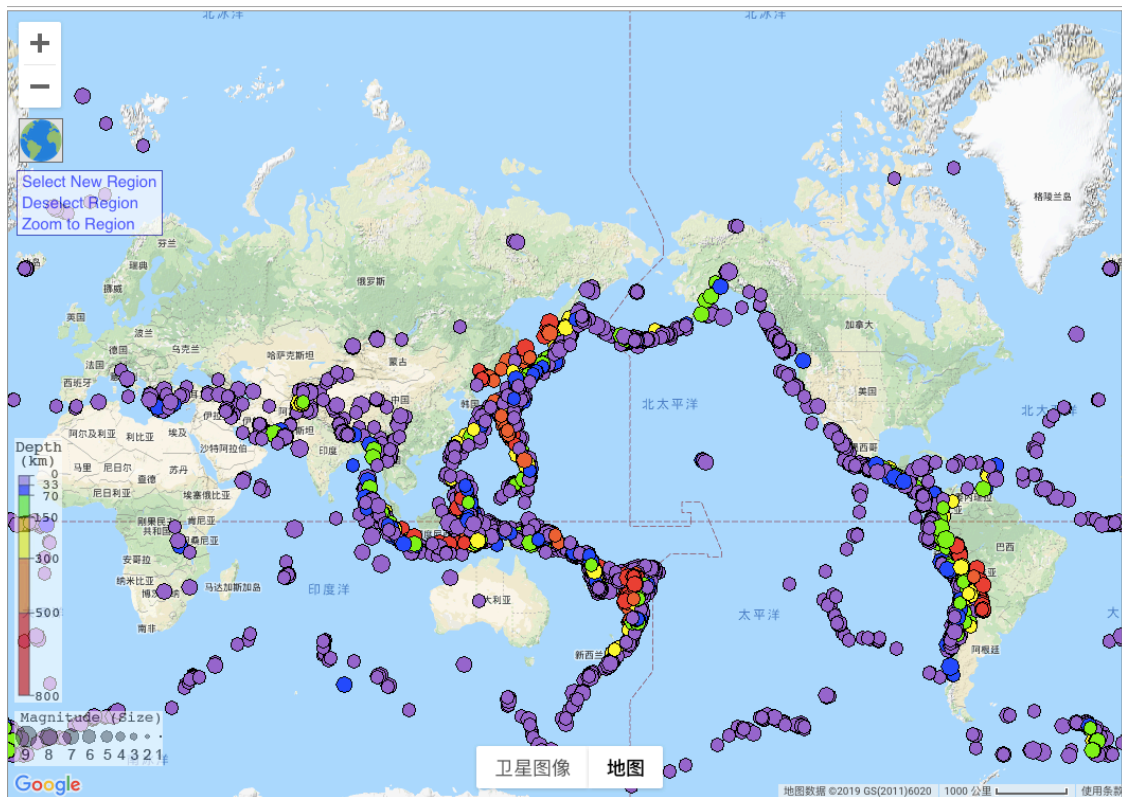


图 1.2 2000 年以来全球范围内 6.0 级以上地震分布

与此同时，近年来我国地震自然灾害频发。根据美国 Incorporated Research Institution for Seismology (IRIS) 数据库，2000 年以来全世界范围内共发生里氏 6.0 级以上地震 3000 余次，其中绝大多数为震源深度小于 70 千米的浅源地震，如图 1.2 所示。这里面就包括 2008 年 5 月 12 日的汶川地震和 2010 年 4 月 14 日的玉树地震。而汶川地震的震害调查结果表明^[7]，1978 年以前的建筑结构破坏情况最为严重，除了使用年限过长之外，一个重要原因是当时的经济水平较低，抗震设计规范较为简略，大多数房屋没有进行抗震设计或者抗震性能远不如现代建筑，而玉树地震巨大经济损失和人员伤亡的一个主要原因是由于地处偏远山区，交通不便造成建筑材料价格较高，同时当地居民没有足够的经济能力建造抗震性能良好的建筑。此外，汶川地震的震害调查结果还表明，即便是经过良好抗震设计的建筑结构，很多按照现代“强柱弱梁”抗震设计理念进行设计和建造的结构，由于楼板、填充墙和楼梯等因素的影响和增强，很少出现“强柱弱梁”型的延性破坏模式，甚至出现了错层结构，造成短柱剪切破坏、异形柱端部破坏等现象。究其原因，部分是由于目前钢筋混凝土基本构件的剪切失效机理尚不明晰，仍无法合理地基本力学原理出发，控制构件从弯曲失效到剪切失效的转化过程。在抗震设计中，一般需要事先假定构件发生弯曲失效，并在此基础上对

延性构件进行抗震分析和设计，以保证结构在地震作用下的耗能能力。同时，为了保证构件首先发生弯曲失效这一假定的合理性，利用“强柱弱梁”、“强剪弱弯”和“强节点弱构件”等设计理念来防止脆性剪切失效模式的发生。遗憾的是，汶川地震的震害调查结果表明，依据这样的抗震设计理念设计和建造的建筑结构并不能完全保证结构按照设计的方式发生破坏。鉴于此，有必要对结构构件的失效模式展开进一步的深入研究，通过准确判断构件的失效模式，可以为 20 世纪 70 年代以前既有建筑的抗震性能评估和加固提供更为理性的依据。

另一方面，随着我国经济的进一步发展，对于某些特别重要的建筑，在满足抗震设计规范要求的同时，还会进行更为精细的结构非线性有限元分析。地震作用下，这些结构通过表现出明显的滞回行为，因此一个可以准确反映结构构件在地震作用下各种力学行为的滞回模型对于这些非线性有限元分析至关重要。然而，目前在结构的非线性有限元分析中，滞回模型的选择与抗震设计规范存在类似的问题：即需要预先对构件的失效模式进行假定。如果假定的失效模式与实际失效模式不符，得到的分析结果往往与实际不符。譬如对于某些易于发生剪切失效的短柱，如果仍然采用常用的纤维截面模型，得到的结果与实际结果会有较大的偏差，因为此时对于发生剪切失效的短柱来说，平截面假定不再适用。鉴于此，有必要建立一个可以反映各种失效模式下构件滞回行为的滞回模型，与失效模式的分类模型一起，为钢筋混凝土柱在地震作用下的非线性有限元分析提供准确有效的恢复力信息。

1.2 抗震设计规范的发展变迁

通过梳理和总结我国建筑结构抗震规范的发展有助于加深对失效模式分类与滞回模型研究意义的理解。建国以来，我国的建筑结构抗震设计规范经历了从无到有、从粗略到精细、从简单到丰富的发展过程^[8]。抗震设计规范的这一发展历程，在一定程度上是由我国的经济发展和城市化发展所推动的。建国初期，从 1953 年开始的第一个五年计划期间内，我国并没有自己的抗震设计规范，而一般的工程如果按照苏联的抗震设计规范设计，土建投资需要增加 10%到 20%左右。考虑到当时国家经济较为困难，因此只有 156 项重点工程是按照苏联的抗震设计规范设计，而一般的工程均不进行抗震设防。

20 世纪 70 年代左右，我国开始尝试编制抗震设计规范，但未正式发布。1966 年和 1967 年邢台和河间地震后，人们开始对地震灾害逐渐建立起感性的认知，并逐步重视建筑结构的抗震性能。1974 年，我国出版了第一部正式批准的抗震设计规范《工业与民用建筑抗震设计规范》TJLL-74（试行）。1976 年唐山地震以后，我国对抗震设计规范的重视程度进一步提高，因此在 1978 年对 1974 版抗震规范进行了修订，出版了《工业与民用建筑抗震设计规范》TJLL-78。之后每过约十年，则发布了一版新的抗

震规范，分别为 89 版、2001 版和 2010 版《建筑抗震设计规范》。纵观我国建筑结构抗震设计规范的发展历程，大致可以分为三个阶段：研究探索初期、工业试行阶段和全面实践阶段^[8]。

1.2.1 研究探索初期阶段

从 1949 年新中国成立到 20 世纪 70 年代初，这一时期为我国建筑抗震设计规范的研究探索初期阶段。这一阶段没有我国自己的抗震技术标准和规范，但逐渐开始对建筑结构抗震设计进行探索。1955 年，翻译出版了苏联的《地震区建筑规范》。1956 年，编制了第一个中国地震烈度区划图，但未正式使用。1959 年，参考 1957 苏联 CH-8-57 规范提出了我国第一个抗震设计规范草案。同年，因国家建委撤销，此草案被暂时搁置。1964 年，提出了第二个抗震设计规范草案《地震区建筑设计规范（草案稿）》，此设计规范也未正式发布，只起到指导和参考作用^[8]。与 1959 年草案相比，1964 年的规范草案有以下几点进步^[8]：（1）废弃了按苏联经验采用的场地烈度概念，对场地的影响转而采用调整反应谱的方法。（2）1959 年草案中，利用宏观方法将场地分为三类，而在 1964 年草案中，则按照多物理指标分为四类。（3）将 1959 年草案中的地震系数改写为表示结构非弹性反应影响的结构系数 C 与表示实际地震动的地震系数 $K = a_{\max} / g$ 两个系数的乘积。（4）采用等效静力法与反应谱法对稳定性依赖于自重维持的结构和位于高烈度区的以自重为主要荷载的结构进行竖向地震力计算。

1.2.2 工业试行阶段

从 20 世纪 70 年代初开始到 20 世纪 80 年代末是我国抗震设计规范的工业试行阶段。1970 年，国家建委重新组织各单位主编我国的建筑抗震设计规范，并在 1974 年出版了我国第一部正式批准的抗震设计规范《工业与民建筑抗震设计规范》TJLL-74（试行）。1978 年唐山地震后，我国对 1974 版规范进行了修改，正式出版了《工业与民用建筑抗震设计规范》TJLL-78。这个版本的抗震设计规范对抗震概念设计的要求较为简单，对场地土的要求简略，仅需要对地基土的容许承载力进行验算，判别是否发生液化；在地震荷载计算方面，仅采用水平方向的底部剪力法和振型分解反应谱法；对构件截面的验算，用简单的几个参数对强度做要求，无详细规定；对框架结构，则要求设置抗震缝，要求质量中心和刚度中心重合，设置柱的最小配筋率，并给出了详细的节点构造图；对于砌体结构，限制了抗震横墙的间距以及建筑总高度，对一定高度的建筑，要求使用构造柱，并对部分情况下的混凝土预制楼板做了拉结要求^[9]。1977 年，我国第一个正式批准试行的抗震鉴定标准《工业与民用建筑抗震鉴定标准》TJ23-77 正式批准试行。

1.2.3 全面实践阶段

从20世纪90年代初开始至今是我国建筑结构抗震设计规范的全面实践阶段。1982年开始,由建筑科学研究院负责主编,对TJLL-78规范进行了修订,于1987年完成了《建筑抗震设计规范》GBJ11-89的送审稿,1989年由建设部批准,1990年实施^[10]。在这一版规范中,第一次采用了以概率可靠度为基础的“三水准”、“两阶段”的抗震设计思想。三水准为“小震不坏”、“中震可修”、“大震不倒”。两阶段为小震作用下的截面抗震验算和大震作用下的结构变形验算;在地震作用计算方法中,增加了结构时程分析法作为补充计算,另外还进一步加入了对扭转效应以及竖向地震效应的计算;在截面承载力的验算中,引入了抗震调整系数;对场地和地基土的类型进行了划分,较详细地对不同类型的地基土承载力进行了验算,并对液化土的液化程度进行了判别,提出了对应的抗液化措施;对结构的某些薄弱位置处,要求进行弹塑性变形计算;对框架结构,限制了抗震规范的最大使用高度,划分抗震等级,提出了规则结构的概念;对基础、钢筋的锚固提出了要求,设定截面设计的地震调幅,规定梁、柱和加密区的纵筋和箍筋间距和最小直径等要求,限制了柱的截面和轴压比;对砌体结构,增加了高宽比的要求,提出了详细的抗剪强度计算公式,对一定高度的建筑,要求使用构造柱,对横墙较少的建筑,譬如教学楼和医院等,则提高了对构造柱的要求,增加对多层砌块结构的要求。

1994年开始,由中国建筑科学研究院负责,开始了对GBJ11-89修订的准备工作,并于2001年4月完成了《建筑抗震设计规范》GB50011-2001的报批稿。2001年7月,建设部正式批准并与国家质量监督检验检疫总局联合发布这一规范。这一规范的改进之处在于:(1)建筑抗震设防依据不再使用近震、远震的概念,而代之以设计地震分组的概念。(2)提出了长周期和不同阻尼比的设计反应谱。(3)增加了结构规则性定义,并提出了相应的抗震概念设计。(4)新增加了若干类型结构的抗震设计原则。另外,对于场地和地基土增加了对断裂带的要求,对桩基的抗震提出要求;对地震荷载的计算,增加了对层间地震力的要求,考虑地基与结构的相互作用;对截面抗震验算则更为详细;对于框架结构,提高了对抗震等级的划分,提高了截面设计的地震调幅,对跨高比较小的连梁和剪跨比较小的柱提高了抗剪要求,提高了对柱截面、纵筋和箍筋的要求^[11]。

2006年开始,由中国建筑科学研究院负责,开始了GB50011-2001修订的准备工作,并在2007年1月通过了修订大纲。在修订过程中,系统总结了2008年汶川地震的震害经验,根据灾后重建的需要,对GB50011-2001进行了局部修订。此后,综合国内外大地震的经验教训,进行总结并最后定稿,形成了《建筑抗震设计规范》GB50011-2010的报批稿,并于2010年5月31日通过住房和城乡建设部正式批准,并与国家质量监督检验检疫总局联合发布这一规范。这一规范的主要改动为^[12]:(1)补充了关

于 7 度 (0.15g) 和 8 度 (0.30g) 区抗震设防的抗震措施规定, 按照《中国地震动参数区划图》调整了设计地震分组。(2) 改进了土壤液化判别公式, 对地震影响系数曲线的阻尼调整参数进行了调整, 完善了隔震结构的水平向减震系数的计算, 补充了大跨屋盖建筑水平和竖向地震作用的计算方法。(3) 对混凝土框架结构房屋、底部框架砌体房屋的抗震设计提出了更高的要求。(4) 明确了钢结构房屋抗震等级并对相应的抗震措施进行了调整。(5) 对多层砌体房屋、混凝土抗震墙房屋、配筋砌体房屋的抗震措施进行了改进。(6) 将隔震和消能减震的概念应用于更多的房屋类型。(7) 取消了内框架砖房的内容。

1.3 汶川地震和玉树地震的震害分析

2008 年 5 月 12 日 14 时 28 分, 四川省汶川县发生了里氏 8.0 级地震, 震源深度 14 千米。这是我国自建国以来遭遇的最为强烈的一次地震, 全国大部分地区均有明显震感。截至 2018 年 6 月 24 日, 地震造成 69185 人遇难, 18467 人失踪, 374170 人受伤, 4624 万人受灾^[7]。2010 年 4 月 14 日 7 时 49 分, 青海省玉树藏族自治州玉树县发生里氏 7.1 级地震, 震源深度 33 千米, 波及范围约 3.58 万平方千米, 极重灾区约为 1000 平方千米, 地震造成 2698 人遇难, 270 人失踪, 246842 人受灾, 直接经济损失达 610 多亿元^[13]。这两次大地震造成了巨大的人员伤亡和经济损失, 让人们进一步重视建筑结构的抗震性能。

1.3.1 汶川地震的震害分析

2008 年 5 月 12 日汶川地震发生后, 清华大学立刻组织了相关专业的专家赶赴四川协助抗震救灾, 西南交通大学和北京交通大学土木工程专家也先后分 3 批开展建筑震害调查, 广州建筑质监站专家也提供了相关建筑震害安全检查的数据^[7]。通过对各类结构形式的震害调查发现, 砖混结构在震区的数量最多, 且震害均比较严重, 发生倒塌的建筑一般抗震体系单薄, 没有设置构造柱和圈梁, 预制楼板未进行拉结; 框架砌体混合结构的结构体系则较为混乱, 受经济因素的限制, 多数此类建筑尽可能少的使用混凝土框架, 使得框架和砌体承重墙抗侧力构件的变形能力不协调, 侧向抗侧刚度分布极其不均匀。在这类结构中, 发现了很多由底部框架柱破坏导致的倒塌和倾覆。如图 1.3 所示。这种震害表明, 一旦结构柱由于侧向地震力的作用发生柱铰破坏, 或者剪切脆性破坏, 会随之失去承受竖向荷载的能力, 当建筑其他竖向承重构件的冗余度不足时, 容易引起建筑物整体发生垮塌, 造成非常严重的后果。



(a) 红白镇底框砖混加油站

(b) 都江堰魁光街底框砖混建筑震害

图 1.3 汶川地震中结构底部柱破坏情况^[7]

在汶川地震中，大多数框架结构的主要承力构件震害一般较轻，主要的破坏都集中在维护结构和填充结构上。调查发现，由于楼板、砌体或填充墙对框架梁刚度的增强作用，使得框架梁或屋盖的实际刚度远比设计刚度大，导致在实际震害中，很少出现“强柱弱梁”形式的破坏，如图 1.4 所示。根据调查，如果将地震区房屋建筑按照震后建筑结构的破坏程度分为 4 个等级：（1）可以使用。结构承重构件基本完好，仅有少量非结构构件的损伤，可以继续使用。（2）加固后使用。结构的承重构件发生一定的损伤，继续使用可能会加重结构的损伤，因此需要加固后使用。（3）停止使用。结构的承重构件发生严重损伤，不能继续使用。（4）立即拆除。结构的承重构件发生非常严重的损伤，随时都有可能倒塌。然后，按照结构类型对这 4 个等级的破坏程度进行统计发现，54%的框架结构是可以使用，只有 21%的砌体结构可以使用；框架结构中，有 7%需要立即拆除，7%需要停止使用；而在砌体结构中，26%需要立即拆除，16%需要停止使用。由此可见，框架结构的抗震性能优于砌体结构。而按照建筑的建造年代进行分类，则可以发现 1978 年以前建造的建筑中，43%都需要立即拆除，8%需要停止使用，39%加固后使用，仅有 10%可以使用；1979 年至 1988 年建造的建筑中，18%需要立即拆除，13%需要停止使用，34%加固后使用，只有 35%都可以使用；1989 年至 2001 年建造的建筑中，14%需要立即拆除，16%需要停止使用，31%加固后使用，有 39%可以使用；2002 年以后的建筑中，仅有 11%需要立即拆除，5%需要停止使用，有 31%加固后使用，53%可以使用。由此可见，随着建筑抗震设计规范的不断发展，按照新规范建造的建筑结构通常具有较好的抗震性能。但同时也需要注意到，仍然存在许多按照旧抗震规范建造的建筑，不能满足现行抗震规范的要求。鉴于此，为了防止这些建筑在未来可能发生的大地震中产生结构柱破坏，失去竖向承载能力，造成过大的人员伤亡和经济损失，需要对这些既有建筑中重要的结构柱进行抗震性能评估，尤其需要对其失效模式进行有效地判断，防止出现柱铰破坏，或者由于错层而导致的短柱剪切脆性破坏等。另一方面，对于重要性极高的建筑，还应该进行建筑在地震作

用下的非线性时程分析，这就需要对各种失效模式结构构件的滞回行为有一个准确的把握。



(a) 南坝镇强梁弱柱导柱顶产生塑性铰

(b) 框架结构错层造成短柱剪切破坏

图 1.4 汶川地震中出现的非强柱弱梁型破坏^[7]

1.3.2 玉树地震的震害分析

2010年4月14日玉树地震灾害发生后，青海省建设系统迅速组织灾后房屋安全评估组，于2010年4月28日赴玉树州开展房屋震害评估工作。此次调查结果同样表明，钢筋混凝土框架结构表现出了很好的抗震性能。严格按照抗震设计规范设计和施工的建筑，抗震性能明显优于没有进行抗震设计的建筑^[13]。在钢筋混凝土框架结构的建筑中，仅少数房屋由于结构柱破坏，导致坍塌、倾倒，如图1.5所示。在大震作用下，混凝土框架结构的破坏形式与汶川地震中类似，都是由于结构柱破坏后失去竖向承载力而导致的结构整体垮塌。此外，同样可以发现现行抗震设计规范中要求的梁铰机制破坏模式并没有实现，“强柱弱梁”的设计原则远没有得到体现。



(a) 玉树州国税局 4 层座塌为 2 层

(b) 某办公楼 1 层座塌、上部楼层整体倾倒

图 1.5 玉树地震中结构底部柱破坏情况^[13]

1.3.3 反思和讨论

汶川地震和玉树地震给人类带来灾害的同时，也留下了深刻的经验教训，这些经验教训指导着建筑结构抗震设计向更加成熟的方向发展。总结起来，有以下三点：

1. 随着我国经济的飞速发展，建筑结构抗震设计规范在建国以后的 70 年间不断发展，这使得许多建造于 20 世纪 70 年代以前的既有建筑不能满足现行的抗震设计规范要求，而在历次的震害调查中都发现，这些老建筑的抗震性能远不如新造的建筑。因此，随着我国城市化进程的不断推进，越来越多的人口进入城市，假如这些既有建筑在强震中发生由结构柱破坏而导致的整体倾覆或者倒塌，如果是在人口密集的大城市，造成的人员伤亡和经济损失将比汶川地震和玉树地震严重的多。因此，有必要对这些既有建筑的重要结构构件，尤其是结构柱的失效模式进行理性、准确的判别，并对易于发生钢筋混凝土柱脆性破坏的构件，提前进行加固工作，保证其具有足够的抗震性能。
2. 目前我国抗震设计规范关于构件抗震设计的基本原则是 20 世纪 70 年代新西兰 Park 教授提出的“强柱弱梁”、“强剪弱弯”和“强节点弱构件”原则。然而，最近几十年大地震的震害调查结果表明，即使是按照上述要求进行设计，也很难避免柱端铰破坏等脆性失效模式^[8]。在汶川地震的调查过程中，类似的发现实际的框架结构震害很少看到“强柱弱梁”式的失效模式^[7]。因此，即使对于按照现代抗震设计规范设计和施工的新建建筑，也易于出现结构柱发生脆性破坏的情况。近年来，我国的学术界和工程界已经开始关注这一问题，并在 2010 版规范修订时据此进行了相应的调整，提高了框架结构柱端弯矩调整系数的取值，但这并不能在根本上解决失效模式的判断和控制问题。一方面，如果系数调整的过于保守，会造成工程造价的增加，如果欠保守，就有可能使得脆性失效的发生，而综合安全性和经济性的方案，大都需要结合构件的设计特征进行确定，并不是笼统的，仅仅用单一的调整系数就能够考虑完善的。因此，有必要对现行抗震设计规范的设计理念进行全面而深刻的审视，尤其是对构件失效模式的判断开展详细的研究。
3. 随着结构非线性分析技术的不断发展，对于非常重要的结构，现在已有条件开展对结构整体的非线性时程分析。对于冗余度较高的建筑结构，单根结构柱的失效并不一定会引起结构整体的倒塌，因此有必要通过结构的非线性时程分析确定结构整体在地震作用下的响应。在这过程中，需要建立一个可以反映各种失效模式下构件滞回行为的滞回模型，与失效模式的分类模型一起，为结构构件在地震作用下的非线性分析提供准确有效的恢复力信息。

1.4 失效模式研究

钢筋混凝土柱目前尚未形成被一致认可的失效模式判断准则。工程师通常利用工程经验，依赖柱的某些关键设计参数，帮助确定柱的失效模式。然而，这仅对剪跨比较大、轴压比较低、纵筋配筋适量、箍筋配筋充足的一类失效特征特别明显的柱适用。对于剪跨比适中的柱，轴压比、纵筋配筋率和箍筋配筋率都是影响柱失效模式的重要因素，而工程经验一般无法有效综合考虑这些因素的共同影响。以下主要对现存文献中关于失效模式的判断准则进行梳理。

1.4.1 Setzler 和 Sezen 判断准则

为了计算钢筋混凝土柱在侧向力作用下柱顶的侧向变形，Setzler 和 Sezen 在 2009 年^[6]从理论分析的角度出发，把柱顶的侧向位移分为由弯曲变形引起的、由剪切变形引起的和由钢筋滑移变形引起的三个部分。将三种变形机制模拟成三种弹簧，形成一个串联弹簧机构，给定侧向力，相加三种变形引起的柱顶侧向位移得到钢筋混凝土柱的总位移，从而预测钢筋混凝土柱的力-位移曲线。显然，这种计算方法只适用于峰值点以前，当加载到峰值点以后，则先要通过比较剪切强度 (V_n)，屈服强度 (V_y) 和弯曲强度 (V_p) 的相对大小来判断失效模式，进而计算峰值点后的力学行为。其中，弯曲强度定义为柱底横截面可以承受的最大弯矩对应的水平荷载，屈服强度定义为纵向钢筋屈服时对应的水平荷载。这两个强度均可以通过截面的弯矩-曲率分析获得。剪切强度则可以利用 Sezen 和 Moehle 在 2008^[16]提出的公式计算。通过比较剪切强度、屈服强度和弯曲强度，Setzler 和 Sezen 将钢筋混凝土柱分为以下五个类别：（1） $V_n < V_y$ ：剪切强度小于屈服强度，柱发生剪切失效，弯曲变形仍然处在弹性阶段。（2） $V_y < V_n < 0.95V_p$ ：剪切强度大于屈服强度，但是小于弯曲强度，柱发生剪切失效，但是柱的弯曲变形进入塑性，开始逐渐影响峰值点后的力-位移曲线。（3） $0.95V_p < V_n < 1.05V_p$ ：弯曲强度和剪切强度大致相同，此时柱的失效模式处于临界状态，可以认为剪切失效和弯曲失效同时发生。（4） $1.05V_p < V_n < 1.40V_p$ ：剪切强度大于弯曲强度，柱在发生较大弯曲变形后发生弯曲失效，非弹性的剪切变形会影响峰值点后的力-位移曲线。（5） $V_n > 1.40V_p$ ：剪切强度远大于弯曲强度，柱发生弯曲失效，且剪切变形仍然处在弹性阶段。

Setzler 和 Sezen 的这一套失效模式判断准则，为钢筋混凝土柱失效模式的分类提供了清晰的理论图景，判断准则中的大部分物理量都有着明确的定义。但是，由于钢筋混凝土柱剪切行为的复杂性，利用现存的剪切理论模型计算得到的剪切强度离散性较大，从而导致在利用承载力相对大小关系判断失效模式时得到的预测结果变异性较大。2007 年，Zhu 等人^[17]在 Setzler 和 Sezen 工作的基础上，进一步定义剪切需求和剪切能力比 (r_s)，将上述分类方式等价于：如果 $r_s < 0.7$ ，发生弯曲失效；如果 $r_s = 0.7 -$

1.0, 发生弯剪失效; 如果 $r_s > 1.0$, 发生剪切失效。Zhu 等人对 125 根矩形截面钢筋混凝土柱试验数据进行了失效模式的分类, 结果表明: $r_s < 0.7$ 的柱中, 只有 191%的柱发生了弯曲失效; 而 $r_s = 0.7 - 1.0$ 的柱中, 只有 33%的柱发生了弯剪失效, $r_s > 1.0$ 的柱中, 只有 32%的柱发生了剪切失效。由此可见, 利用单一的确定性指标对钢筋混凝土柱的失效模式分类, 只对弯曲失效型柱具有较高的精度, 而无法很好地识别出弯剪失效型和剪切失效型柱。同时, 这些结果表明: 钢筋混凝土柱失效模式分类离散型大的症结在于剪切强度预测的不准确性。另一方面, Setzler 和 Sezen 失效模式判断准则的问题在于他们的理论不具有自洽性, 他们利用两个完全不同的理论模型分别计算剪切强度和弯曲强度, 然后通过比较这两个强度来判断失效模式。这种做法的合理性是值得商榷的。

1.4.2 基于简化桁架模型的概率指标

考虑到上述钢筋混凝土柱失效模式分类具有离散型大的特点, Ning 和 Feng 在 2018 年^[18]提出了失效模式概率指标的概念。利用这个概率指标, 可以将钢筋混凝土柱剪切强度预测公式的不确定性考虑到失效模式分类模型中, 在计算判断失效模式概率指标平均值的同时, 还可以得到概率指标的方差等信息, 从而可以对失效模式识别的准确性进行合理的估计, 为工程结构的可靠度分析提供有价值的信息。在这当中, Ning 和 Feng 概率指标的定义与 Zhu 等人^[17]的定义类似, 但是利用了统一的桁架-拱模型来计算弯曲强度和剪切强度。该模型采用桁架结构模拟钢筋混凝土柱在侧向力作用下力流从加载点到固定端的传力路径。通过将模型中的五个参数处理为随机变量来考虑剪切强度的不确定性, 采用 GLUE 方法^{[19][20]}计算参数的似然函数, 得到它们的后验分布, 并据此计算模型参数的均值和方差, 进而计算概率指标的均值和方差。然而, Ning 和 Feng 的概率指标虽然可以科学合理地考虑目前对钢筋混凝土弯剪竞争机理不清而导致的不确定性因素, 但没有直接解决失效模式识别预测离散型大的问题。

1.4.3 失效模式经验指标

Ma 和 Gong 在 2018 年^[21]对钢筋混凝土柱的试验数据进行了统计分析。通过对试验数据的初步分析后, 认为柱的剪跨比、轴压比、纵筋配筋指标和箍筋配筋指标 (与传统的配筋率定义略有不同) 是四个可以确定失效模式的关键因素。利用这四个关键参数, 构造出了一个简单的失效模式判断经验指标, 并对 351 根钢筋混凝土柱试验数据进行了分类。结果表明, 利用这四个关键参数作为输入信息, 可以很好地对钢筋混凝土柱的失效模式进行分类, 精度较高。然而, 虽然 Ma 和 Gong 提出的经验指标对 351 根钢筋混凝土柱具有较好的分类表现精度, 但存在以下几点不足: (1) 在构造经验指标时, 采用的函数形式具有任意性。(2) 研究给出的经验指标分类高精度是优化后的结果, 是利用 351 根试验数据对经验指标中的参数进行回归后得到的精度, 而没有利

用模型预测 351 根试验数据以外的试验结果，因此无法评估经验指标的泛化能力。（3）没有给出试验数据库中三种失效模式柱的分布情况，也没有给出分类结果的许多细节，只给出了精度信息，故无法判断分类结果的统计涨落特性。

1.4.4 失效模式研究中存在的问题

上述文献调研可以发现，利用单个指标对钢筋混凝土的失效模式进行分类预测是存在困难的。由于理论上无法对钢筋混凝土的抗剪承载力进行准确的预测，因此无法抓住从弯曲失效到剪切失效的这一转化过程。为了解决这一问题，本文引入机器学习方法来处理钢筋混凝土柱失效模式分类的问题。与现有的指标不同，机器学习方法尤其适用于这种机理不明的复杂工程问题，它能够从现有的、大量的试验数据中挖掘出潜在的失效模式转换规律，还可以利用各种方法在模型中引入非线性成分，以拟合复杂的决策边界。因此，机器学习模型可以联合考虑多种影响因素对钢筋混凝土柱的失效模式进行分类，避免了单一指标进行预测的局限性。

1.5 滞回模型研究

1.5.1 滞回模型研究新进展

一个可以反映地震作用下，从线弹性阶段到混凝土开裂、刚度衰减，再到裂缝增多、裂缝开闭和钢筋滑移造成捏拢效应，最后到构件出现强度退化和突然失效的滞回模型对于钢筋混凝土柱的抗震性能评估至关重要^[22]。因此，研究者在 Veletsos 等人^[23]提出的理想弹塑性滞回模型基础上，结合钢筋混凝土柱循环加载作用下的力学行为特征，相继提出了 Clough 模型^[24]、Takeda 模型^[25]、Sezen 和 Chowdhury 模型^[6]、Haselton 模型^[26]等折线型滞回模型。近些年来，新的折线型滞回模型层出不穷，在继承已有滞回模型优点的同时，这些新的滞回模型加入了反映试验局部损伤特征或微观损伤特征的新特点，向着精细化的方向不断发展。以下通过详细介绍近年来提出的三个具有代表性的滞回模型，说明钢筋混凝土柱滞回模型的发展趋势和存在的问题。

2009 年，Sezen 和 Chowdhury^[6]综合考虑钢筋混凝土柱的弯曲变形、剪切变形和纵向钢筋滑移，提出了一类折线型滞回模型。该模型通过纤维模型，结合弯矩-曲率分析计算弯曲变形，采用修正压力场理论^[27]计算剪切变形，利用 Sezen 和 Moehle^[28]与 Sezen 和 Setzler^[29]提出的简化分析方法计算滑移变形，首先获得了三种变形对应的单调加载骨架曲线，然后将此骨架曲线作为包络线，分别结合 Takeda 等人^[25]提出的弯曲滞回规则、Ozcebe 和 Saatcioglu^[30]提出的剪切滞回规则、Saatcioglu 等人^[31]提出的纵向钢筋滑移滞回规则得到三种变形对应的循环加载滞回模型。最后，考虑三种变形对钢筋混凝土柱总侧移变形的贡献，将三部分作为弹簧串联在一起，三部分承受相同外力，对变形量进行线性叠加。可见，此折线型滞回模型运用分步解决的研究方法，可以较为精

细化地反映钢筋混凝土柱三种变形的贡献比例。与试验对比分析结果表明,该模型对于峰值点以前的恢复力,可以给出很好的理论解释,且与试验结果的吻合程度较高。但在峰值点后,面对不同失效型的钢筋混凝土柱,其模型预测往往不能很好地反映真实的恢复力特征。主要原因在于,该模型利用不同的理论分别计算三种变形,并且假定三种变形可以直接求和,因此在实际应用中,理论的自洽性不足,如对于剪切失效型钢筋混凝土柱,由于应力分布不连续,采用纤维模型计算柱的弯曲变形成分显然是不合理。

2016年,Haselton等人^[26]认为ASCE/SEI 41^[32]中的力-位移关系没有单独考虑反复损伤累积引起的退化效应,容易给出过于保守的预测结果。因此,他们通过直接考虑反复损伤累积引起的退化效应,提出了一个基于现象学的折线型滞回模型。该滞回模型主要由单向加载骨架曲线、循环加载包络线和滞回规则构成。在对255根钢筋混凝土柱试验数据进行参数识别之后,Haselton等人采用经验回归分析方法,建立了从柱设计参数预测滞回模型关键参数的经验方程。然而,对应模型的建立,在模型参数的识别过程中,首先需要对单向加载骨架曲线进行参数校准,然后结合循环加载试验结果,识别滞回模型的参数。遗憾的是,目前几乎所有的钢筋混凝土柱试验数据都是循环加载作用下的结果,因此难于与已有的试验数据相结合。此外,Haselton等人选取的255根钢筋混凝土柱试验数据,其剪跨比范围为1.5-6.0,混合了剪切失效和弯剪失效两种破坏模式,建立的经验方程在实际预测时具有较大的离散性。

2016年,针对剪切失效型钢筋混凝土柱,Li和Hwang^[33]对其单向加载骨架曲线进行了详细研究。基于试验现象观察,他们提出了一个三折线滞回模型,包括开裂点、峰值点和破坏点(承载力为零)三个重要的控制点,分别对应混凝土开裂、裂缝间钢筋混凝土短柱压碎,整个构件达到抗剪强度和抗剪强度退化,构件失效三个损伤过程。其中,Li和Hwang采用ACI 318-14^[34]规范中的钢筋混凝土剪力墙开裂承载力公式计算开裂点对应的承载力,采用Hwang和Lee^[35]提出的软化短柱拉-压杆模型计算峰值点的承载力,采用Sezen和Moehle^[36]的方法,将侧向位移分为弯曲变形、剪切变形和滑移变形三个部分,分别计算开裂点、峰值点和破坏点对应的位移。显然,此三折线滞回模型的物理意义明确,计算相对复杂,可以对剪切失效型钢筋混凝土柱的恢复力包络线作出较为合理的预测。然而,Li和Hwang没有对加入滞回规则后的滞回模型开展进一步的研究。

1.5.2 滞回模型研究中存在的问题

目前,钢筋混凝土柱的滞回模型大多没有显式地考虑轴力对钢筋混凝土柱滞回行为的影响,仅将轴力作为设计参数考虑,属于一维内力空间内的恢复力-位移关系,不能反映变轴力情况下的滞回关系,而在地震作用下,尤其是竖向地震作用下,轴力具有较为明显的变化,因此已有的滞回模型难以描述变轴力作用下钢筋混凝土柱的滞回

曲线。同时，钢筋混凝土结构基本原理表明，构件的极限弯矩和轴力是相互耦的，轴力对构件极限弯矩的影响由构件的 P-M 曲线描述。另一方面，由于构件真实的滞回曲线刚度是连续变化的，如果采用简化的折线型模型描述构件的滞回行为，需要相对较多的模型参数才能准确的模拟其滞回曲线，但较多的模型参数会增加计算的复杂度和编程难度，同时拟合精度相对较差。

1.6 本文的主要研究思路和内容

钢筋混凝土柱是钢筋混凝土结构中非常重要的承力构件。钢筋混凝土柱失效模式的准确分类和滞回曲线的精确描述，是保证其抗震性能的关键环节。因此，本文首先针对钢筋混凝土柱的失效模式分类问题进行了深入研究，提出了适用于不同失效模式下的压弯耦合滞回模型，显式考虑了轴力对钢筋混凝土柱滞回行为的影响，为结构的非线性时程分析提供了准确有效的恢复力信息。本文的具体工作如下：

第二章采用机器学习算法处理了钢筋混凝土柱失效模式的分类问题，建立了从钢筋混凝土柱设计参数预测其失效模式的人工神经网络预测模型。在预测模型的建立过程中，发现并初步分析了原始数据库中的偏斜数据问题。最后，利用得到的神经网络预测模型开展了输入参数对失效模式影响的参数敏感性分析，研究了钢筋混凝土柱的失效模式演化过程。

第三章对钢筋混凝土柱失效模式分类问题中的偏斜数据问题进行了更为深入的讨论。首先利用几个简单的数值算例研究了偏斜数据如何影响训练得到的预测模型，并介绍了其中常用的处理方法。然后，利用主成分分析方法将 4 维的特征矢量空间降为 2 维，并按照不同的失效模式在此 2 维矢量空间进行可视化，通过观察不同失效模式集聚的特点，综合采用高等采样方法和除噪方法对原始数据进行了处理；最后，结合以单层决策树为基础预测模型的 AdaBoost 算法，对处理过后的数据库进行训练和测试，得到了更加准确的失效模式分类模型。

第四章提出了适用于钢筋混凝土柱的基于 BWBN 模型的压弯耦合滞回模型。首先简单介绍了 BWBN 模型的微分方程形式，并进行了模型参数的敏感性分析。然后，介绍了 BWBN 模型的积分表示形式，并在此基础上引入了压弯耦合效应；推导了对应的微分演化方程，建立了钢筋混凝土柱的压弯耦合滞回模型。针对压弯耦合滞回模型，利用微分进化算法，结合不同失效模式下钢筋混凝土柱的试验恢复力-位移曲线，对模型参数进行了识别。

第五章总结了本文的工作，给出了研究的结论，并对今后的工作做出了展望。

第2章 基于机器学习的失效模式分类

在震害调查中，钢筋混凝土柱的失效模式一般分为三种，分别为：剪切失效、弯剪失效和弯曲失效。剪切失效具有脆性破坏的特征，破坏前无明显征兆，耗能小。在地震作用下，剪切失效型的钢筋混凝土柱由于耗能能力差，无法为结构提供阻尼，减少结构位移。一旦发生剪切失效，不能承受楼板和梁传下来的竖向荷载，导致整个结构发生倒塌，造成严重的经济损失和人员伤亡。因此，剪切失效是工程中首先应该避免的失效模式。弯曲失效则具有延性破坏的特征，破坏前由于塑性变形的发展，一般会出现明显的大变形，耗能大。在地震作用下，弯曲失效型的钢筋混凝土柱可以为结构提供滞回阻尼，加速结构位移的衰减，保证结构的安全。因此，在我国钢筋混凝土结构设计和抗震规范^[12]中，一般按照弯曲失效来设计钢筋混凝土柱，而利用构造手段避免剪切失效的发生。然而，由于规范的不断更新和调整，在我国中、低抗震设防烈度地区的既有钢筋混凝土结构中，存在很大一部分钢筋混凝土柱不能满足现行的抗震规范要求。这类柱一般被称为非抗震钢筋混凝土柱^[4]。非抗震钢筋混凝土柱一般存在箍筋间距过大或者钢筋端部锚固不足等问题，在遭遇强烈地震作用时，由于缺乏足够的抗震构造要求，容易发生脆性破坏。因此，科学地对钢筋混凝土柱的失效模式进行分类判断，可以为抗震性能评估工作提供有价值的信息。

另一方面，由于不同失效模式下钢筋混凝土柱的滞回曲线各不相同，因此对钢筋混凝土柱失效模式的准确判断有助于对柱滞回曲线的精确预测。如图2.1所示。其中，剪切失效型钢筋混凝土柱的变形主要是由剪切变形组成的，在峰值点以后，其由剪切变形引起的恢复力退化严重，而弯曲失效型钢筋混凝土柱峰值点后的变形主要是由弯曲变形提供的，由于纵筋屈服，塑性变形发展成熟，由弯曲变形引起的恢复力退化较为缓慢，因此可以满足工程的延性需求。弯剪失效型钢筋混凝土柱的滞回曲线特征介于两者之间。




图 2.1 不同失效模式下柱的力学行为

三种失效模式对应不同的滞回曲线，造成在进行钢筋混凝土结构强震作用下的非线性结构分析时，如果假设的失效模式与实际失效模式不相符，即会得到不合理的分析结果。譬如，如果把剪切失效型钢筋混凝土柱错误地假设为弯曲失效型，则可利用基于纤维梁截面的梁-柱单元模拟钢筋混凝土柱的滞回曲线，但这种单元无法反映剪切失效型柱强度退化、刚度退化和捏拢效应等重要的力学行为特征。因此，有必要对钢筋混凝土柱失效模式的分类进行研究。然而，由于剪切失效机制的复杂性，目前还难以建立能够准确预测钢筋混凝土柱失效模式的理论模型。机器学习的方法十分适合用来处理这种机理尚不明确的问题。本章主要利用人工神经网络分类机，建立钢筋混凝土柱失效模式的分类预测模型，并对分类机的预测效果进行评估、对输入参数进行敏感性分析。

2.1 确定关键输入参数

在计算机科学和数据科学领域有一句话叫：垃圾进，垃圾出（garbage in garbage out），意思是说如果输入算法的数据本身存在问题的话，算法最后得到的结果必然也是有问题的。这句话强调了输入信息对于最终算法的优劣具有至关重要的作用，主要包括以下两层含义：

(1) 输入的变量不足以反映或预测我们感兴趣的变量。这一点用一个简单的例子来说明：假设我们想要预测流体垂直冲击障碍物时对障碍物表面作用的水压力，根据流体力学的知识，需要的输入信息为流体的密度和流速，缺一不可。假设我们希望通过机器学习的方法发现此流体力学的规律，但如果输入算法的参数错选为密度和加速度，则最终的算法不可能给出合理的预测结果。

(2) 输入数据库的数据分布本身有问题。还是用上述例子加以说明：假设输入算法的变量选择正确，但是输入算法数据具有一个奇怪的特点，密度和流速平方的乘

积集中分布在一个值附近，方差很小。根据流体力学的知识，水压力和这个乘积是成正比的，如果这个乘积的方差很小，得到的最终预测算法也会不可靠。

本节主要讨论第 1 个问题，即确定关键的输入参数。第 2 个问题将在下一节进行详细的讨论。目前，确定模型关键输入参数主要有两个方法：与物理原理相结合和量纲分析。关于失效模式的理论图景，在 1.4 节中已经有所讨论，即弯曲机制和剪切机制的相互竞争，引起了失效模式的转变，研究者们通过比较弯曲强度和剪切强度的大小关系来预测钢筋混凝土柱的失效模式，而剪切强度预测公式往往存在较大的离散性，容易导致分类预测效果不佳。但是，通过研究剪切强度理论预测公式中包含的输入参数，仍然可以为机器学习算法的输入参数选择提供一定的理论依据。因此，接下来将介绍 2 个剪切强度预测公式和 1 个弯曲强度预测公式，在对它们进行无量纲化处理后，从中提取出机器学习算法需要的关键输入参数。

2.1.1 剪切和弯曲强度公式讨论

在我国混凝土结构设计规范^[37]中，第 6.3.12 条提到：矩形、T 形、和 I 形截面的钢筋混凝土偏心受压构件，其斜截面抗剪承载力应该符合以下规定：

$$V_n = \frac{1.75}{\lambda + 1} f_t b h_0 + \frac{f_{yv} A_{sv} h_0}{s} + 0.07P \quad (2.1)$$

其中 λ 为柱的剪跨比， f_t 为混凝土的抗拉承载力， b 和 h_0 分别为矩形截面垂直于和平行于侧向力方向的尺寸， f_{yv} 和 A_{sv} 分别为箍筋的屈服强度和单肢截面积乘以抗剪的肢数， s 为箍筋间距， P 为轴压力。对于钢筋混凝土构件，一个很自然的强度单位是其抗压承载力 $f_c b h_0$ ，因此在式 (2.1) 两边同时除以抗压强度得到

$$\frac{V_n}{f_c b h_0} = \frac{1.75}{\lambda + 1} \frac{f_t}{f_c} + \frac{f_{yv} A_{sv}}{f_c b s} + \frac{0.07P}{f_c b h_0} \quad (2.2)$$

由式 (2.2) 可以发现，无量纲化的剪切强度主要与剪跨比 λ 、箍筋配筋率与箍筋屈服强度和混凝土抗压强度比值的乘积 $f_{yv} A_{sv} / f_c b s$ 以及轴压比 $N / f_c b h_0$ 三个输入变量有关。不同标号混凝土的抗拉和抗压承载力的比值变化一般不大，这里可以近似认为是一个常数。

类似的，Sezen 和 Moehle 在 2004^[38]提出的剪切强度公式为

$$V_n = k \left(\frac{0.5\sqrt{f_c}}{\lambda} \sqrt{1 + \frac{P}{0.5\sqrt{f_c} A_g}} 0.8A_g + \frac{A_{sv} f_{yv} h_0}{s} \right) \quad (2.3)$$

其中， k 是设计中需要考虑的折减系数，在这里不予考虑， A_g 为柱截面面积，其余符号意义与式 (2.1) 中相同。同样，可以发现 Sezen 的公式中一个类似于抗压承载力的值 $\sqrt{f_c} A_g$ 是自然的单位，因此将式 (2.3) 无量纲化得

$$\frac{V_n}{\sqrt{f_c A_g}} = k \left(\frac{0.5 \times 0.8}{\lambda} \sqrt{1 + \frac{P}{0.5 \sqrt{f_c A_g}} + \frac{A_{sv} f_{yv} h_0}{\sqrt{f_c A_g} s}} \right) \quad (2.4)$$

其中, $P/\sqrt{f_c A_g}$ 与轴压比的概念类似。由式 (2.4) 可以发现, 在 Sezen 的公式中, 无量纲化的剪切强度同样与剪跨比、轴压比以及箍筋配筋率与箍筋屈服强度和混凝土抗压强度比值的乘积三个无量纲参数有关, 但与我国混凝土结构设计规范不同的是, 在 Sezen 的剪切强度公式中, 剪跨比和轴压比的贡献是在同一项, 而不是简单的相加。

利用类似的方法, 对美国 ASCE-ACI Committee 426 (1973) 的剪切强度公式^[39]、Priestley 等人在 1994 年的剪切强度公式^[40]、Pan 和 Li 在 2012 年提出的剪切强度公式^[4]等进行简化分析, 其结果表明, 尽管每个预测公式的具体形式各有不同, 但用于预测剪切强度的输入参数主要是剪跨比、轴压比和箍筋配筋率与箍筋屈服强度和混凝土抗压强度比值的乘积这三个无量纲数。

对于弯曲强度, 目前关于钢筋混凝土构件弯曲行为的理论已经比较成熟, 这里以我国混凝土结构设计规范^[37]中偏压构件正截面弯曲承载力计算公式为例, 此处的处理方式与 Ma 和 Gong^[21] 类似:

$$P = f_c b x \quad (2.5)$$

$$M = f_c b x \left(h_0 - \frac{x}{2} \right) + A_s f_y (h_0 - a'_s) \quad (2.6)$$

其中 P 是构件承受的轴向压力, x 为受压区高度, M 为弯曲承载力, A_s 为纵筋截面积, f_y 为纵筋屈服强度, a_s 为截面受压侧保护层厚度, 其余符号的意义与本节其他公式中的相同。由于我们只对输入的无量纲变量感兴趣, 而不关注公式的具体形式, 故在以下的推导中忽略 a_s 项, 因为考虑到和 h_0 相比, 保护层厚度一般为一个小量。利用式 (2.5) 消去式 (2.6) 中的受压区高度 x , 并将 M 无量纲化 (对于侧向受力的悬臂构件来说, 自然的单位为 $f_c b h_0^2$) 可以得到

$$\frac{M/h_0}{f_c b h_0} = \frac{P}{f_c b h_0} \left(1 - \frac{P}{2 f_c b h_0} \right) + \frac{A_s f_y}{b h_0 f_c} \quad (2.7)$$

可以看到, 无量纲化的弯曲承载力, 主要受到轴压比以及纵筋配筋率和纵筋屈服强度与混凝土抗压强度比值的乘积影响。

2.1.2 四个关键输入参数的定义

经过上述分析, 选取 4 个关键输入参数, 分别为剪跨比 α_r , 轴压比 α_n , 纵筋配筋指标 α_1 和箍筋配筋指标 α_v

$$\alpha_r = \frac{L}{h}, \alpha_n = \frac{P}{f_c A_g}, \alpha_1 = \frac{f_y}{f_c} \rho, \alpha_v = \frac{f_{yv}}{f_c} \rho_v \quad (2.8)$$

其中 L 为剪跨, 定义为反弯点到柱固定端的距离, h 为截面深度, 即截面平行于侧向力方向的几何尺寸, P 为轴向压力, f_c 为混凝土的抗压强度, A_g 为截面毛截面积,

f_y, f_{yv} 分别为纵筋和箍筋的屈服强度, ρ, ρ_v 分别为纵筋配筋率和箍筋配筋率, 与常用配筋率定义相同

$$\rho = \frac{A_s}{A_g}, \rho_v = \frac{A_{sv}}{bs} \quad (2.9)$$

其中 A_s 为纵筋截面积, A_{sv} 为箍筋单肢截面积乘以抗剪的肢数, b 为截面宽度, 即截面垂直于侧向力方向的几何尺寸, s 为箍筋间距。值得一提的是, 这四个无量纲关键参数的定义与 Ma 和 Gong 构造失效模式经验指标^[21]所用的四个变量定义相同, Ning 和 Feng^[18]的简化桁架模型中也采用了相同的定义。

下面进行一个简单的总结: 通过对现存的剪切强度公式和弯曲强度公式进行简化分析, 发现输入的参数总是只有 4 个无量纲数, 只是公式形式各有不同。考虑到失效模式的判断一般是由剪切强度和弯曲强度的相对大小关系定义的, 所以认为这 4 个无量纲数也是影响钢筋混凝土失效模式的关键因素。因此, 选择这 4 个无量纲参数作为钢筋混凝土失效模式识别机器学习模型的输入参数。

2.2 试验数据库

机器学习技术是要在已有的数据中挖掘出有用的信息, 因此试验数据库的选择和处理尤为重要。要想获得较好的预测结果, 必须保证输入机器学习算法的数据质量, 同时保证数据分布的合理性。本节首先介绍机器学习算法用到的原始试验数据库的基本情况、原始数据分布情况、原始数据存在的问题以及相应的处理方法。然后, 将处理过的数据库作为机器学习算法的输入数据库, 保证机器学习算法输入数据分布的合理性, 为保证最终训练得到的机器学习预测模型质量奠定坚实的数据基础。

2.2.1 原始试验数据库

Pacific Earthquake Engineering Research (PEER) 中心提供了一个包含 251 条矩形截面钢筋混凝土柱数据的数据库^[41]。为了处理各个试验加载时柱两端固定方式不同的情况, 数据库将试件等效为悬臂柱, 并记录等效后的试件长度, 用于剪跨比的计算。按照试验现象的不同, 这些试件的失效模式被分为剪切失效、弯剪失效和弯曲失效三种。具体来说, 如果试验者没有在试验中发现剪切破坏的现象, 就将此试件分为弯曲失效; 如果试验者发现试件有剪切破坏的特征, 则需进一步计算有效恢复力绝对值的最大值, 并与最大应变为 0.004 对应的恢复力 ($F_{0.004}$) 进行对比, 如果有效恢复力绝对值的最大值比 $0.95F_{0.004}$ 小, 或者破坏时的延性系数小于 2 (见图 2.1), 就将此试件分为剪切失效; 除上述两种情况以外的试件, 则分为弯剪失效。这里注意到最大应变为 0.004 时候的恢复力基本对应于构件的弯曲强度, 因为一般认为混凝土的极限压应变为 0.0033。由此可见, PEER 数据库对失效模式的分类方式与 2.1 节介绍的理论框架基本一致。根据上述分类方式, 在 251 条数据中, 剪切失效型数据有 18 条, 弯剪失效型

数据有 36 条，弯曲失效型数据有 197 条，失效模式的分布情况，如图 2.2 所示。从饼状图可以看出，在原始数据库中，只有 7.2%的柱发生剪切破坏，14.3%的柱发生弯剪破坏，而有 78.5%的柱都是弯曲破坏，也就是说原始数据库的失效模式分布具有弯曲失效主导的特征。与三种失效模式均匀分布的数据库相比，具有弯曲失效主导特征的数据库，容易导致最终的机器学习预测模型具有预测弯曲失效的倾向性，因为这样的预测模型具有最优的目标函数取值，总体预测精度较高。但是用这样的数据库训练出来的模型是病态的，属于 2.1 节所提到的“输入数据库的数据分布本身有问题”。在第 2.2.2 分节以及第 3 章我们会着重处理原始数据库失效模式分布具有弯曲失效主导的问题。




图 2.2 PEER 数据库钢筋混凝土柱失效模式分布饼状图

原始数据库重要变量的数值统计特征，如表 2.1 所示。表中， b, h 分别为柱截面宽和高度（垂直于和平行于水平方向的几何尺寸）， L 为等效化悬臂柱的长度， f_c, f_y, f_{yv} 分别为混凝土抗压强度、纵筋屈服强度、箍筋屈服强度， ρ, ρ_v 分别为箍筋配筋率和箍筋配筋率。

表 2.1 原始数据库重要变量的数值统计特征

	b/mm	h/mm	L/mm	f_c/MPa	f_y/MPa	f_{yv}/MPa	$\rho/\%$	$\rho_v/\%$
均值	290	315	1091	52	489	434	2.37	0.82
方差	118	118	546	29	222	59	1.01	0.51
最小值	80	80	80	16	249	316	0.68	0.07
25%分位数	200	250	603	29	368	388	1.69	0.49
50%分位数	250	305	1140	36	428	437	2.22	0.71
75%分位数	400	400	1600	80	512	468	2.46	1.05
最大值	914	914	2335	118	1424	587	6.03	2.95

从表 2.1 可以看出,原始数据库覆盖的范围较广,截面宽 b 和截面高度 h 的范围均为 80 mm ~ 914 mm; 试件长度 L 的范围为 80 mm ~ 2335 mm; 混凝土抗压强度 f_c 的范围为 16 MPa ~ 118 MPa; 箍筋屈服强度 f_{yv} 的范围为 249 MPa ~ 1424 MPa; 纵筋屈服强度的范围为 316 MPa ~ 587 MPa; 纵筋配筋率 ρ 的范围为 0.68% ~ 6.03%; 箍筋配筋率 ρ_v 的范围为 0.07% ~ 2.95%。

图 2.3 是 4 个关键输入参数的分布情况。其中,剪跨比 α_r 的范围为 1.00 ~ 7.64,均值为 3.44,方差为 1.39; 轴压比的范围为 0 ~ 0.90,均值为 0.27,方差为 0.20; 纵筋配筋指标的范围为 0.06 ~ 0.51,均值为 0.24,方差为 0.11; 箍筋配筋指标的范围为 0.01 ~ 0.29,均值为 0.08,方差为 0.05。

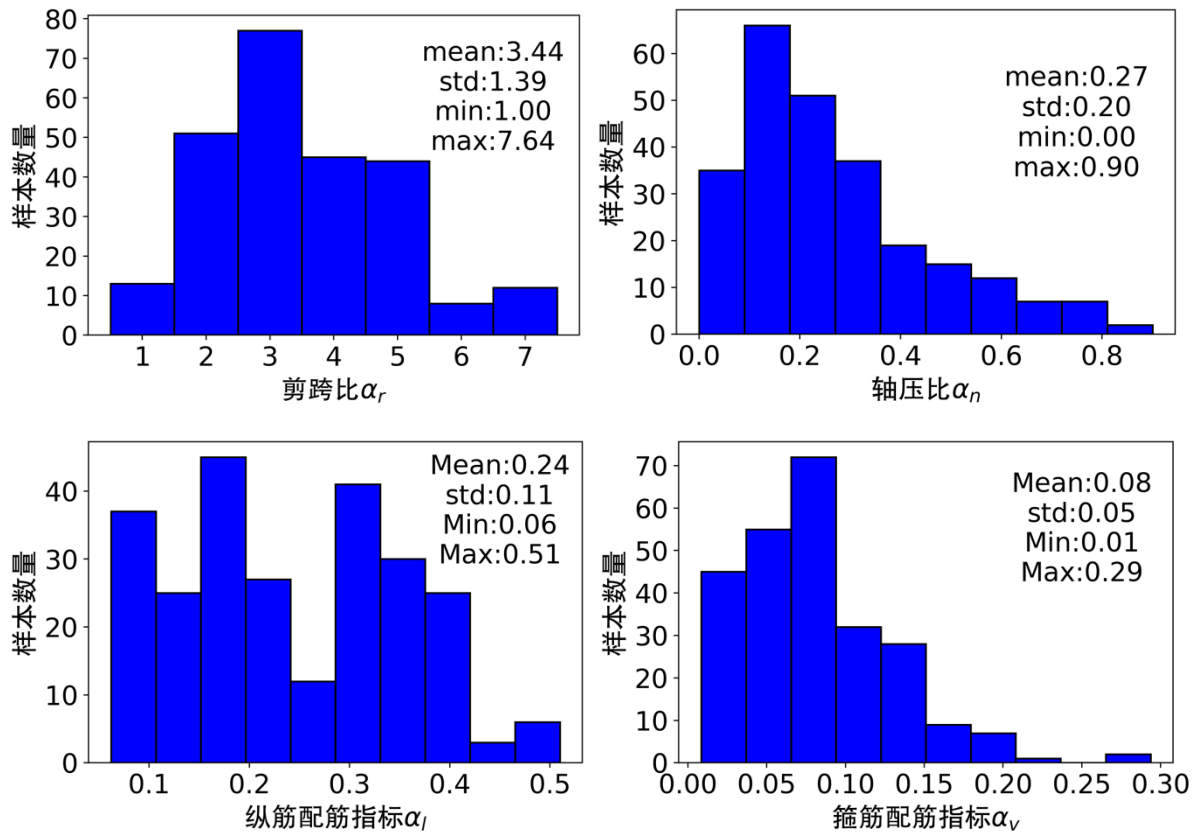


图 2.3 原始 PEER 数据库四个关键参数的分布

2.2.2 偏斜数据的处理

由于 PEER 原始试验数据库中弯曲失效型钢钢筋混凝土柱的数量远比其他两种失效模式钢筋混凝土柱的数量要多,如果不加处理,直接将原始试验数据库用于机器学习算法,会导致最终训练得到的预测模型具有预测弯曲失效的倾向性。由于其余两种失效模式的数据量很小,即使预测模型对这两种失效模式的预测不准确,反映在总体精度上的惩罚很小。这种现象在数据科学领域被称为偏斜数据问题 (skewed data)、或者分类不平衡问题 (class imbalance) [42]。在失效模式识别问题中,剪切失效和弯剪失

效数据的数据总量很小（分别为 18 和 36 条），占总体数据的百分比也很小（分别为 7.2%和 14.3%），这两类数据被称为少数类（minority classes）；弯曲失效数据的数据量较大（197 条），且占比很大（78.5%），所以叫多数类（majority class）。

有很多方法可以用来解决偏斜数据问题，这些解决方法可以分为两大类：1) 对数据库进行处理，这类方法被统称为采样方法（sampling method），可以进一步细分为过采样（over-sampling）和欠采样（under-sampling）两类子方法。过采样方法就是利用算法随机生成少数类数据，增加少数类的数据量，而欠采样就是随机丢弃多数类数据，减少多数类的数据量。2) 对机器学习算法进行改进，主要有损失函数敏感学习（cost-sensitive learning），即改进机器学习算法，使得算法可以考虑数据集分类的不平衡程度。3) 集成学习算法，例如增强算法（boosting algorithm）。增强算法是一个算法框架，可以与损失函数敏感学习技术以及采样方法等结合应用。不失一般性，本章选用最简单且有效的欠采样方法——随机欠采样。

丢弃数据量的确定需要利用到学习曲线，而学习曲线的概念在 2.3.4 分节会有详细介绍，这里仅仅陈述结果。在 197 条弯曲失效数据中通过随机采样选取了 97 条数据（即随机丢弃了 100 条弯曲失效数据）。另外，又从 Seismic Engineering Research Infrastructures for European Synergies (SERIES)^[43]整理的数据库另外收集了 7 条剪切失效的数据。因此，最终得到一个包含 158 条钢筋混凝土矩形截面柱的数据库作为机器学习算法的输入数据库（见附录）。在此数据库中，剪切失效型数据有 25 条，弯剪失效型数据有 36 条，弯曲失效型数据有 97 条，失效模式的分布情况，如图 2.4 所示。从图 2.4 可以看出，虽然处理后的数据库中弯曲失效型数据仍然占据大部分，但是与原始数据库（图 2.2）相比，处理过后的数据库失效模式分布的偏斜程度有了很大的改善；弯曲失效型数据从原来的 78.5%下降到 61.4%，剪切失效型数据从原来的 7.2%上升到 15.8%，弯剪失效型数据从原来的 14.3%上升到 22.8%。




图 2.4 随机欠采样后的失效模式分布饼状图

处理后的数据库其重要变量的数值统计特征，如表 2.2 所示。从表中可以看出，由于采用了随机欠采样的方法，得到的数据库重要变量的数值统计特征与原始数据库（表 2.1）相比变化很小。

表 2.2 随机欠采样后重要变量的数值统计特征

	b/mm	h/mm	L/mm	f_c/MPa	f_{yv}/MPa	f_y/MPa	$\rho/\%$	$\rho_v/\%$
均值	283	316	1062	46	463	426	2.39	0.77
方差	130	125	554	27	208	64	0.90	0.51
最小值	80	80	80	16	249	317	1.25	0.07
25%分位数	160	250	597	28	345	369	1.77	0.39
50%分位数	250	305	1070	34	412	434	2.22	0.70
75%分位数	400	400	1600	68	487	474	2.47	1.00
最大值	914	914	2335	118	1424	586	6.03	2.95

图 2.5 是处理后的数据库 4 个关键输入参数的分布情况。注意到与原始试验数据库相比，除了样本数量整体有下降以外，4 个关键参数的分布形状大致保持不变，这也进一步验证了随机欠采样的方法可以保持原始数据库数据分布的特点。值得注意的是，箍筋配筋指标 α_v 的分布有一些细微的变化，其中箍筋配筋指标在 0.05 ~ 0.10 范围的样本减少幅度远大于 0 ~ 0.05 范围的样本。这是因为我们大量减少了弯曲失效型样本，而弯曲失效型样本的箍筋配筋指标大都聚集在 0.05 ~ 0.10 的范围里。当箍筋配筋过少时，试件发生剪切失效的可能性更高。在 2.4 节讨论分类机的预测效果时，我们会将原始数据库训练得到的预测模型与用处理后的数据库训练得到的预测模型进行对比，由此进一步说明输入数据库的数据分布对最终预测算法的优劣具有至关重要的作用。

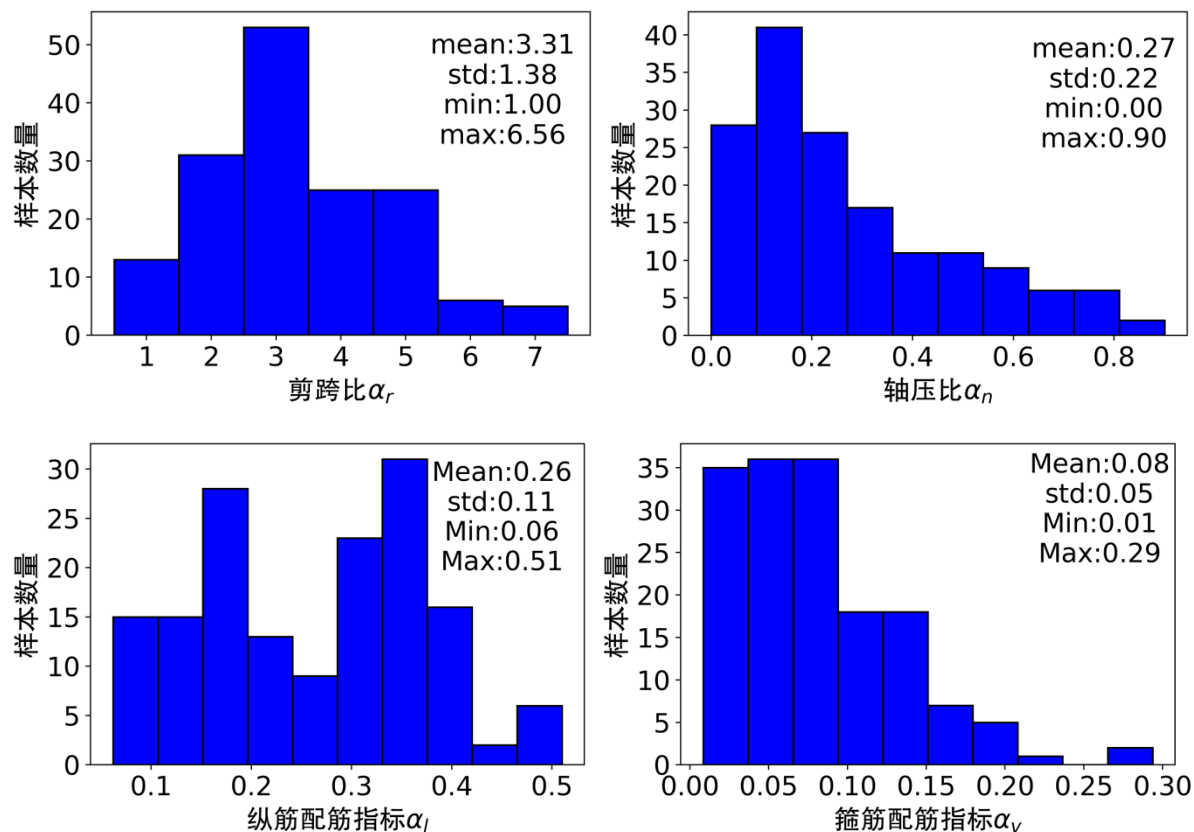


图 2.5 随机欠采样后四个关键参数的分布

2.3 人工神经网络分类机的构建

神经网络分类机是一类常用的机器学习模型。神经网络模型通过模拟生物体大脑中神经元传递和处理信息的结构，期望可以实现大脑擅长的模式识别和认知任务。与计算机相比，生物的大脑具有鲁棒性强、分布式程度深、并行处理方便、信息的存储和处理集成为一体等特征。现代神经学和解剖学认为，神经元细胞是生物大脑中负责传递、存储信息的重要组成部分。神经元细胞的解剖构造如图 2.6 所示，主要包含细胞体和两类树状的分支结构：轴突和树突。神经元细胞通过树突来接收其他神经元传递过来的电信号，通过轴突来将自身细胞体产生的电信号传递给其他神经元细胞。轴突在尾部分叉开来，并在分叉的末端长出突触。一旦电信号传递到轴突尾部的突触上，突触受到刺激，释放神经递质，传递给其他神经元细胞，刺激或者抑制其他神经细胞的激发水平。突触的敏感性会随着刺激信号的变化而不断自我调节，在特定的神经活动中，突触发展出特定的敏感性，表现出明显的自我学习行为。突触这种与神经活动历史相关的特性很有可能是人类大脑拥有记忆能力的原因^[44]。

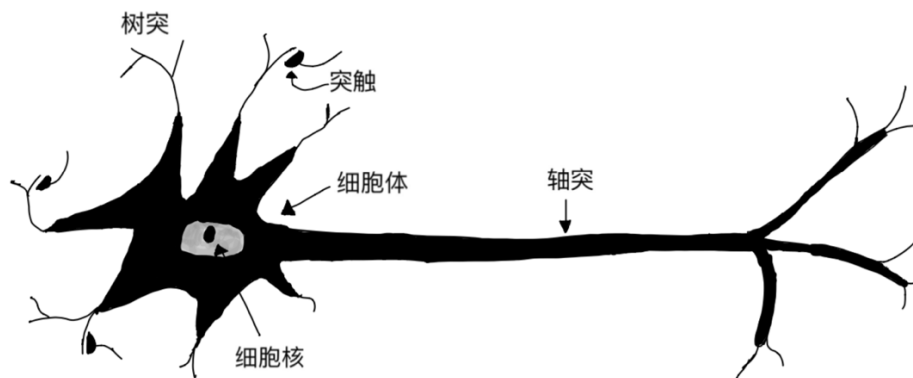


图 2.6 神经元

在人类大脑皮层大中，神经元细胞的数量级大约是 10^{11} ，这一数量级与银河系中恒星的总数相当^[45]，且神经元细胞之间的连接错综复杂，每个神经元都和另外 10^3 到 10^4 个神经元连接在一起，人脑中神经元细胞之间的连接总数大约在 10^{14} 到 10^{15} 数量级。虽然单个神经元细胞的构造相对简单，但当如此天文级别数量的神经元聚合在一起，相互联系、相互作用，就可以形成具有高级认知能力的大脑。著名的凝聚态物理学家菲利普·安德森（Philip Anderson）在他的一篇名为 *More Is Different*^[46] 的文章中提到，当系统的基本组成部分聚合在一起形成一个复杂结构时，往往会呈现出单个基本组成部分不具有的全新的性质（见图 2.7）。这种总体大于部分之和的现象也被称作涌现现象（*emergency*）。在凝聚态物理领域，物理学家们发展出了一套叫做对称性破缺的概念来理解基本粒子在形成简单的晶体结构或者量子多体系统时，从对称的量子态到具有一定空间结构物质的相变过程^[47]。对于其他尺度之间，从小实体相互作用组成大实体的转变过程，还有待进一步的科学研究。天文数量级的神经元细胞，如何通过相互连接和相互作用，形成有意识以及高级识别功能的大脑这一过程的理论认识，需要神经生理学、认知科学、心理学、统计物理学、控制论、计算机科学、人工智能、统计学等多学科跨学科合作^[44]。




图 2.7 由水分子聚合成雪花过程中的涌现现象（图片来自维基百科）

2.3.1 人工神经网络分类机理论

人工神经网络（Artificial Neural Network, ANN）是一种通过模仿人类大脑神经元的结构以及相互连接方式、信号传递过程的一类机器学习模型，一般用来实现分类和回归两种任务。在机器学习领域，人工神经网络分类机通常被用来进行分类。它们在 2012 年被成功地运用于图片识别领域^[48]，由此引起了人们的广泛关注。Krizhevsky 等人通过训练一个具有 6000 万个参数、65 万个神经元、5 层卷积层的卷积神经网络模型，将 120 万张图片分为 1000 种不同的类别，训练得到神经网络分类机具有前所未有的精度：置信度最高的前 5 个模型预测的错误率仅有 17%。人工神经网络分类机能够通过一组简单但非线性的变换来学习非常复杂的函数，这些非线性的函数变化可以自动学习分类任务所需的隐藏变量^[49]。与较老的学习算法（如逻辑回归）相比，随着隐藏层和神经元数量的增加，若同时保证输入算法的数据足够多，神经网络分类机可以训练得到性能更好的模型。

因此，人工神经网络分类机是一种典型的有监督学习。在有监督学习中，训练模型所用的数据由特征矢量 \mathbf{x} 和分类标签 \mathbf{y} 两部分组成（无监督学习的输入数据只有特征矢量 \mathbf{x} ，而没有分类标签 \mathbf{y} ）。注意到本研究中用小写粗体字母表示向量。通过训练得到人工神经网络分类机后，输入新数据的特征矢量 \mathbf{x} ，分类机可以预测此数据的分类 \mathbf{y} ，由此完成预测数据分类的任务。

I. 单个感知机




图 2.8 单个感知机和 Sigmoid 激活函数

为了模仿人类大脑皮层的解剖学构造，神经网络分类机的基本组成单元是与神经元细胞结构类似的感知机（perceptron），如图 2.8(a)所示。用带有 Sigmoid 激活函数的一个单元（即图中的用 a 表示的圆圈，后文中有时会称这一个单元为神经元）模拟神经元细胞的细胞体，输入此单元的信号来自人工神经网络中其他 d 个感知机 $x_1, \dots, x_j, \dots, x_d$ ，分别对应不同的权重 $w_1, \dots, w_j, \dots, w_d$ ，用来模拟不同的神经元释放的神经递质对此神经元细胞体的不同刺激（或抑制）作用。在此基础上，另外增加一项偏置单元 $x_0 \equiv +1$ 以及与之对应的偏置元权重 w_0 ，用来模拟此神经元细胞体在不受任何其他神经元信号刺激（或抑制）时的静置状态。将上述输入信号和权重紧凑地表示为列向量形式 $\mathbf{x} = [x_0, x_1, \dots, x_d]^T$ ， $\mathbf{w} = [w_0, w_1, \dots, w_d]^T$ 。同时，为了综合考虑这些其他 d 个感知机的信号对此单元的影响，选择将信号按照对应的权重进行线性组合

$$z = \sum_{i=0}^d w_i x_i = \mathbf{w}^T \mathbf{x} \quad (2.10)$$

线性组合得到的 z 就是综合考虑其他 d 个感知机输入信号后最终输入此单元的信号。然后，采用 Sigmoid 激活函数模拟神经元细胞体的单元带

$$g(z) = \frac{1}{1 + e^{-z}} \quad (2.11)$$

它的函数图像如图 2.8(b)所示，Sigmoid 函数可以将定义在实数域的线性组合值 z 挤压到区间 $(0,1)$ ，是用来模拟神经元体细胞受刺激（或抑制）后激发状态的常用非线性函数。由于 $g(z)$ 满足逻辑微分方程

$$\frac{d}{dz} g(z) = g(z)(1 - g(z)) \quad (2.12)$$

因此，只需要知道函数 $g(z)$ 在某点的取值，就能方便的求得 $g(z)$ 在这个点的导数值，从而方便将来利用梯度类优化算法进行机器学习模型的训练。进一步，将 z 通过 Sigmoid 函数后，得到此感知机的输出值

$$a = g(z) = g(\mathbf{w}^T \mathbf{x}) \tag{2.13}$$

输出值 a 模拟神经元细胞在受到其他 d 个神经元的刺激信号后，信号传递到轴突末端的突触时，突触释放出神经递质的过程。输出值 a 将会作为其他感知机的输入信号。

II. 人工神经网络分类机（也叫多层感知机）

将多个感知机排列在一起，形成人工神经网络分类机中的一层，层与层之间的感知机相互连接、传递信息，模拟生物神经系统中神经元细胞之间的相互作用过程，形成的网络结构被称为人工神经网络分类机。因为是由一层一层的感知机通过层与层直接连接构成，人工神经网络分类机有时也被称为多层感知机。下面以本文构建的人工神经网络分类机为例，介绍多个感知机如何共同组合成一个人工神经网络分类机。

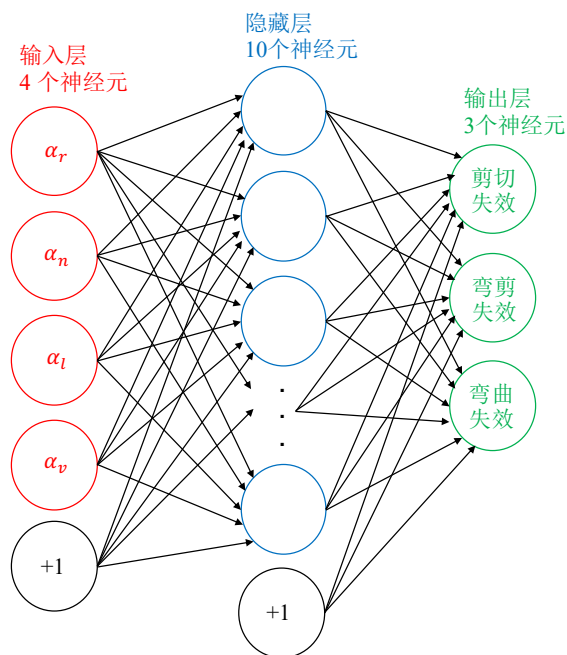


图 2.9 本文构建的神经网络分类机

如图 2.9 所示。人工神经网络分类机主要由输入层、输出层和隐藏层三部分组成。一般来说，输入层和输出层都是单层结构，分别代表输入训练数据的特征矢量 \mathbf{x} 和分类标签 \mathbf{y} 。在本文构建的神经网络分类机中，输入层包含 4 个神经元，代表 2.1 节定义的 4 个关键输入参数，分别为剪跨比 α_r ，轴压比 α_n ，纵筋配筋指标 α_l 和箍筋配筋指标 α_v ，它们的具体定义由式 (2.8) 给出。另外在输入层还加入了一个偏置元，取值恒为 +1，不失一般性，可以把它当做特征矢量的第一个分量。因此， $\mathbf{x} = [1, \alpha_r, \alpha_n, \alpha_l, \alpha_v]^T$ 。值得一提的是，输入层的 4 个神经元，并不接收其他神经元传递过来的信息，也不带有 Sigmoid 函数，仅用来输入数据的特征矢量 \mathbf{x} ，并传递给隐藏层各个神经元。输出层包含 3 个神经元，分别代表试验数据库标定的三种失效模式：剪切失效、弯剪失效和弯曲失效。这 3 个神经元都具有单个感知机的所有结构，输入信号为隐藏层最后一层神经元的输出值并根据对应的权重系数进行线性组合得到的结果，经过 Sigmoid 函数

后，输出值为神经网络分类机的分类预测。对于分类问题，数据的标签具有如下定义：标签向量 \mathbf{y} 的维度等于分类的数目，如果数据属于第 k 类，那么标签向量 \mathbf{y} 只有第 k 个分量等于 1，其余分量均等于 0。在本文构建的神经网络分类机中，一共有 3 类，因此标签向量 \mathbf{y} 是一个 3 维向量，我们规定剪切失效、弯剪失效和弯曲失效分别为第 1、2、3 类。假设一个数据属于剪切失效，对应的标签向量则为 $\mathbf{y} = [1,0,0]$ 。这样定义的标签向量具有概率上的意义， $\mathbf{y} = [1,0,0]$ 在概率上代表该数据属于剪切失效的概率等于 1，属于其他两种失效的概率等于 0。如果将某数据的特征矢量 \mathbf{x} 输入神经网络分类机，最后输出层输出的是一个三维向量，向量的每个分量都是一个属于区间(0,1)的数字，三个分量表示该数据属于对应类别的概率是多少。例如，如果输出向量为 (0.98,0.198,0.003)，则表示该数据属于剪切失效的概率为 98%，属于弯剪失效的概率为 19.8%，而属于弯曲失效的概率为 0.3%。最后，取概率最大的类别为分类机的预测类别。在上述例子中，分类机对该数据的预测为剪切失效。

隐藏层的层数和每层的神经元数量是可以自由调节的。一般来说，隐藏层的层数越多、每层的神经元数量越多，人工神经网络分类机越复杂，因此可以处理更加复杂的问题。一般来说，更大的输入训练数据量，得到的模型的预测效果会更好。但需要注意的是，在训练数据量不是很大的情况下，过于复杂的人工神经网络分类机，容易产生过拟合的现象。隐藏层的神经元具有单个感知机的所有结构，即从上一个隐藏层（或输入层）接收信号，并将信号输出到下一个隐藏层（或输出层）。本文构建的人工神经网络分类机有一个隐藏层，且此隐藏层的神经元数目设为 10 个。在这个隐藏层也加入了一个恒等于+1 的偏置元。关于隐藏层结构的确定，在下节将有详细介绍。

用向量和矩阵描述人工神经网络分类机。分类机的一层对应一个列向量，层与层之间的连接关系用权重矩阵表示，信号从前一层到后一层的传递由矩阵作用在前一层代表的列向量这一过程来表示。一个具有 l 个隐藏层的人工神经网络分类机，加上输入层和输出层，一共有 $l + 2$ 层。记第一层输入层为 $\mathbf{a}^{(1)} = \mathbf{x}$ ，最后一层输出层则为 $\mathbf{a}^{(l+2)}$ ，中间的隐藏层为 $\mathbf{a}^{(i)}, i = 2, 3, \dots, l + 1$ ，向量维度为 $d^{(i)}$ 。考察信息从第 i 层 $\mathbf{a}^{(i)}$ 到第 $i + 1$ 层第 k 个神经元 $a_k^{(i+1)}$ 的传递过程，用单个感知机结构来描述，因此可结合式 (2.10) 和式 (2.13)，得到

$$\mathbf{z}_k^{(i+1)} = \mathbf{w}_k^{(i)\top} [+1; \mathbf{a}^{(i)}] \quad (2.14)$$

$$a_k^{(i+1)} = g(\mathbf{z}_k^{(i+1)}) \quad (2.15)$$

其中 $[+1; \mathbf{a}^{(i)}]$ 表示首个分量为+1，其余分量构成列向量 $\mathbf{a}^{(i)}$ 的 $d^{(i)} + 1$ 维列向量， $\mathbf{w}_k^{(i)}$ 是权重列向量，维数为 $d^{(i)} + 1$ ， $k = 1, 2, \dots, d^{(i+1)}$ 。上面的表达可以更为紧凑地表示为

$$\mathbf{z}^{(i+1)} = \mathbf{W}^{(i)} [+1; \mathbf{a}^{(i)}] \quad (2.16)$$

$$\mathbf{a}^{(i+1)} = g(\mathbf{z}^{(i+1)}) \quad (2.17)$$

其中 $\mathbf{W}^{(i)}$ 为权重矩阵，矩阵的第 k 行为 $\mathbf{w}_k^{(i)\top}$ ，因此权重矩阵的维数为 $d^{(i+1)} \times (d^{(i)} + 1)$ 。式(2.16)和式(2.17)定义了信号从第 i 层到第 $i+1$ 的传递过程。显然，这是一个递推过程，从输入层开始，一层一层传递到最后一层输出层。只要给定所有的权重矩阵 $\mathbf{W}^{(i)}, i = 1, 2, \dots, l + 1$ ，就确定了一个神经网络模型分类机。通常将整个神经网络分类机表示为 $\mathbf{h} = \mathbf{h}_w(\mathbf{x})$ ，其中 \mathbf{x} 是送入输入层的特征矢量， \mathbf{h} 表示神经网络分类机输入层输出的预测向量，与数据的标签向量 \mathbf{y} 维度相同， w 表示所有权重矩阵构成的有序序列。分类机的训练过程，就是要寻找到最优的权重参数，使得模型在数据集上的分类误差最小，即让分类机预测 \mathbf{h} 与实际标签向量 \mathbf{y} 差异最小。

对于分类问题，一般利用交叉熵损失函数（cross-entropy cost function）来定量表示分类机预测与实际标签向量之间的差异。对于 K 分类问题，因输出层向量维数为 K ，假设数据总量为 m ，则交叉熵损失函数可定义为

$$J(w) = \frac{1}{m} \sum_{i=1}^m \sum_{k=1}^K \left[-y_k^{(i)} \log \{ [h_w(x^{(i)})]_k \} - (1 - y_k^{(i)}) \log \{ 1 - [h_w(x^{(i)})]_k \} \right] \quad (2.18)$$

需要注意的是，式(2.18)中的上标 (i) 代表第 i 个数据，与神经网络分类机的层数无关。该损失函数与统计学中伯努利统计模型的似然函数有着类似的数学形式。在用最大似然方法进行参数估计时，在数学上可以证明，这样的似然函数是凸函数，而凸函数在优化问题中是最容易处理的，可以避免陷入局部最优的问题。进而，对式(2.18)定义的交叉熵损失函数进行最优化，定义最优分类机的权重矩阵序列为

$$\hat{w} = \arg \max_w J(w) \quad (2.19)$$

该优化过程一般利用反向传播算法，该算法在机器学习的专著中有详细的推导和说明^[50]。因此，给定训练集数据，并利用反向传播算法，就可以得到最优分类机对应的权重矩阵有序序列 w 。

2.3.2 隐藏层结构的确定

虽然复杂的隐藏层得到的人工神经网络分类机具有更高的训练精度，但如果数据量的大小与隐藏层的复杂程度不匹配时，很容易产生过拟合现象，导致算法虽然在训练集具有很高的精度，但是对训练集以外的数据集预测精度比训练集的精度会低很多，这样的分类机泛化能力差，在实际应用过程中预测效果不理想。因此，在保证分类机具有较高的训练集精度后，需要控制隐藏层的复杂度。鉴于此，首先从单个隐藏层开始，逐渐增加隐藏层中神经元的个数，研究分类机在数据集上分类精度的变化。在这当中，分类的精度就是分类机分类正确的数据数量与数据总量的比值。分类机的训练精度如图2.10所示。可见，随着隐藏层神经元数量的增加，分类机训练精度从84%逐渐增加，当隐藏层神经元数量增加到10个之后，训练精度开始稳定在98%到99%之间。由此可见，一个包含10个神经元（不包括偏置元）的单隐藏层结构对于钢筋混凝土

土柱的失效模式分类问题已经拥有足够的精度。本文构建的人工神经网络分类机的总体结构如图 2.9 所示。




图 2.10 分类机训练精度和隐藏层神经元数量的关系

值得一提的是，上述“模型越复杂容易引起过拟合”的观点是经典统计学习理论中的核心概念——偏差-方差权衡（bias-variance tradeoff）的一种具体体现^[51]，下述 2.3.3 节采用的规则化参数也是用来进一步控制预测模型的偏差-方差权衡，而这种观点仅适用于规模较小的人工神经网络模型。近几年，神经网络方面的研究表明，当神经网络模型的参数达到几百万个以后，多数情况下此模型在测试集上的预测效果要比规模较小的神经网络模型要好^[52]。因此测试集的错误率会随着神经网络复杂度的提高出现先下降、后上升、再一次下降的趋势，这被称为双下降现象（double descent）^[53]，如图 2.11 所示：(a)图展示了当模型复杂度适中时，测试集错误率呈 U 型，预测模型随着复杂度的提高，从欠拟合到过拟合演化；(b)图展示了当模型复杂度很大时，测试集错误率在达到一个极大值后再一次随着模型复杂度的提高而下降。这种现象表明，当模型的复杂度超过内插复杂度的阈值后，越复杂的模型不仅不会产生过拟合问题，反而可以得到更好的预测结果^[54]。




图 2.11 训练集和测试集错误率随模型复杂度的变化：(a)模型复杂度适中 (b)模型复杂度很大

目前，对于双下降现象的研究尚不完善，关于神经网络模型的复杂度与其预测能力是否成正相关这一点上，还未形成定论。此外，许多基本性的概念还需要进一步的研究和讨论。譬如对模型复杂度的合理定义^[58]以及对双下降曲线在模型复杂度趋向于无穷时的渐进行为的讨论^[59]等。因此，考虑当模型复杂度很大时的深度学习理论尚且处于发展过程中，还没有足够成熟的经验性和理论性支持，本文仅在图 2.11(b)中的“经典”区域进行讨论。

2.3.3 规则化参数的确定

虽然通过控制隐藏层结构的复杂度可以在一定程度上减轻过拟合的问题，但是人工神经网络分类机本身并没有任何其他控制过拟合的机制。对于给定数据集，随着人工神经网络分类机隐藏层结构复杂度的增加，分类机的学习能力不断增强，总会或多或少产生过拟合问题。在确定隐藏层结构时，本文构建的人工神经网络分类机的训练精度高达 98%，显然有产生过拟合问题的可能性，而最优的分类机不仅需要对训练集数据具有较高的分类精度，还应该有良好的泛化能力，即对训练集以外的数据也应具有较好的分类预测精度。因此，除非训练分类机的数据量高达几百几千万，一般都建议要在人工神经网络分类机中加入规则化项来对过拟合问题加以控制^[60]。

分析过拟合问题产生的原因，首先以一元回归问题为例，给定输入自变量 x ，想要预测因变量 y 。为了考虑 x 与 y 之间的非线性关系，考虑利用 x 的 d 阶多项式来作为回归函数 $y = a_0 + a_1x + a_2x^2 + \dots + a_dx^d$ ，其中 a_0, a_1, \dots, a_d 为模型参数。显然，多项式的阶数越高，模型参数越多，模型的复杂程度越高，对训练集数据的拟合效果越好，但如果数据存在噪声的话，很容易产生过拟合问题。如图 2.12 所示，黑色实线表示实际的函数，它是一个 2 阶多项式，黑色叉形数据点是在实际的函数上加上了高斯噪声，用 1 阶多项式和 8 阶多项式对数据点进行拟合，可以发现 8 阶多项式的图像比 1 阶多项式和实际函数更接近黑色数据点，但是对于自变量 x 比 4 稍大的数据，8 阶多项式的预测与实际数据的预测偏差会非常大，这就是出现了典型的过拟合现象。在这当中，8

阶多项式拟合结果的震荡非常厉害主要是因为拟合函数中存在阶数过高的项引起的。通过观察高阶项前面的系数发现，4、5、6、7阶的系数在数值上有很大的绝对值，分别为 $a_4 = -51, a_5 = 106, a_6 = -93, a_7 = 34$ ，而其余各项的系数绝对值都小于10。由于自变量的取值绝对值都小于4，因此这几项在拟合中起了主导作用，这同时导致拟合结果的震荡非常严重。由此可见，想要控制过拟合问题，可以控制高阶项系数的绝对值大小，当高阶项系数绝对值较小时，高阶项产生的贡献也就被抑制了。




图 2.12 一元回归中的过拟合

因此，在人工神经网络分类机的交叉熵损失函数（2.18）中，可以加入一个规则化项，来惩罚较大的非线性项系数

$$J(w) = \frac{1}{m} \sum_{i=1}^m \sum_{k=1}^K \left[-y_k^{(i)} \log \{ [h_w(x^{(i)})]_k \} - (1 - y_k^{(i)}) \log \{ 1 - [h_w(x^{(i)})]_k \} \right] + \frac{\lambda}{2m} \sum_i \sum_{j=1} \sum_{k=2} (W_{j,k}^{(i)})^2 \quad (2.20)$$

其中 $\lambda \geq 0$ ，是用来调解规则化程度的参数，被称为规则化参数； $W_{j,k}^{(i)}$ 表示位于第 i 层和第 $i+1$ 层之间的权重矩阵 $\mathbf{W}^{(i)}$ 的第 (j,k) 个元素。注意到权重矩阵第一列 $W_{j,k}^{(i)}, k=1$ 对应的偏置元权重不会在模型中引入非线性，因此不会引起过拟合问题，不需要加入到规则化项中，而当非偏置神经元对应的权重系数值越大，对损失函数的惩罚就越大。当权重系数相同时，规则化参数 λ 越大，惩罚越大。因此可以认为，当规则化参数 λ 较小时，得到的模型非线性程度大，当规则化参数较大时候，得到的模型越来越趋于线性化。

对于加入了规则化项的人工神经网络分类机，一般利用如下流程：首先将全部数据集分为训练集、交叉验证集和测试集三个部分；然后，固定规则化参数 λ 的取值，利用训练集训练得到分类机的权重矩阵序列 w ，得到一个分类机，并用交叉验证集数据评估此分类机的泛化能力；进而，改变 λ 的取值，重复上述步骤；最后，选出在交叉验

证集表现最好的分类机作为最后的预测模型，并利用测试集评估这个最终模型的预测能力。值得一提的是，直接用最终分类机在交叉验证集上的精度来评估分类机的预测效果是不合理的，因为交叉验证集数据是用来确定模型的规则化参数的，因此分类机在交叉验证集上的预测精度是一个最优解。最合理的做法就是事先分出一部分测试集，用来评估最终模型的预测性能，而不在模型训练和调参的过程中使用。

对于钢筋混凝土柱的失效模式分类问题，如图 2.13 所示，首先需要把全部数据集分为训练集、交叉验证集和测试集三个部分，注意到目前还没有形成一套通用的方法来确定这三个数据集占全部数据集的比例^{[61][62]}。在本研究中，采用了随机采样的方法，将 2.2 节处理过偏斜数据问题后的包含 158 条钢筋混凝土矩形截面柱的数据库的 60%划分为训练集，20%划分为交叉验证集，剩下的 20%作为测试集，这三个数据集包含的数据量分别为 95、29、34。然后，规则化参数 λ 的取值从 0 变化到 2，一共取 10 个等间距的点，并记录每个规则化参数取值得到的分类机的训练集错误率和交叉验证集错误率，得到的结果如图 2.14 所示。从图中可以看到，随着规则化参数取值的增大，训练集错误率逐渐增加，这是因为人工神经网络分类机的非线性性质会随着规则化参数的增加受到越来越严格的控制。当规则化参数取为 0.022 时，交叉验证集的错误率最小，为 17%。因此，最终规则化参数的取值为 0.022，对应的训练集精度和交叉验证集精度分别为 97%和 83%。

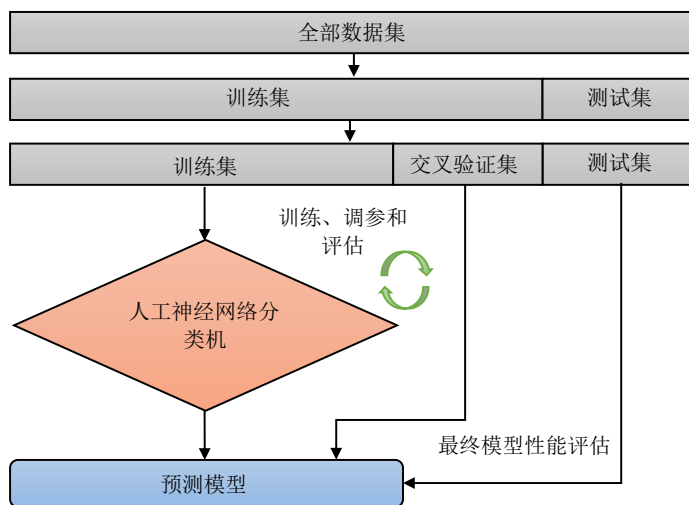


图 2.13 训练、调参和模型评估流程




图 2.14 规则化参数的确定

2.3.4 数据量大小的确定

注意到，在 2.2.2 分节处理偏斜数据问题时，我们随机丢弃了 100 条弯曲失效数据。这一节对丢弃数据量的多少给出详细的说明。通常，我们在确定送入机器学习算法的数据量是否足够时可以采用学习曲线。学习曲线表示的是随着训练集数据量的增加，机器学习的算法在训练集和交叉验证集上预测错误率的变化。一般来说，随着训练数据集数据量的增加，训练集的错误率会逐渐上升，交叉验证集的错误率会逐渐下降。当两者的变化随着数据量的增加变化趋于平缓时，意味着数据量已经逐渐趋于饱和。也就是说，在不改变机器学习算法本身的情况下，即使进一步增加数据量，也不能改善预测模型的效果了。

对于钢筋混凝土柱的失效模式分类问题，首先将规则化参数 λ 设置为最优值 0.022，然后从 1 开始增加送入算法的训练数据样本量，以 10 为增量步，一直增加到 91 为止（训练集的数据量为 95），记录每个训练数据样本量情况下的训练集错误率和交叉验证集错误率，得到的学习曲线如图 2.15 所示。可以看到，当数据量在 71 到 91 之间时，交叉验证集的错误率开始趋于平缓。由此可见，留下的 158 条数据对于本文构建的神经网络模型来说是合理的，在解决偏斜数据库问题的同时，又不至于过分影响最终预测模型的效果。




图 2.15 学习曲线

2.4 分类机的预测效果和参数敏感性分析

在 2.3 节，我们完成了人工神经网络模型的构建，得到了一个单隐藏层人工神经网络分类机，此隐藏层包含 10 个神经元（不包括偏置元），在损失函数中加入了规则化项来控制分类机的过拟合问题，并用交叉验证集数据确定了规则化参数 λ 的取值为 0.022。接下来，将利用预留的测试集数据，对 2.3 节得到的人工神经网络分类机的预测能力进行评估。

2.4.1 预测精度和混淆矩阵

在这里，利用混淆矩阵来评估分类机的分类预测能力。通过比较预测分类与实际分类，可以得到一个 3×3 的混淆矩阵，如表 2.3 所示。混淆矩阵的一行表示实际的分类结果，一列表示预测的结果。因此，混淆矩阵可以直观、全面的反映分类机的预测效果。从表中可以看到，测试集共有 34 条数据，实际发生剪切失效、弯剪失效和弯曲失效的数据分别为 6、8 和 20 条，分类机分别预测了 5、11 和 18 条剪切失效、弯剪失效和弯曲失效结果。进一步，利用两个指标来评估此人工神经网络分类机的预测效果：准确率和召回率。对于每一个失效类型，准确率定义为正确分类的数据总量除以分类机预测此类的总数据量，而召回率定义为正确分类的数据量除以实际为此分类的总数据量。因此，对于 6 条实际发生剪切失效的数据，分类机能正确地将其中 5 条识别出来，只有 1 条被错误地识别为弯剪失效，因此剪切失效的召回率为 83%；其次，分类机一共预测了 5 个剪切失效结果，这 5 个预测全部正确，因此剪切失效的准确率为 100%。对于 8 条实际发生弯剪失效的数据，分类机能正确地将其中 7 条识别出来，只有 1 条被错误地识别为弯曲失效，因此弯剪失效的召回率为 88%；其次，分类机一共预测了 11 个弯剪失效结果，其中有 7 个预测正确，4 个预测错误。其中，1 个实际为剪

切失效，3个实际为弯剪失效，因此弯剪失效的准确率为64%。另外，对于20条弯曲失效数据，分类机能正确地将其中17条识别出来，只有3条被错误地识别为弯剪失效，因此弯曲失效的召回率为85%；分类机一共预测了18个弯曲失效结果，其中有17个预测正确，1个实际为弯剪失效，因此弯曲失效的准确率为94%。

表 2.3 分类机的测试集混淆矩阵

失效模式		预测结果			总计
		剪切失效	弯剪失效	弯曲失效	
实际结果	剪切失效	5	1	0	6
	弯剪失效	0	7	1	8
	弯曲失效	0	3	17	20
总计		5	11	18	34

在此基础上，还可以利用 F_1 指标联合考虑准确率和召回率这两个指标。 F_1 指标定义为准确率和召回率的调和平均数

$$F_1 = \frac{2}{\frac{1}{\text{准确率}} + \frac{1}{\text{召回率}}} \quad (2.21)$$

因此，剪切失效、弯剪失效和弯曲失效的 F_1 指标分别为 91%，74%和 89%。显然，分类机对剪切失效和弯曲失效两种模式的分类效果都非常好，而对弯剪失效模式的分类效果不如另外两种好，这是因为弯剪失效模式本身就是介于剪切失效和弯曲失效之间的一种失效模式。在基于试验观测进行定义时，弯剪失效模式本身就较为模棱两可，它兼备剪切失效和弯曲失效两者的特征。另外注意到，在混淆矩阵中，只有相邻的失效模式才会发生误判，而在剪切失效和弯剪失效这两者之间没有相互误判。这说明相邻失效模式之间的分界线实际上是较为模糊的，这主要是由于钢筋混凝土柱的失效模式尚未形成统一、明确、科学、客观的定义^[18]。PEER 数据库对失效模式的标定，首先依赖于原始文献中试验者是否报告发生剪切破坏，但试验者的判断并没有遵循统一的分类标准，大都基于经验的主观性判断。在缺乏失效模式明确定义的情况下，这样的主观判断本身就是具有一定的离散性和不确定性的。因此，在形成失效模式统一定义以前，失效模式的识别预测必然具有其内禀的离散型。

在 2.2.2 节处理偏斜数据问题时，我们随机丢弃了 100 条弯曲失效数据，由于这些数据没有用来训练和调整人工神经网络分类机，他们可以用来测试最终分类机的预测效果。对于这 100 条实际弯曲失效的数据，分类机能正确地将其中 97 条识别出来，只有 2 条被错误地识别为弯剪失效，1 条被错误地识别为剪切失效。因此，对于这 100 条数据，弯曲失效的准确率高达 97%。

为了进一步说明 2.2.2 节处理偏斜数据的必要性，我们利用原始数据库的 251 条数据，采用与 2.3.3 节同样的流程训练和调节得到一个分类机，这个分类机在测试集的混

淆矩阵如表 2.4 所示。从表中可以看出，此分类机在弯曲失效模式的召回率为 100%，准确率为 98%， F_1 指标为 99%；在弯剪失效模式的召回率为 75%，准确率为 67%， F_1 指标为 71%；在剪切失效模式的召回率为 40%，准确率为 67%， F_1 指标为 50%。由此可见，用原始数据库得到的分类机容易只对弯曲失效具有较好的预测效果，却失去了对剪切失效的预测能力。这种预测效果偏向弯曲失效的原因就是由原始数据库失效模式的分布严重偏向于弯曲失效引起的。这两个混淆矩阵的对比表明了输入的数据库质量对最终得到的人工神经网络分类机的预测效果有很大的影响。

表 2.4 用原始数据库得到的分类机测试集混淆矩阵

失效模式		预测结果			总计
		剪切失效	弯剪失效	弯曲失效	
实际结果	剪切失效	2	3	0	5
	弯剪失效	1	6	1	8
	弯曲失效	0	0	40	40
总计		3	9	41	53

2.4.2 参数敏感性分析

基于得到的人工神经网络分类机，我们可以对钢筋混凝土柱失效模式随着 4 个关键无量纲参数的变化而产生的演化进行分析。

I. 纵筋配筋指标和箍筋配筋指标

固定剪跨比和轴压比，依次变化纵筋配筋指标和箍筋配筋指标，得到的失效模式分布，如图 2.16 所示。可见，当剪跨比和轴压比固定时，钢筋混凝土柱的失效模式在纵筋配筋指标和箍筋配筋指标空间近似为线性可分。在高纵筋配筋指标、低箍筋配筋指标下，倾向于发生剪切失效。在低纵筋配筋指标、高箍筋配筋指标下，倾向于发生弯曲失效，而且剪切失效和弯曲失效之间的转换非常迅速，弯剪失效过渡区很窄，且剪切和弯曲失效之间的决策边界可以很好地被近似为一条直线。在低轴压比下，随着剪跨比从 2.5（图 2.16(a)）变成 3.5（图 2.16(b)），决策边界发生平移，但斜率的变化很小。也就是说，对于低轴压比的钢筋混凝土柱，弯曲失效和剪切失效的决策边界可以近似表示为

$$\alpha_l - k\alpha_v - b(\alpha_r) = 0 \tag{2.22}$$

其中 k 为一个正常数，表示决策边界的斜率， $b(\alpha_r)$ 为截距，是剪跨比 α_r 的函数。给定两个配筋指标和剪跨比，当等式左侧大于 0 时，发生剪切失效，当等式右侧小于 0 时，发生弯曲失效。




图 2.16 两个配筋指标对失效模式的影响

II. 剪跨比和轴压比

类似的，将纵筋配筋指标和箍筋配筋指标固定为数据库的平均值，分别为 $\alpha_1 = 0.26, \alpha_v = 0.08$ （见图 2.5），研究轴压比和剪跨比的变化对钢筋混凝土柱失效模式的影响。由于决策边界较为复杂，在三维图像上可以更清楚地表示出来，故以失效模式为纵轴，从下往上分别为剪切失效、弯剪失效和弯曲失效，所得结果，如图 2.17 所示。其中，剪跨比从 1.00 变化到 6.55，轴压比从 0.1 变化到 0.9。可见，在低轴压比时，随着剪跨比的增加，失效模式从剪切失效向弯曲失效转变，且中间需要经过一个较窄的弯剪失效过度平台，表明随着剪跨比的变化，失效模式的转变非常迅速。但是在较高的轴压比下，随着剪跨比的增加，失效模式从弯剪破坏开始，首先转变为弯曲破坏，然后转变回弯剪破坏，最后又转变为弯曲破坏。这样的现象与 Kani 提出的剪切谷^{[63][64]}十分类似。Kani 的分析结果表明，对于无腹筋梁，当剪跨比从 1.0 增加到 2.5 时剪切承载力和弯曲承载力的相对比值会大幅度减小，导致失效模式往剪切失效型转变。这主要是由于拱效应机制的出现。而在高轴压比下，钢筋混凝土柱同样会出现类似的拱效应，剪力会直接通过受压混凝土短柱传递到支座上。




图 2.17 剪跨比和轴压比对失效模式的影响

2.5 本章小结

本章首先介绍了钢筋混凝土柱失效模式分类的理论背景和现存的若干分类方式，然后结合此理论背景，通过分析剪切和弯曲承载力预测公式，提取了 4 个关键输入参数，接着说明并处理了原始数据库中存在的偏斜数据问题。介绍了神经网络分类机的基本理论，并针对处理过后的数据库，构建了一个单隐藏层神经网络分类机，并在交叉熵损失函数中加入了规则化项来控制分类机的过拟合问题，利用交叉验证集确定了最优的规则化参数取值，得到了最终的人工神经网络分类机。利用测试集数据评估了分类机的预测能力。研究表明：神经网络分类机对剪切失效和弯曲失效两种模式的分类效果都非常好， F_1 指标分别为 91%和 89%，但对弯剪失效分类具有较差预测精度，其原因与目前缺乏对钢筋混凝土柱失效模式的统一、明确、科学、客观的定义有关。最后的参数敏感性分析表明，在低轴压比下，剪切失效和弯曲失效在两个配筋指标空间的决策边界可以很好地被近似成直线，剪跨比的变化会引起决策边界的平移，而几乎不改变其斜率，低纵筋配筋指标和高箍筋配筋指标的构件会倾向于发生弯曲失效；但在高轴压比下，随着剪跨比的增加，失效模式会经历从弯曲失效转变为弯剪失效再转变为剪切失效的过程，这与 Kani 提出的剪切谷现象类似，并且可以用高轴压比下钢筋混凝土柱中产生的拱效应机制来解释。

第 3 章 失效模式分类中的偏斜数据问题

在第 2 章 2.2 节介绍原始数据库失效模式的分布情况时，发现原始数据库存在严重的偏斜数据问题。在原始数据库的 251 条数据中，剪切失效型数据有 18 条，弯剪失效型数据有 36 条，弯曲失效型数据有 197 条，失效模式的分布情况，如图 2.2 所示。其中，剪切失效、弯剪失效和弯曲失效数据量的比例约为 1:2:11，弯曲失效型数据量是剪切失效型数据量的 10 倍多，是弯剪失效型数据量的 5 倍多。在数据科学中，像这种某类型数据的数据量占总数据量比例很小的问题一般被称为相对稀少，而剪切失效和弯剪型数据的数据量本身就很小，只有 18 条和 36 条，这种一般被称为绝对稀少^[42]。

2.4.1 节分析了利用原始数据库训练得到的分类机在测试集上的混淆矩阵以及利用处理过后的数据库训练得到的分类机在测试集上的混淆矩阵，并计算了两个分类机在每种失效模式上的召回率、准确率和 F_1 指标。分析结果表明，由于原始数据库的失效模式分类分布朝着弯曲失效偏斜，导致训练得到的分类机预测能力也向着弯曲失效发生偏斜，而对剪切失效的召回率和准确率都较小。在 2.2.2 分节，采用了最简单的随机欠采样方法来处理原始数据，改善了偏斜数据问题，但考虑到丢弃的数据量数量较大（随机丢掉了 197 条数据中的 100 条），有可能会丢弃掉数据中有用的信息，因此本章围绕失效模式中的偏斜数据问题，首先介绍了偏斜数据问题如何影响失效模式识别预测，然后讨论了处理偏斜数据问题的常用方法，包括 SMOTE 过采样方法、除噪声算法、高等欠采样方法以及增强类算法，最后讨论了综合利用高等采样方法和增强类算法后得到的预测模型分类效果。

3.1 偏斜数据的影响和常用处理方法

偏斜数据 (skewed data)，或者也被称作不平衡数据 (imbalanced data)，是指数据库中不同类的数据分布不均匀，或者某一种类型数据的数据量远超过另一种数据的数据量。其中，数据量较大的类型被称为多数类 (majority class)，数据量较小的类型被称为少数类 (minority classes)，例如在失效模式识别的原始数据库中，弯曲失效是多数类，而剪切失效和弯剪失效为少数类。少数类数据虽然在数据总量中占少数，但在实际应用中非常重要。事实上，在罕见疾病识别、信用卡盗刷识别、通讯系统异常等实际问题的数据都具有偏斜数据的特征^[42]。失效模式的识别也具有类似的特征。由于剪切失效模式的钢筋混凝土柱具有高危险性，工程师希望可以在抗震性能评估将可能发生剪切失效的构件都识别出来，并进行有效的加固工作。因此，若采用如总体精度或者错误率这样的单个评价指标来训练并调节训练机时，由于少数类误判对总体损失函数的贡献很小，得到的分类机对于少数类的识别预测能力很差，不能满足工程师

的要求。在 2.4.1 节分析原始数据库得到的分类机在测试集上的混淆矩阵时，发现此分类机对剪切失效预测的 F_1 指标只有 50%。

3.1.1 偏斜数据的不利影响

在机器学习中，大部分标准的机器学习模型都假定训练的数据集中，不同类型的数据都有相近的数据量，因此它们的错误分类对损失函数的贡献是相近的^[65]。而如果在训练集数据中，不同类型的数据量极其不平衡时，会导致分类机不能正确地考虑数据集数据类型的分布情况，最后导致预测效果不佳的预测模型，但并不是所有的偏斜数据都会对分类机造成严重的不利影响，例如对于 Sick 数据集^[66]，虽然训练集中不同类型数据的数据量高度不均衡，但利用标准的机器学习模型训练得到的分类机，对稀少的数据量也有较好的预测效果。

I. 分类不平衡和分类重叠

这里需要区分和关联数据的分类不平衡和数据的分类重叠现象。2004 年，Prati 等人^[67]在对一系列人工生成的数据集进行分析后，发现偏斜数据并不是造成分类机预测效果不佳的唯一因素，不同分类数据之间的重叠也是一个重要原因。对于没有发生不同分类之间重叠的数据集，即使不同分类的数据量高度不平衡，也不会对最终分类机的预测效果造成影响，因为实际的决策边界可以达到训练集精度的 100%，见图 3.1 (a)，而若不同分类的数据量均衡，但分类之间具有一定重叠的数据集，同样不会对最终分类机的预测效果造成影响，因为这种是大部分标准的机器学习模型都假定的情况，见图 3.1(b)；但对于不同类型的数据量不平衡，且不同类型的数据之间具有重叠的数据集，则会对最终的分类机预测效果造成严重的不利影响，训练得到的决策边界会往左下角移动。因为，这样的决策边界比实际决策边界具有更高的训练集总体精度，最终得到的损失函数值也更小（见图 3.1(c)）。由此可见，只有偏斜数据和分类重叠这两个问题结合在一起，才会对最终训练得到的分类机预测效果造成不利影响。




图 3.1 分类不平衡和分类重叠

三张图中虚线均表示实际的决策边界，黑色加号表示少数类数据点，黑色圆点表示多数类数据点
(a)分类不平衡但没有分类重叠。(b)分类平衡但有分类重叠。(c)分类不平衡且有分类重叠

这也进一步解释了在第 2 章对钢筋混凝土柱的失效模式建立机器学习模型过程中遇到的问题。首先，原始数据库存在数据偏斜问题，弯曲失效为多数类，剪切失效和弯剪失效都是少数类。同时，在 2.4.1 节中提到过，由于 PEER 数据库对失效模式的标定依赖于原始文献中试验者是否报告发生剪切破坏，但试验者的判断并没有遵循统一的分类标准，存在较大的离散性和随机性，必然会导致不同类型的数据之间存在重叠。偏斜数据和失效模式标定的离散性结合在一起，导致了利用原始数据库训练得到的分类机预测效果不佳。因此，只有偏斜数据和分类重叠这两个问题结合在一起，才会对最终训练得到的分类机预测效果造成不利影响。同时，只要能够解决这两个问题中的任意一个，就可以消除这种不利影响。在第 2 章，我们通过随机欠采样的方法，在一定程度上缓解了数据分类的不平衡问题，得到了一个预测效果较好的分类机。但是从测试集混淆矩阵的结果来看，不同失效类型之间的数据是具有一定的分类重叠问题的。可以预计，如果进一步对数据的分类重叠问题进行处理，则可以进一步提高分类机的预测效果。

II. 数值算例

为了对上述论证进行验证，以一个简单的数值算例研究在分类不平衡和分类重叠分别发生变化时，对训练得到的分类机决策边界的影响。首先，利用 sklearn 库^[68]中的函数 `make_classification` 来生成人工的分类数据集。该函数采用 Guyon^[69]在 2003 年提出的方法来生成人工的分类数据集，通过预先给定分类数目 n 和数据特征矢量的维度 d ，该算法可以在特征矢量空间确定 n 个点作为每一类数据的质量中心，并在这些中心周围生成 d 维高斯分布的数据点。然后，通过控制类与类之间中心的距离以及高斯分布的协方差矩阵，就可以控制分类之间的重叠，在保持每一类数据协方差矩阵不变的情况下，类与类之间的中心距离越大，分类之间的重叠就越小。

为了便于数据可视化，选择数据的特征矢量维度为 2；分类数目确定为 3 类，与失效模式识别问题的分类数目一致；分别对分类中心距离较大和较小的两种情况进行分析。在每一种情况下，改变分类的不平衡程度并观察分类机决策边界的变化情况。分类机选为较简单的支持向量机，这是由于对于线性可分的问题，在线性支持向量机的优化目标函数中，只有靠近边界的若干数据点对算法有贡献，这些靠近决策边界的点被称作支持向量。也就是说，只要数据线性可以分，由于线性支持向量机只对决策边界附近的若干点敏感，分类不平衡问题不会对最终得到的预测模型有太大的不利影响。所得结果，如图 3.2 所示。可见，(a)图中三种类型数据的中心间距大，分类重叠小，(b)图中三种类型数据的中心间距小，分类重叠大。在每种分类重叠情况下，三类数据的总数据量均为 1000，但三类数据的比例发生如下变化：1:1:1→1:2:7→1:5:94→1:3:196。从(a)图中可以发现，当分类重叠小时，即使不同分类的数据量变得极其不平衡，决策边界的变化也会很小，主要是由于每一类数据的数据量在变化时，处在决策边界附近

的点仅略有不同。但另一方面，从(b)图中可以发现，当分类重叠较大时，数据集不再线性可分，不同类型的数据量分布越不均衡，最后得到的分类机预测效果越偏向于多数类。

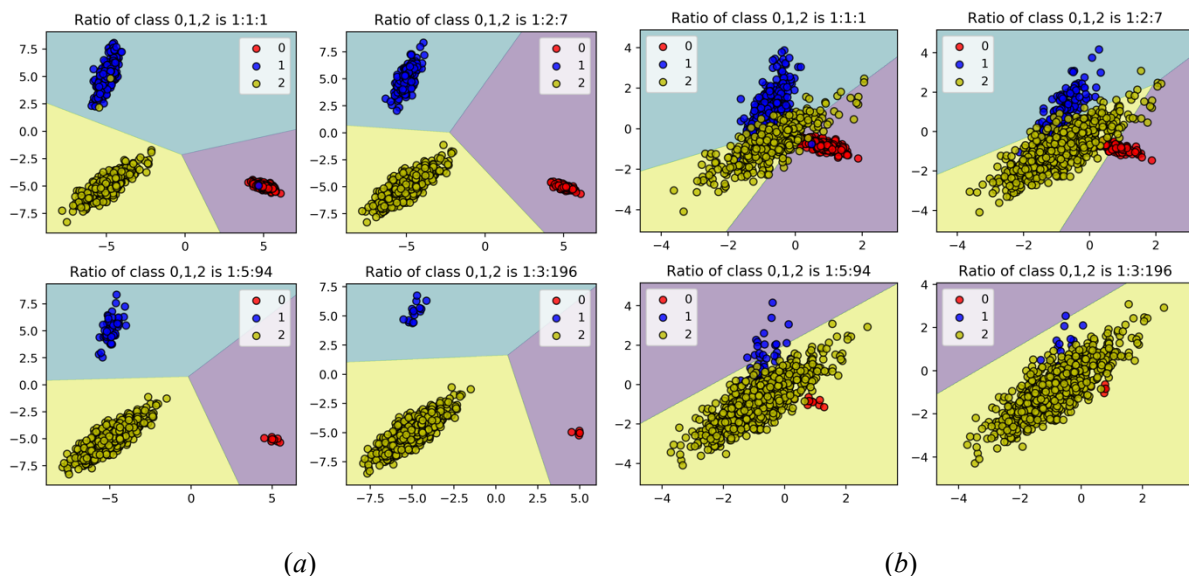


图 3.2 分类不平衡和分类重叠数值试验

(a)三类中心间距大，分类重叠小；(b)三类中心间距小，分类重叠大

3.1.2 常用处理方法

处理偏斜数据问题的方法，一般可分为数据集层面的方法和算法层面的方法两种^[70]。数据层面的方法是对原始数据库进行处理，以减轻数据分类的不平衡或者数据分类的重叠问题，从而改善最终机器学习模型的预测效果。算法层面的方法则是通过改变或者使用新的机器学习模型，使得算法可以考虑数据集数据类型的分布情况，而不是像标准的机器学习模型一样直接假定各个类型均匀分布。

I. 数据集层面：改善数据分类的不平衡

数据层面的方法又分为改善数据分类的不平衡方法和减少数据分类重叠的方法（或者减轻数据分类噪声）两类。首先，介绍减轻数据分类不平衡的方法。在 2.2.2 节，我们采用了随机欠采样方法来处理原始数据以改善分类不平衡问题，随机丢弃了 100 条弯曲失效数据；但考虑到在决策边界附近的数据点与远离决策边界的数据点相比更加重要：一旦决策边界附近的数据点发生变化，会引起决策边界发生变化，远离决策边界数据点的变动对决策边界的扰动则一般很小；在随机欠采样中，有一定的几率会将决策边界的数据点丢弃掉，造成有效信息的损失。因此，可采用凝聚最近邻居法（condensed nearest neighbor，或者简称为 CNN）^[71]考虑这两种数据点的不同。CNN 属于一种启发式的欠采样方法^[72]，利用 k 最近邻居算法（ k -nearest neighbor 或者简称为 k -NN），从多数类中只挑选出与少数类数据距离较近的数据点，而忽略距离较远的点，

这等价于只保留处在决策边界的边界点，而丢弃远离决策边界的冗余数据点（见图 3.3）。




图 3.3 丢弃远离决策边界的冗余数据点

另一种减轻数据分类不平衡的方法是过采样方法。与欠采样方法相反，过采样方法增加少数类数据的数据量。最简单的过采样方法是随机过采样，即随机重复少数类数据的数据点，这种方法可以改进数据分类不平衡的问题，但是仅通过重复少数类的数据点，实际上没有引入新的信息，而且容易造成过拟合问题^[42]。为了解决这一问题，SMOTE (Synthetic Minority Oversampling Technique)^[73]算法可以根据现有的少数类数据，生成新的人工合成数据。与随机过采样方法相比，SMOTE 算法可以在解决数据分类不平衡的同时，有效地减轻过采样引起的过拟合问题。但是另一方面，对于本身具有分类重合的数据集来说，SMOTE 算法随机生成的人工合成数据容易加重分类重叠的问题，这给机器学习算法带来新的不利影响。

II. 数据集层面：减少数据的分类重叠

为了解决数据集本身的分类重合（或者是过采样引起的分类重合）问题，需要对分类重合的数据点加以处理，避免数据集噪声对训练得到的分类机预测效果造成不利影响。其中，最经典的方法利用 Tomek 连接的概念^[74]，识别并处理成对的分类重合数据。Kubat 和 Matwin 在 1997 年将 Tomek 连接和 CNN 结合起来运用，首先用 Tomek 连接除去分类重叠，然后用 CNN 丢弃多数类中的冗余数据，提出了单边选择（one-sided selection 或者简称为 OSS）^[72]方法。单边选择方法一方面可以处理数据的分类重叠问题，另一方面可以对多数类进行有针对性的欠采样，缓解了数据的分类不平衡问题，因此可以较好地处理偏斜数据对分类机造成的不利影响。另一种除噪声的方法叫做 Wilson 编辑最近邻居法（Wilson's Edited Nearest Neighbor Rule 或者简称为 ENN）^[75]，这种方法的基本思想是：对于一个数据点，首先找出它的 3 个最近邻居点，如果 3 个点中有 2 个点的分类都和这个点不同，就认为这个点是应该被丢弃的噪声点。Laurikkala 在 2001 年^[76]利用 ENN 方法对多数类数据进行了欠采样，提出了邻居点清理规则（Neighborhood Cleaning Rule 或者简称为 NCL），对于一个数据点，同样首先需

要找出它的 3 个最近邻居点，如果 3 个点中有 2 个点的分类都和这个点不同，而且这个点属于多数类，则删除这个点；如果这个点中有 2 个点的分类都和这个点不同，但这个点属于少数类，则删除 3 个邻居点中的多数类点。

III. 算法层面

算法层面的方法主要通过改变机器学习算法来考虑数据集分类的不平衡问题。针对不同的机器算法，算法层面的方法具有不同的形式，一般来说，没有一种算法层面的方法是可以适用于所有的机器学习算法的。这是因为使得机器学习算法无法正确处理偏斜数据集的算法内在因素很多，不同的算法，其最重要的影响因素各不相同^[70]。大体上来说，算法层面的方法分为 3 类：1) 损失敏感方法；2) 基于支持向量机的一类算法和 3) 利用对偏斜数据不敏感的算法。损失敏感方法的思想很简单，由于少数类数据量不占优势，对算法损失函数的贡献很小，因此考虑对少数类数据和多数类数据赋予不同的损失权重，使得对一条少数类数据的分类错误造成的损失大于对一条多数类数据分类错误的损失，以弥补少数类数据的不足。在人工神经网络分类机中，这种方法可以通过加入损失矩阵来考虑少数类和多数类两种数据错误分类的损失权重，得到损失敏感的人工神经网络分类机^[77]。第二类方法是基于支持向量机的一类算法，在 3.1.1 节我们利用数值算例在研究分类不平衡和分类重叠问题的过程中发现，当分类重叠很小时，即使分类极其不平衡，支持向量机也可以得到很好的决策边界，这是因为支持向量机只对处在决策边界的数据点（支持向量）敏感。但是当分类出现较大的重叠现象时，支持向量机的训练目标从硬间隔最大化（hard-margin maximization）变为软间隔最大化（soft-margin maximization），由于多数类的数据点落在分类软间隔之间的数据量比少数类的数据要多很多，在损失函数中贡献较大，造成了支持向量机预测向多数类偏斜。为了解决这一问题，一方面可以对落在软间隔之间的多数类和少数类数据赋予不同的损失（这是属于敏感类方法），还可以对支持向量机的核函数进行改进，使之可以适应偏斜且有重叠的数据集，这种方法被称作核函数改进法（kernel modification method）^[70]。除此以外，支持向量机的核函数还可以与模糊数学概念结合，或者与主动学习方法相结合来解决偏斜数据问题。最后一类方法则是直接选择对偏斜数据不敏感的算法，譬如 k 最近邻居算法和朴素贝叶斯等^[78]。实际上，在处理数据集分类重叠的多数算法中，都用到了如 k 最近邻居算法这种对偏斜数据不敏感的思想来初步确定决策边界的大体位置。在这里，考虑算法层面的方法大都针对某一种特定的机器学习算法，适应性不是很强，虽然在某些特定的领域^{[79][80]}对偏斜数据的处理具有很好的效果，但是与数据集层面的方法相比，算法层面方法的开发时间成本过高，且有效性不一定能够得到保证^{[81][82]}，因此，我们只在处理数据集中分类重叠时，运用了若干对偏斜数据不敏感的算法，而没有对损失敏感方法和基于支持向量机一类的算法进行进一步的研究。

3.2 原始数据库处理

本研究的原始数据库在第 2.2.1 节已有详细介绍，一共包含了 251 条矩形截面钢筋混凝土柱，其中剪切失效、弯剪失效和弯曲失效的分别为 18 条、36 条和 197 条，剪切失效和弯剪失效数据存在绝对稀少的问题，因此首先利用过采样方法增加这两类数据的数据量。同时，考虑原始数据库的数据本身就存在分离重叠问题，在过采样之后，分类重叠现象会被加剧，因此在处理数据集的过程中，结合分类重叠的算法一起进行采样。

3.2.1 SMOTE 类算法

为了解决剪切失效和弯剪失效数据的绝对稀少问题，过采样方法必不可少。单纯重复现有少数类数据的随机过采样方法因实际上没有引入任何新的数据点，过于粗糙，而且过多重复的数据点容易造成机器学习模型的过拟合，造成最后得到的预测模型泛化能力弱，因此采用 SMOTE 算法进行过采样。SMOTE (Synthetic Minority Oversampling Technique)^[73]算法通过生成新的人工合成数据来增加少数类数据量，在一定程度上可以减轻随机过采样方法带来的过拟合问题。

SMOTE 生成新人工合成数据点的方法如图 3.4(a)所示。以最左下角和最右上角少数类数据为例，SMOTE 算法首先找出这个数据点附近 k 个最近的少数类邻居点（图中 $k = 3$ ），记这个数据点的特征矢量为 \mathbf{x}_i ，然后从这 k 个点中任意选取一个点，它的特征矢量为 $\hat{\mathbf{x}}_i$ ，新的数据位于这个数据点和这个邻居点连线上的任意位置

$$\mathbf{x}_{\text{new}} = \mathbf{x}_i + (\hat{\mathbf{x}}_i - \mathbf{x}_i) \times \delta \quad (3.1)$$

其中 \mathbf{x}_{new} 是新人工合成数据点的特征矢量， $\delta \in [0,1]$ 是一个随机数，其实这是在两个数据点之间的插值。需要指出的是，SMOTE 算法可以减轻数据集分类的不平衡，从而改善训练得到的机器学习模型的预测能力，但是 SMOTE 算法对所有的少数类点采用相同的处理方法，可能会引起过度泛化问题，加剧数据集的分类重叠现象。在图 3.4(a) 中，有 4 个少数类数据位于决策边界右侧，属于噪声点。利用 SMOTE 算法进行过采样后，在这 4 个少数类数据附近也会生成很多新的人工合成点（如图中最右上角数据点附近生成的合成数据点），这些新的合成点会大大加剧数据的分类重叠问题，不利于机器学习算法的训练。因此，必须有选择性地生成人工合成的数据点，这就需要在算法中考虑某个点邻近的所有数据点，而不只是少数类邻居点，并据此判断这个点的相关特点。

Han 和 Wang 在 2005 年提出了一个改进的算法 Borderline-SMOTE^[83]，在这个算法中，将少数类数据分为“危险点”、“安全点”和“噪声点”三类，然后只在危险点附近生成新的人工数据。分类的规则是：首先确定某一少数类数据点 \mathbf{x}_i 附近 m 个最近的邻居点（不仅包括少数类数据，还包含多数类数据），记这 m 个点组成的集合为

$S_{i,m-NN}$, 记所有多数类数据点组成的集合为 S_{maj} , 在这 m 个最近邻居点中, 多数类的数据数目为 $|S_{i,m-NN} \cap S_{maj}|$ 。危险点、安全点和噪声点分别定义为

$$\begin{aligned} & \text{如果 } \frac{m}{2} \leq |S_{i,m-NN} \cap S_{maj}| < m, \text{ 则 } x_i \text{ 为危险点} \\ & \text{如果 } |S_{i,m-NN} \cap S_{maj}| < \frac{m}{2}, \text{ 则 } x_i \text{ 为安全点} \\ & \text{如果 } |S_{i,m-NN} \cap S_{maj}| = m, \text{ 则 } x_i \text{ 为噪声点} \end{aligned} \quad (3.2)$$

并且只在当这个点是危险点时, 才利用 SMOTE 算法在此点附近生成人工合成数据点。如图 3.4(b)所示, 图中 $m = 5$, A 点附近有 3 个多数类数据点, 2 个少数类数据点。因此, A 点是危险点, 需要利用 SMOTE 算法生成人工合成数据点; B 点附近只有 2 个多数类数据点, 因此 B 点是安全点, 不需要在附近生成新数据; 而 C 点附近 5 个数据点全都是多数点, 因此 C 是噪声点, 不需要在附近生成新数据。可以发现, 危险点一般在决策边界附近, 安全点离决策边界较远, 而噪声点可以被认为是被错误标定分类的点。Borderline-SMOTE 算法一方面避免了在噪声点附近生成新的数据点, 控制了由过采样引起的分类重叠问题, 另一方面只在决策边界的危险点附近生成新的数据点, 这是考虑到离决策边界较远的安全点在机器学习模型的训练中一般是冗余数据, 因此在安全点附近生成新数据点的性价比不高。事实上, 只在离决策边界较近的点附近进行过采样才具有更好的效果^[84]。Borderline-SMOTE 算法与原始的 SMOTE 算法相比, 采样生成的新数据更有针对性, 得到的分类机预测效果更好, 但是在危险点附近生成的新数据, 还是有一定几率增加数据之间的分类重叠, 譬如图 3.4(b)中, 如果在 A 点的右侧生成新数据, 则新数据很有可能落在决策边界的右侧。




图 3.4 SMOTE 类算法生成新数据点

黑色加号表示少数类数据点, 黑色圆点表示多数类数据点。(a)原始 SMOTE 算法, (b)Borderline-SMOTE 算法

为了进一步减轻数据之间分类的重叠问题, Nguyen 等人在 2009 年提出了 SVM-SMOTE 算法^[85]。SVM-SMOTE 方法与 Borderline-SMOTE 方法相同的地方在于, 它只

在离决策边界较近的少数类附近生成新的合成数据。不同的是，SVM-SMOTE 算法综合利用插值和外推方法（如图 3.5 所示）。另一方面，考虑支持向量机受分类不平衡问题的影响较小，SVM-SMOTE 算法首先利用标准的支持向量机来初步确定决策边界的区域，得到的支持向量就是位于决策边界附近的数据点，对于每一个属于少数类的支持向量 sv_i ，按照如下规则生成新的数据：首先，确定少数类支持向量 sv_i 附近 m 个最近邻居点（不仅包括少数类数据，还包含多数类数据）和 k 个最近少数类邻居点。如果这 m 个最近邻居点中的多数类数据点小于 $m/2$ ，说明此支持向量相对来说距决策边界较远，故使用外推法生成新的数据，即先从 k 个最近少数类邻居点中任意选取一个点，它的特征矢量为 \hat{x}_i

$$\mathbf{x}_{\text{new}} = \mathbf{sv}_i + (\mathbf{sv}_i - \hat{\mathbf{x}}_i) \times \delta \quad (3.3)$$

其中 \mathbf{x}_{new} 是新人工合成数据点的特征矢量， $\delta \in [0,1]$ 是一个随机数，这其实表示向两个数据点外侧进行外推，如图 3.5(b) 所示；如果这 m 个最近邻居点中的多数类数据点不小于 $m/2$ ，说明此支持向量距决策边界较近，故使用与 SMOTE 类似的插值法（式 3.1）生成新的数据，即先从 k 个最近的少数类邻居点中任意选取一个点，它的特征矢量为 $\hat{\mathbf{x}}_i$ ，如图 3.5(a) 所示。

$$\mathbf{x}_{\text{new}} = \mathbf{sv}_i + (\hat{\mathbf{x}}_i - \mathbf{sv}_i) \times \delta \quad (3.4)$$

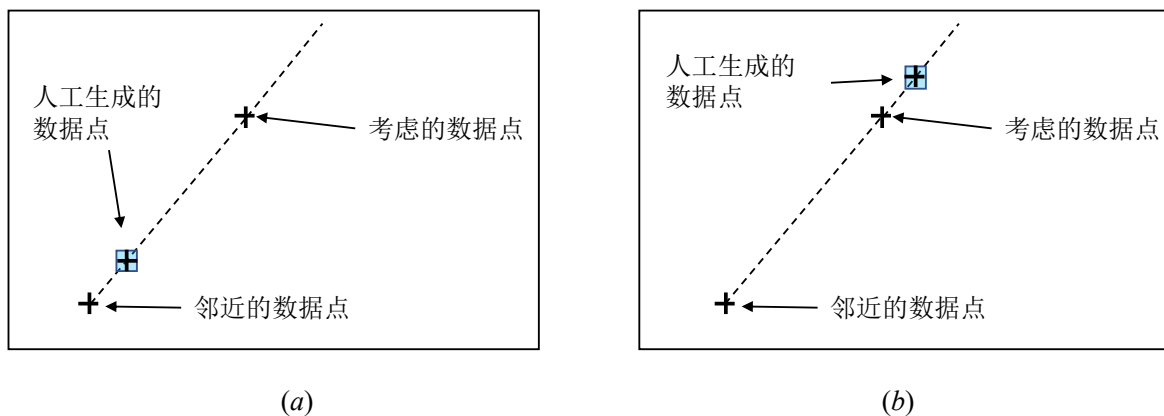


图 3.5 插值和外推 利用(a)插值法和(b)外推法生成新数据点

将外推法和插值法结合生成新的数据点具有更好的效果，这是因为少数类数据的总体数据量较小，因此少数类数据落在决策边界的个数与多数类相比会少很多，导致决策边界会偏向少数类。如图 3.6 (a) 所示，仅仅使用插值法进行过采样，并不能很好地解决这个问题。但是，如果对离决策边界较近的支持向量利用外推法向外生成新的数据，有利于少数类数据向多数类数据的扩张，有助于推动预测模型的决策边界向多数类移动，如图 3.6 (b)。

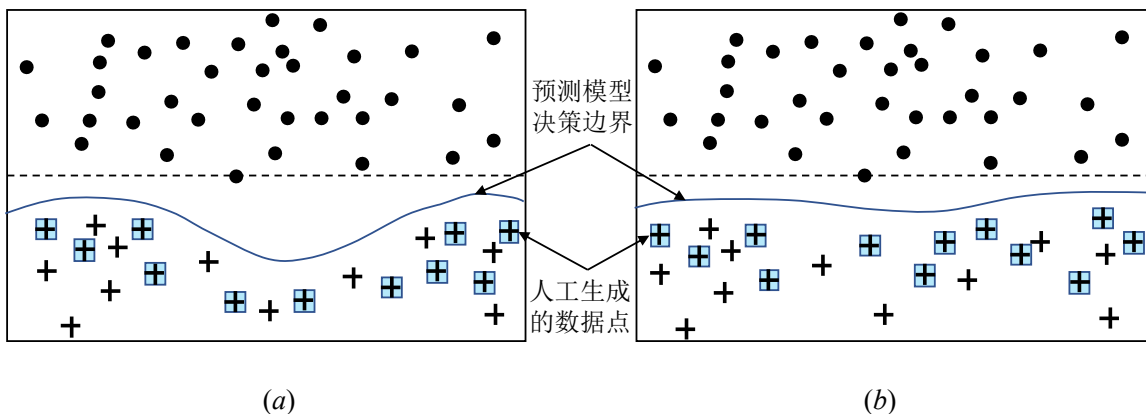


图 3.6 插值和外推结合的优势 利用(a)插值法和(b)外推法和插值法结合

3.2.2 除噪声和高等欠采样方法

减少数据的分类重叠，不仅对最终训练得到的机器学习模型预测效果有益，还有助于提高过采样算法的有效性，例如 SVM-SMOTE 算法首先利用标准的支持向量机来初步确定决策边界的区域，而在 3.1.1 节，以一个数值算例为例，在研究分类不平衡和分类重叠问题时发现，仅当数据集分类重叠较小的情况下，支持向量机对分类不平衡的数据库才有很好的预测结果。因此，在利用 SVM-SMOTE 进行过采样之前，有必要对数据集的分类重叠问题进行处理，这需要用到除噪声的算法。

常用的除噪声算法是 Tomek 连接，Tomek 连接^[74]的概念可以用来识别具有分类重叠的噪声点。Tomek 连接的定义为：对于一对具有不同分类标签的两个数据点 x, y ，记这两个点之间的距离为 $D(x, y)$ ，如果对任意的其他数据点 z ，都有 $D(x, z) \geq D(x, y)$ 并且 $D(y, z) \geq D(x, y)$ ，那么这一对点 (x, y) 就是一个 Tomek 连接（如图 3.7 所示）。Tomek 连接一般是处在决策边界的数据点或者是噪声点。




图 3.7 Tomek 连接

另一种常用的除噪声算法叫做 Wilson 编辑最近邻居法（Wilson’s Edited Nearest Neighbor Rule 或者简称为 ENN）^[75]，ENN 法的基本思想是：对于一个数据点，首先找

出它的 3 个最近邻居点，如果 3 个点中有 2 个点的分类都和这个点不同，就认为这个点是应该被丢弃的噪声点。一般来说，用 ENN 方法清理的数据点数量比用 Tomek 连接清理的数据点数量要多一些，因此 ENN 方法对噪声点的清理更加彻底。

此外，高等欠采样方法一般要与除噪声算法联合使用。凝聚最近邻居法（condensed nearest neighbor，或者简称为 CNN）^[71]是一种常用的高等欠采样方法，CNN 先要初步确定决策边界的大致范围，然后将远离决策边界的多数类冗余数据丢弃，从而减小计算量，解决数据的分类不平衡问题。如果对分类重叠严重的数据集直接进行 CNN 欠采样，容易丢弃过多的有用数据。单边选择（one-sided selection 或者简称为 OSS）^[72]方法首先采用 Tomek 连接对噪点进行处理，然后再用 CNN 欠采样方法处理数据分类的不平衡，利用处理过后的数据集训练机器学习模型。因此，单边选择是一种效果很好的高等欠采样方法，适合对存在分类重叠问题的数据集应用。

3.2.3 原始数据库前处理流程

应用上述方法，首先对原始数据库进行处理。原始数据库仍然是 2.2.1 节介绍的 PEER 数据库，但是另外又结合了 Seismic Engineering Research Infrastructures for European Synergies (SERIES)^[43]数据库中另外收集的 7 条剪切失效型数据（与 2.2.2 节中加入的剪切失效数据相同）。因此，本节使用的原始数据库一共包含 258 条钢筋混凝土矩形截面柱的数据库。在原始数据库中，剪切失效型数据有 25 条，弯剪失效型数据有 36 条，弯曲失效型数据有 197 条，三种类型的数据量比例约为 1 : 1.5 : 8。另外，为了对原始数据库中不同失效模式的数据在其特征矢量空间中的分布有一个直观的了解，对不同分类的数据点在特征矢量空间进行可视化。通过 2.1 节的分析可知，失效模式识别分类问题的数据特征矢量 \mathbf{x} 是一个 4 维矢量 $\mathbf{x} = [\alpha_r, \alpha_n, \alpha_l, \alpha_v]^T$ ，这 4 个分量分别为剪跨比 α_r ，轴压比 α_n ，纵筋配筋指标 α_l 和箍筋配筋指标 α_v 。由于 4 维的特征矢量空间无法进行可视化，因此需要先将 4 维特征矢量空间降为 2 维。利用主成分分析（principle component analysis 或者简称为 PCA）的方法来进行特征矢量空间的降维。

3.2.3.1 主成分分析方法

主成分分析方法首先通过将原始线性空间的各分量进行正交变化（即在线性空间进行旋转变换），将原始观测量变化为线性无关的分量，称为主成分。然后，将所有的主成分方向观测数据的方差从大到小排列，方差最大的分量称作第一主成分，方差第二大的分量称作第二主成分，以此类推。主成分分析方法如图 3.8 所示。以二维联合高斯分布的数据为例，在原始线性空间中，两个分量显然是呈正向线性相关的，但通过正交变化，旋转坐标轴，可以得到两个线性无关的分量，这两个分量在原始线性空间中的方向如图 3.8 中的黑色箭头所示。指向右上角方向的观测量方差较大，因此是第一主成分，而指向左上方的观测量方差较小，因此是第二主成分。对于 N 维线性空间

来说，同样可以找到 N 个主分量，在需要降维的问题中，一般从中提取前几个主分量，而忽略方差较小的主分量。




图 3.8 主成分分析

记第一主成分的方向为 \mathbf{w}_1 ，那么一个数据点 \mathbf{x} 在这个方向的投影值为 $z_1 = \mathbf{w}_1^T \mathbf{x}$ ，将数据点 \mathbf{x} 处理为随机向量，记它的协方差矩阵为 $\Sigma = \text{Cov}(\mathbf{x})$ ，根据概率论的知识，随机变量 $z_1 = \mathbf{w}_1^T \mathbf{x}$ 的方差等于 $\text{Var}(z_1) = \mathbf{w}_1^T \Sigma \mathbf{w}_1$ 。在第一主成分的方向，随机变量 z_1 的方差最大，因此同时需要满足约束 \mathbf{w}_1 是一个单位向量（即 $\mathbf{w}_1^T \mathbf{w}_1 = 1$ ）。利用拉格朗日乘子法求解此极值问题，构造拉格朗日量

$$L = \mathbf{w}_1^T \Sigma \mathbf{w}_1 - \lambda_1 (\mathbf{w}_1^T \mathbf{w}_1 - 1) \quad (3.5)$$

其中 λ_1 为拉格朗日乘子。对 \mathbf{w}_1 求导，并令导数等于 0 得到

$$0 = 2\Sigma \mathbf{w}_1 - 2\lambda_1 \mathbf{w}_1 \quad (3.6)$$

此式可以变形为

$$(\Sigma - \lambda_1) \mathbf{w}_1 = 0 \quad (3.7)$$

显然，这是协方差矩阵 Σ 的一个特征值问题， λ_1 是它的一个特征值， \mathbf{w}_1 是对应的特征向量，此时随机变量 z_1 的方差 $\text{Var}(z_1) = \mathbf{w}_1^T \Sigma \mathbf{w}_1 = \mathbf{w}_1^T \lambda_1 \mathbf{w}_1 = \lambda_1$ ，由于 \mathbf{w}_1 是第一主成分对应的方向，根据定义， λ_1 应该取 Σ 特征值中的最大值。接下来求第二主成分对应的方向 \mathbf{w}_2 ，分析过程与 \mathbf{w}_1 类似，但多了一个约束条件： \mathbf{w}_2 应该垂直于 \mathbf{w}_1 ，即 $\mathbf{w}_1^T \mathbf{w}_2 = \mathbf{w}_2^T \mathbf{w}_1 = 0$ 。因此，构造拉格朗日量

$$L = \mathbf{w}_2^T \Sigma \mathbf{w}_2 - \lambda_2 (\mathbf{w}_2^T \mathbf{w}_2 - 1) - \alpha \mathbf{w}_2^T \mathbf{w}_1 \quad (3.8)$$

其中 λ_2 和 α 均为拉格朗日乘子。对 \mathbf{w}_2 求导，并令导数等于 0 得到

$$0 = 2\Sigma \mathbf{w}_2 - 2\lambda_2 \mathbf{w}_2 - \alpha \mathbf{w}_1 \quad (3.9)$$

左乘 \mathbf{w}_1^T ，并注意到 \mathbf{w}_2 垂直于 \mathbf{w}_1 ，得到

$$\alpha = 2\mathbf{w}_1^T \Sigma \mathbf{w}_2 \quad (3.10)$$

由于 \mathbf{w}_1 是协方差矩阵 Σ 的一个特征向量，有 $\Sigma \mathbf{w}_1 = \lambda_1 \mathbf{w}_1$ ，两边取转置并注意到协方差矩阵 Σ 是一个对称矩阵，因此得到 $\mathbf{w}_1^T \Sigma = \lambda_1 \mathbf{w}_1^T$ ，代入上式可以得到

$$\alpha = 2\mathbf{w}_1^T \Sigma \mathbf{w}_2 = 2\lambda_1 \mathbf{w}_1^T \mathbf{w}_2 = 0 \quad (3.11)$$

将 $\alpha = 0$ 带入式(3.9)得到

$$(\Sigma - \lambda_2) \mathbf{w}_2 = 0 \quad (3.12)$$

这样就变成了协方差矩阵 Σ 的一个特征值问题， λ_2 是它的一个特征值， \mathbf{w}_2 是对应的特征向量。根据第二主成分的定义， λ_2 是第二大的特征值。以此类推，第 k 主成分的方向 \mathbf{w}_k 是协方差矩阵 Σ 第 k 大特征值 λ_k 对应的特征向量，且 λ_k 是数据在这个方向投影 \mathbf{z}_k 的方差。

对于给定的数据库，用 $m \times p$ 矩阵 \mathbf{X} 表示。数据库的一行代表一条数据，每个数据用一个 p 维特征向量 \mathbf{x}_i 表示，因此数据库中一共有 m 条数据。由于主成分分析法对变量的缩放非常敏感，因此需要对原始数据库进行中心标准化处理，即对特征向量的每一个分量，减去其均值，并除以其标准差，设中心标准化后的数据库为 \mathbf{X}_n ，它的协方差矩阵为 $\Sigma = \mathbf{X}_n^T \mathbf{X}_n$ 。然后求解 Σ 的特征值和特征向量，即可得到主成分的方向和对应方向投影的方差。

根据上述推导，对于失效模式识别数据进行可视化，首先对包含258条钢筋混凝土矩形截面柱的数据库进行主成分分析，得到的四个主成分方向的方差从大到小分别为1.92，0.041，0.011和0.0018。前2个主成分方差之和占4个主成分方差之和的99.3%，因此这个2维投影可以很好的表示数据在原始4维特征矢量空间的分布情况。本节后续所有的可视化都是在这两个主成分上进行投影得到的。

原始数据库中，不同失效模式数据的二维分布图，如图3.9所示。可以看到，剪切失效数据主要分布在左下角的一个较小区域，而弯曲失效数据分布在右上角一个较大的区域，剪切和弯曲失效数据之间的重叠较小。弯剪失效数据与剪切失效和弯曲失效数据均有较大的重叠。同种失效模式的数据，有些会成簇出现，如最左上角和下侧中央的若干剪切失效型数据。这一般代表由同一个试验者进行的同一批试验中的不同试件。




图 3.9 原始数据库各失效模式的分布情况 (PCA 保留前 2 个主成分)

3.2.3.2 原始数据库的前处理流程

原始数据库的前处理流程，如图 3.10 所示。用到的算法具体介绍在 3.2.1 节和 3.2.2 节。具体算法的实现利用 Python 中的 Imbalanced-learn 库^[86]。算法的参数设置如表 3.1 所示。

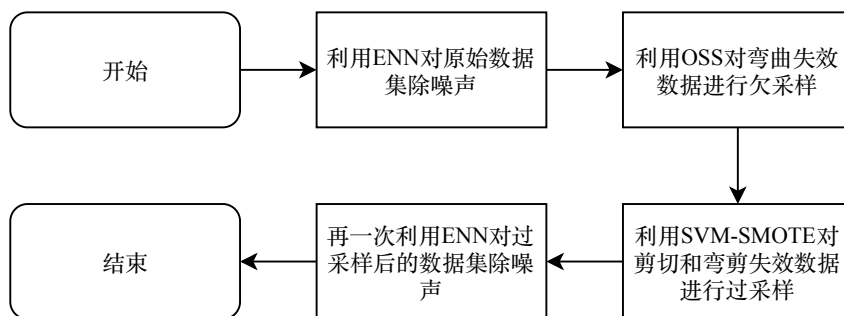


图 3.10 原始数据库的前处理流程

表 3.1 函数参数设置

算法名	算法参数设置 (未提及的均为默认值)
EditedNearestNeighbours (in first step)	sampling_strategy='not minority', n_neighbors=3, kind_sel='all'
OneSidedSelection	sampling_strategy='majority'
SVMSMOTE	sampling_strategy='not majority'
EditedNearestNeighbours (in last step)	sampling_strategy='all', n_neighbors=3, kind_sel='all'

由于原始数据库中分类重叠的问题较为严重，因此考虑先除噪声后过采样。这是因为 SVM-SMOTE 过采样法首先需要用标准的支持向量机初步确定决策边界区域，而 3.1.1 节的数值算例表明，数据分类不平衡和分类重叠同时存在的话，会对支持向量机的预测结果造成不利影响，因此在利用 SVM-SMOTE 进行过采样之前首先进行除噪声，以减轻数据分类重叠问题。具体来说，本节采用 Wilson 编辑最近邻居法 (ENN) 进行

除噪声。由于剪切失效数据的重要性高于弯剪失效和弯曲失效数据，所以只删除弯剪失效和弯曲失效数据，而保留剪切失效数据。由于原始数据库中由同一个试验者进行的同一批试验中的不同数据点会成簇出现，仅考虑成对出现的不同类数据点的 Tomek 连接对这种数据集的除噪声效果不佳，因此使用 ENN 方法，设置邻居点个数为 3，且只要其中有 1 个点与被考虑的点分类标签不同，就丢弃这个被考虑的数据点。使用 ENN 除噪声后，数据集从 25 条剪切失效、36 条弯剪失效、197 条弯曲失效变为 25 条剪切失效、12 条弯剪失效、184 条弯曲失效，除噪声后的数据集分布，如图 3.11 所示。与图 3.9 相比，ENN 方法主要删去了距离剪切失效太近的弯曲失效和弯剪失效数据点，除此以外，还删去了位于弯曲失效和弯剪失效边界的个别数据点。




图 3.11 ENN 除噪声后的数据集

为了防止过采样中生成太多的人工数据点，在采用 ENN 除噪声后，再利用单边选择 (OSS) 对弯曲失效数据进行高等欠采样，将弯曲失效数据量从 184 降低至 135。欠采样后，再利用 SVM-SMOTE 对剪切失效和弯剪失效数据进行过采样。之所以选择 SVM-SMOTE 算法，是因为在 2.5.1 节讨论分类机的预测性能时发现，基于原始数据库训练得到的分类机预测有向弯曲失效偏斜的倾向（见表 2.4），因此希望人工生成的新数据点可以将决策边界推离弯曲失效，减轻分类机预测发生偏斜的问题。过采样后，三种失效模式的数据量相同，均为 135，失效模式的分布情况如图 3.12 所示。与原始数据集相比，前处理后的数据集中，三种失效模式聚集的区域变得更加明显。考虑到生成新的人工合成数据后会引入新的分类重叠，故用 ENN 再进行一次除噪声，但这一次对三种失效模式的噪声数据均进行了删除处理。最终得到的数据集包括剪切失效型数据 135 条、弯剪失效型数据 132 条、弯曲失效型数据 126 条，如图 3.13 所示。




图 3.12 OSS 欠采样和 SVM-SMOTE 过采样后的数据集




图 3.13 前处理后的数据集

3.3 增强类算法

虽然 SMOTE 类过采样方法可以在一定程度上减轻随机过采样方法引起的机器学习模型过拟合问题，但是过采样方法在原始数据库中引入了新的数据，仍然存在引起过拟合的可能性。在第 2 章中，我们在利用神经网络分类机建立预测模型的过程中，为了控制过拟合问题，引用了交叉验证集来调节神经网络分类机的规则化参数。在这一章，我们将采用另一种方法来控制过拟合问题，以提高预测模型的泛化能力，即增强类算法。

3.3.1 增强类算法简介

在人工神经网络模型的构建过程中，首先从一个可能发生过拟合的模型出发，保证模型在训练集的精度，然后再通过调节正则化参数来控制过拟合问题。而增强类算法（boosting algorithm）利用完全不同的思路来保证模型的泛化能力。它首先从一个分类精度较低的弱分类机（weak learner）出发，通过训练一系列这样的弱分类机，然后综合考虑这一系列弱分类机系综（ensemble）的预测结果，得到最终的预测结果。在增强类算法中，最经典的是 AdaBoost 算法。AdaBoost 算法的优点是除了弱分类机本身的模型参数以外，只有一个可调参数，即系综中弱分类机的个数 T 。可以在数学上证明，对于二元分类问题，只要弱分类机的分类错误率略低于 50%，AdaBoost 算法可以将这个弱分类机增强为高精度的分类机，且分类机的分类错误率随着分类机系综中弱分类机的个数 T 的增加以指数形式下降^[87]。由于 AdaBoost 算法是由一系列弱分类机构成，因此从一开始就避免了过拟合问题。理论上来说，随着系综中弱分类机个数的增多，有可能造成一定的过拟合现象，但是在实际应用中发现^[88]，即使弱分类机的个数多达几千，增强类算法也不会过拟合。

AdaBoost 算法通过对训练集样本设置不同的权重，来训练侧重点不同的一系列弱分类机，算法的流程如图 3.14 所示。在这当中，最关键的步骤是训练样本分布的更新。由于错误率 $e_t < 0.5$ ，可以保证 a_t 是正数，因此对于第 t 个弱分类机分类正确的样本，可以降低它在 $t+1$ 个弱分类机训练时的权重，而对于第 t 个弱分类机分类错误的样本，则可以增加它在第 $t+1$ 个弱分类机训练时的权重。因此，第 $t+1$ 个弱分类机侧重考虑的是第 t 个弱分类机分类错误的训练样本，不同的弱分类机对不同类型的样本有较好的分类效果，当这些弱分类机综合在一起时，形成的系综对整体样本都有较好的分类效果。

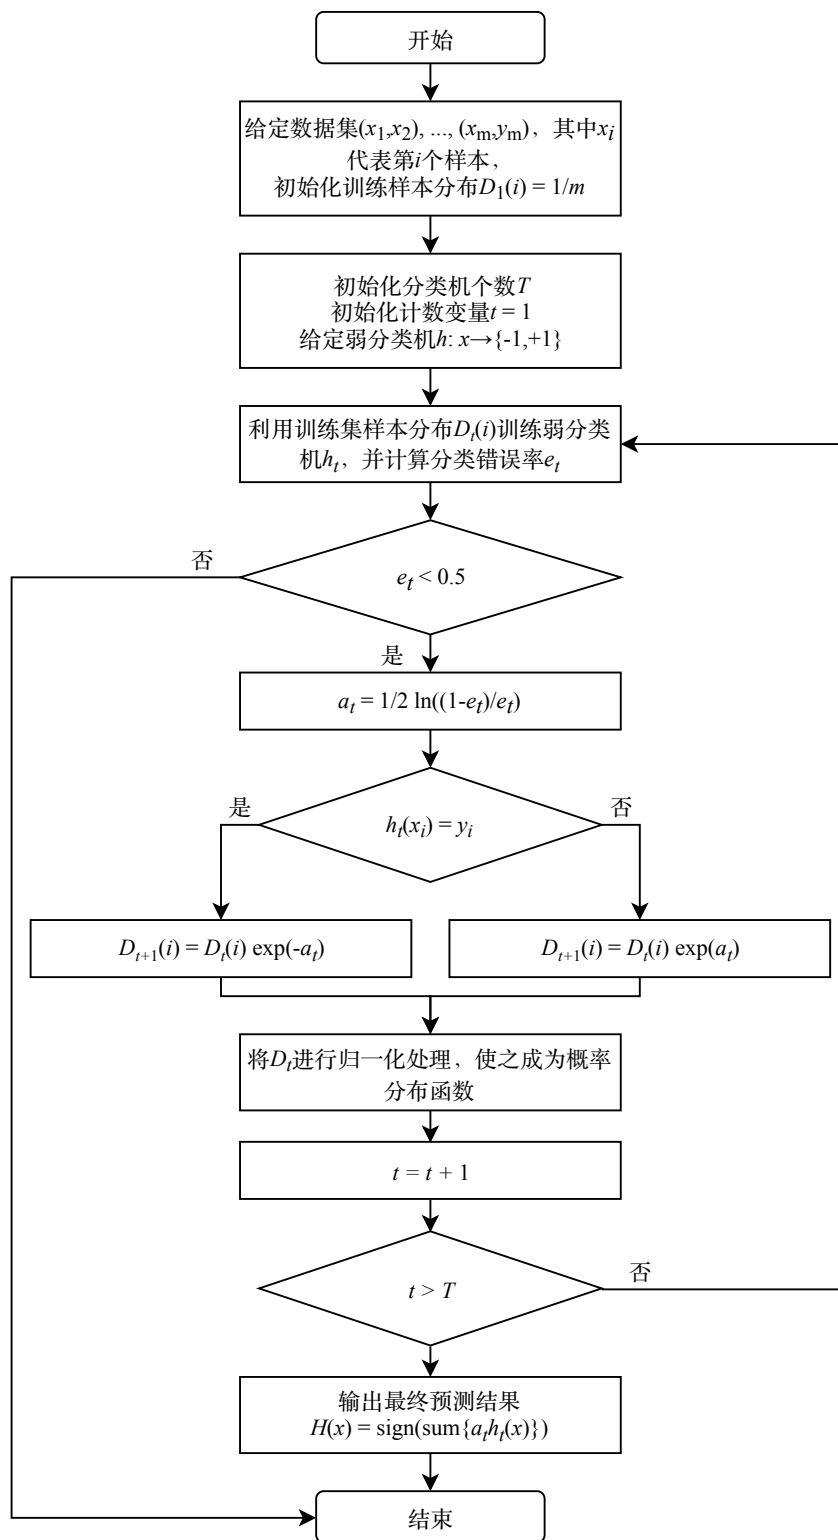


图 3.14 AdaBoost 算法流程图

3.3.2 AdaBoost 算法应用

将 3.2 节处理后的数据集随机采样，取其中的 80%作为训练集，20%作为测试集。弱分类机的类型选为单层决策树，即判断准则仅为特征矢量的分类机。一个简单的例子如图 3.15 所示。





图 3.15 单层决策树

为了确定分类机中弱分类机的数量，令弱分类机的个数 T 从 1 变化到 400，并计算每个 T 对应的训练集精度和测试集精度，所得结果，如图 3.16 所示。可见，当 T 大于 150 后，测试集和训练集的错误率都趋于稳定，不失一般性，取 $T = 200$ 。另外，在图中还可以发现，随着 T 的增加，测试集和训练集的错误率始终都非常接近，这表明预测模型具有很好的泛化能力，这也进一步验证了增强算法不容易产生过拟合这一结论 [88]。

图 3.16 错误率和弱分类机的个数 T 关系图

3.4 预测效果与对比讨论

利用测试集数据对最终得到的分类机进行预测能力评估，所得的混淆矩阵，如表 3.2 所示。可见，测试集中一共有 79 条数据，其中 77 条均分类正确，总体精度高达 97%。剪切失效的数据有 29 条，准确率为 97%，召回率为 100%， F_1 指标为 98%；弯剪失效的数据有 28 条，准确率为 96%，召回率为 96%， F_1 指标为 96%；弯曲失效的数据有 22 条，准确率为 100%，召回率为 95%， F_1 指标为 98%。三种失效模式 F_1 指标的几何均值 (geometric mean) 为 97%。而在第 2 章中的研究发现，如果直接用原始数据集训练神经网络分类机，在测试集的剪切失效、弯剪失效和弯曲失效的 F_1 指标分别为 40%、70%、99%，三种失效模式 F_1 指标的几何均值为 65%；如果用随机欠采样方法处理原始数据库，并训练神经网络分类机，在测试集的剪切失效、弯剪失效和弯曲失效的 F_1 指标分别为 91%、74%、89%，三种失效模式 F_1 指标的几何均值为

84%。由此表明，联合采用 AbaBoost 算法和数据采用除噪方法可以有效的处理偏斜数据问题，得到的最终预测模型精度高，且具有很好的泛化能力。

表 3.2 分类机在测试集的混淆矩阵

失效模式		预测结果			总计
		剪切失效	弯剪失效	弯曲失效	
实际结果	剪切失效	29	0	0	29
	弯剪失效	1	27	0	28
	弯曲失效	0	1	21	22
总计		30	28	21	79

3.5 本章小结

本章对钢筋混凝土柱失效模式分类中的偏斜数据问题进行了进一步的深入研究：首先分析了偏斜数据集对最终的机器学习分类机预测能力产生不利影响的两个主要因素是数据分类的不平衡和数据分类的重叠，然后分别介绍了处理这两个问题的若干解决方案，大体分为基于数据集层面和基于算法层面这两类方法，进而采用数据集层面的高等采用方法和除噪声方法，对原始数据库进行前处理。在前处理过程中，利用主成分分析法对失效模式的 4 维特征矢量空间进行降维可视化，并根据可视化的结果选择前处理所用的相关算法、确定前处理流程，最后用前处理后的数据测试集训练基于单层决策树的 AdaBoost 模型，并用测试集对机器学习模型的预测能力进行了评估。研究表明，AdaBoost 算法结合采样除噪方法是处理钢筋混凝土柱失效模式识别中偏斜数据问题的有效手段。

第 4 章 基于 BWBN 的压弯耦合滞回模型

在强震作用下，钢筋混凝土柱的恢复力一般会因为变形过大而表现出明显的滞回行为。对于弯曲失效型柱，由于构件的塑性发展充分，因此地震作用下的滞回环饱满，刚度退化和强度退化较为缓慢，可以有效地消耗地震输入到结构的能量，减小结构的变形，保证结构的安全可靠；对于剪切失效型柱，由于柱的塑性发展不足，在峰值点以后恢复力退化严重，同时由于钢筋的滑移错动，会产生严重的捏拢效应，在地震作用下的滞回环耗能较小，不利于地震输入到结构能量的耗散，在地震作用下可能因为变形较小即发生破坏。由于在很多建筑结构中，钢筋混凝土柱都是主要的承重构件，一旦发生破坏，可能会引起建筑结构的整体倒塌，造成严重的经济损失和人员伤亡；对于弯剪失效型柱，耗能能力处在剪切失效型和弯曲失效型之间，具有一定的变形能力，但一般由于塑性发展不完全，耗能能力不如弯曲失效型柱。显然，这三种失效模式的钢筋混凝土柱的滞回行为各有特点，因此需要对三种失效模式的钢筋混凝土柱滞回曲线分别进行研究。

滞回模型大体可以分为折线型滞回模型（polygonal hysteresis models, PHMs）和光滑型滞回模型（smooth hysteresis models, SHMs）两大类^[22]。折线型滞回模型通常能够考虑混凝土开裂、钢筋屈服以及强度和刚度退化引起的刚度折线型变化；在光滑型滞回模型中，混凝土的开裂发展等将引起刚度的连续变化，只有在卸载以及发生刚度退化时，刚度会发生突变。当前，主要的折线型模型包括：Veletsos 等人提出的理想弹塑性模型^[23]、Clough 等人提出的双折线模型^[24]、Takeda 模型^[25]、由 Saidi 和 Sozen 提出的 Q-hysteresis 模型^[91]、由 Ozcebe 和 Saatcioglu 提出的剪切滞回模型^[92]、Dowell 等人提出的 pivot 滞回模型^[93]、Sucuoglu 和 Erberik 提出的基于能量的滞回模型^[94]、Ibarra 等人提出的捏拢滞回模型骨架曲线^[95]等。图 4.1 展示了前四个折线型模型的示意图。可见，这些折线型滞回模型一般用若干关键点控制滞回曲线的形状，随着滞回模型越来越精细，模型参数的数量会越来越多，但模型参数数量的增加会导致计算复杂度和计算机数值实现难度的增加。而在光滑型滞回模型中，模型参数相对减少，但一般缺少明确的物理意义，虽然与试验数据的拟合精度能够较高，但不便于工程应用。在这当中，Bouc 和 Wen 模型^{[96][97]}用微分方程的形式描述滞回关系，是一类应用广泛的光滑型滞回模型，可以较精确地反映钢筋混凝土柱的滞回行为。此后，Baber 和 Noori 对这一模型进行了改进和推广，得到了著名的 BWBN 模型^[98]。由于此模型可以综合考虑结构构件在地震作用下的强度退化、刚度退化和捏拢效应，并且对各种构件的滞回曲线进行有效识别^[99]，因此近年来得到广泛关注。本章主要研究是否能够采用 BWBN 模型描述钢筋混凝土柱不同失效模式下的滞回曲线。

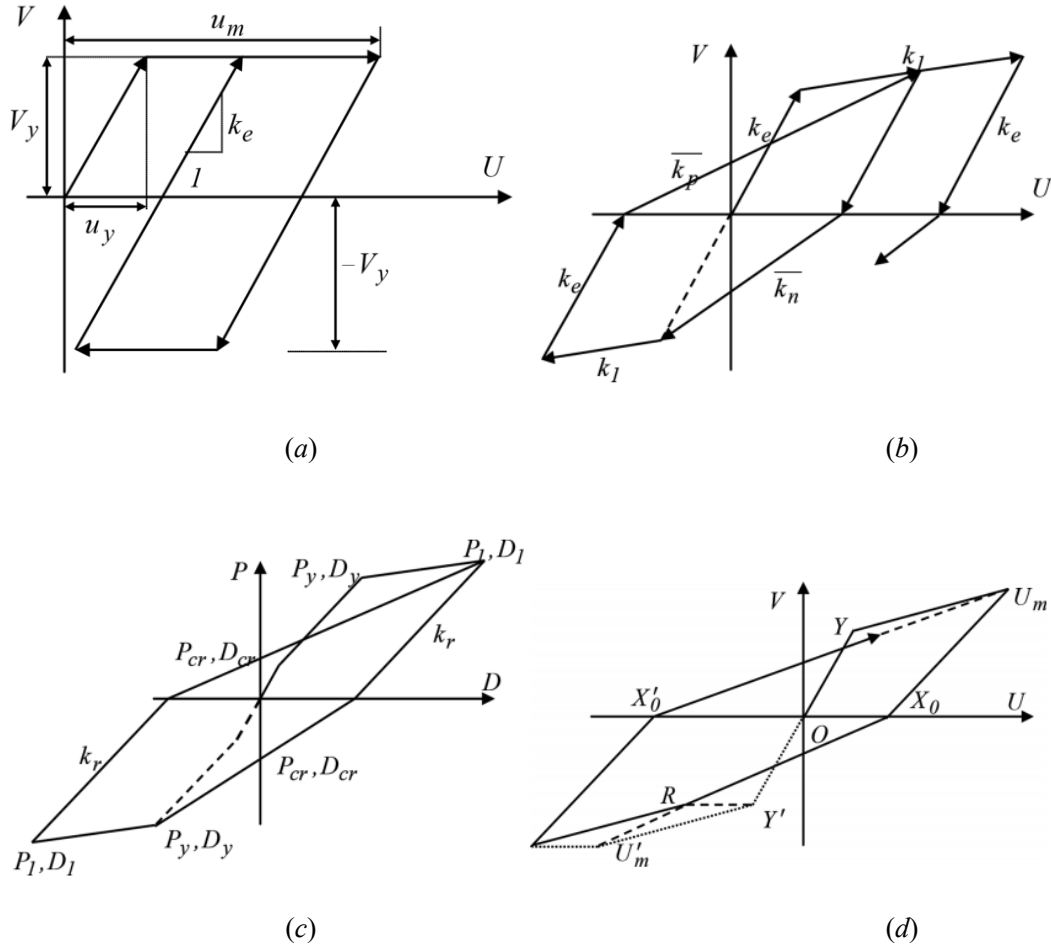


图 4.1 若干折线型模型 (a)理想弹塑性模型、(b)Clough 模型、(c)Takeda 模型、(d)Q-hysteresis 模型

在 BWBN 类模型中，最常用的一类表达形式是单个自由度的力-位移演化关系，其可以对钢筋混凝土柱在侧向荷载和轴向受压下的力-位移关系进行很好的模拟。然而，钢筋混凝土柱构件所承受的极限抗弯承载力和轴力是相互耦合的：当轴向力较小时，柱的抗弯承载力会提高，当轴向力超过某个临界值后，随着轴向力的增加，柱的抗弯承载力会随之下降。同时，轴向力对钢筋混凝土柱的失效模式演化具有显著影响。在变轴力情况下，失效模式有可能由弯曲失效转变为剪切失效，造成滞回曲线的显著不同。因此，如果将轴力引入到 BWBN 类模型中，建立压弯耦合模型，以描述滞回曲线的演变成为本章关注的焦点。目前，BWBN 类模型考虑钢筋混凝土柱压弯耦合效应的研究还不充分，Colangelo 在利用随机等效线性化研究多自由度非线性结构的过程中，提出了一个考虑钢筋混凝土柱压弯耦合效应的方法^[100]，但是并没有对这个模型的合理性进行进一步的详细讨论和解释。因此，本章结合 BWBN 模型的积分形式，从数学的角度对 Colangelo 提出的模型合理性进行了解释，并且将这个模型推广为一个可以考虑轴力变化速度的率相关压弯耦合模型。

4.1 BWBN 滞回模型简介

BWBN 模型是由 Bouc 和 Wen 建立，并由 Baber 和 Noori 改进和推广的。在工程领域，BWBN 最先被应用于木结构建筑中。2002 年，Zhang 等人用 BWBN 模型对木制墙体进行了模拟^[101]。2009 年，Xu 等人对木制节点进行了模拟^[102]。随后，BWBN 模型逐渐被应用于钢筋混凝土结构中^[103]，其中包括钢筋混凝土框架结构^[104]、梁柱节点以及墙体^[105]。2016 年，Yu 等人^[99]利用 BWBN 模型对剪切失效型钢筋混凝土柱的滞回曲线进行模拟，结果表明 BWBN 模型可以很好的反映剪切失效柱刚度和强度的退化、捏拢效应。

4.1.1 微分方程形式

BWBN 模型将总恢复力分为弹性恢复力和滞回恢复力两个部分

$$R(u, z) = \alpha k_0 u + (1 - \alpha) k_0 z \quad (4.1)$$


其中 $R(u, z)$ 代表总恢复力， k_0 为初始弹性刚度， u 为柱顶相对于柱底部的侧向位移， z 为滞回位移， α 为弹性恢复力占总恢复力的比例，是一个介于 0 到 1 的常数。注意到 k_0 和 α 是两个模型参数，而 u 一般是事先给定的数据。为了确定总恢复力，需要确定滞回位移 z 的演化方程。Bouc 和 Wen^[96] 最初给出的演化方程为

$$\dot{z} = A\dot{u} - \beta z|\dot{u}| - \gamma|z|\dot{u} = \dot{u}(A - |z|(\beta \text{sign}(z\dot{u}) + \gamma)) \quad (4.2)$$

其中的 A, β, γ 为常数，且 $A > 0, \beta > 0$ 。Wen 在此基础上，又增加上了一个正幂指数参数 n

$$\dot{z} = \dot{u}(A - |z|^n(\beta \text{sign}(z\dot{u}) + \gamma)) \quad (4.3)$$

其中， n 是一个正实数，参数 β 和 γ 需要满足 $\beta + \gamma > 0$ 。参数 n 控制恢复力曲线从弹性到塑性的转化过程，随着 n 的增大，曲线越接近理想弹塑性模型，如图 4.2 所示。其余的两个参数固定为： $\beta = 1, \gamma = 0$ ， n 分别取为 1、3 和 9。式(4.3)定义的滞回位移演化方程一般被称作非退化的 BWBN 模型。


 图 4.2 改变参数 n 对滞回位移演化的影响

显然，对于单调加载，恢复力曲线的形状只与参数 β 和 γ 之和有关，而与这两个参数各自的取值无关。假设 z 的初值为 0^+ ，对于正向单调加载， \dot{u} 始终大于 0，因此 $\text{sign}(z\dot{u}) = 1$ ，在式(4.3)两侧同时除以 \dot{u} ，可得到

$$\frac{dz}{du} = A - z^n(\beta + \gamma) \quad (4.4)$$

这个自治方程的不动点对应模型的最大滞回位移 z_m

$$z_m = \left(\frac{A}{\beta + \gamma} \right)^{\frac{1}{n}} \quad (4.5)$$

而对于负向单调加载，经过相同的分析可以得到同样的结果。对于循环加载，恢复力曲线的形状与参数 γ 和 β 之差有关。假设在正向单调加载后开始卸载，有 $\text{sign}(z\dot{u}) = -1$ ，在式(4.3)两侧同时除以 \dot{u} 得到

$$\frac{dz}{du} = A + z^n(\beta - \gamma) \quad (4.6)$$

由此可见， $\beta - \gamma$ 控制了卸载时滞回位移的演化。

Baber 和 Wen^[97]进一步对式(4.3)进行了改进，增加了 η 和 ν 这两个函数用来考虑构件的强度退化和刚度退化效应

$$\dot{z} = \frac{1}{\eta} \dot{u} (A - \nu |z|^n (\beta \text{sign}(z\dot{u}) + \gamma)) \quad (4.7)$$

其中， η 和 ν 是随加载的进行为单调递增的正值函数，分别代表了构件刚度的退化和强度的退化

$$\eta = 1 + \delta_\eta \epsilon \quad (4.8)$$

$$\nu = 1 + \delta_\nu \epsilon \quad (4.9)$$

其中， $\delta_\eta > 0, \delta_\nu > 0$ 是两个待定常数， ϵ 为累计滞回耗能，定义为

$$\epsilon = (1 - \alpha)k_0 \int_0^T \dot{u}z dt = (1 - \alpha)k_0 \int_{path} z du \quad (4.10)$$

积分中的 $path$ 表示沿着给定的 u 路径进行积分。在 $z-u$ 空间内，累计滞回耗能就是滞回环所包围的面积再乘以 $(1 - \alpha)k_0$ 。显然，对于单调加载，根据之前类似的分析，可以得到最大的滞回位移变为

$$z_m = \left(\frac{A}{v(\beta + \gamma)} \right)^{\frac{1}{n}} \quad (4.11)$$

因此，随着加载的进行， v 单调增加，最大滞回位移 z_m 随之逐渐下降，这反映了钢筋混凝土构件累计滞回损伤对构件强度的影响。如图 4.3 所示，随着加载的进行，由虚线表示的曲线逐渐下降，在不同的位移幅值下，对应的点分别在这四条虚线上，实际的力-位移曲线为连接这一系列点的黑色实线。可以看到，函数 v 有效地反映了钢筋混凝土柱力-位移曲线峰值点后的强度退化行为。常数 δ_v 越大，强度退化越严重。




图 4.3 强度退化效应

参数 η 对刚度的影响则比较直接，随着 η 的增加， dz/du 的绝对值逐渐变小，这反映到力-位移曲线上就对应了刚度的退化。如图 4.4 所示，常数 δ_η 越大，强度退化越严重。




图 4.4 刚度退化效应

在此基础上，为了进一步考虑钢筋混凝土构件在循环加载下出现的捏拢效应，加入捏拢函数 h 。捏拢效应的产生，主要是因为当卸载到恢复力为 0 附近时，混凝土裂缝开闭和钢筋在混凝土中的滑移而引起的刚度下降，因此捏拢效应本质上属于刚度退化的一种特殊类型，它的特点是只在滞回恢复力等于 0 附近时刚度退化严重，而在其他区域没有明显的作用。如图 4.5 所示。因此，可在刚度退化函数 η 的分母上再加入一个考虑捏拢的函数，得到

$$\dot{z} = \frac{h}{\eta} \dot{u} (A - \nu |z|^n (\beta \text{sign}(z\dot{u}) + \gamma)) \quad (4.12)$$

其中的捏拢函数 h 为

$$h = 1 - \zeta_1 \exp \left\{ - \left[\frac{z \text{sign}(\dot{u}) - qz_m}{\zeta_2} \right]^2 \right\} \quad (4.13)$$

式中 $\zeta_1 = \zeta_s [1 - \exp(-p\epsilon)]$ 是控制捏拢严重程度的函数， ζ_s 和 p 是两个待定常数， ϵ 是式(4.10)定义的累计滞回耗能； $\zeta_2 = (\psi + \delta_\psi \epsilon)(\lambda + \zeta_1)$ 是控制捏拢效应在滞回位移 z 上的弥散长度的， $\psi, \delta_\psi, \lambda$ 是三个待定常数，分别控制捏拢的大小、捏拢扩散速度以及参数 ζ_2 相对于 ζ_1 的变化速率； q 控制捏拢开始的位置； z_m 为式(4.11)中的最大滞回位移；从式(4.13)可以看出，当 z 取值在 $qz_m \text{sign}(\dot{u})$ 附近时最为严重，而在远离 $qz_m \text{sign}(\dot{u})$ 时 $h \approx 1$ ，即不出现捏拢现象。




图 4.5 捏拢效应

根据式(4.12)可知, BWBN 模型的滞回位移演化微分方程综合考虑了钢筋混凝土柱的强度退化、刚度退化和捏拢效应, 与式(4.1)一起构成了 BWBN 滞回模型。模型中共包含 13 个待定参数, 分别为: $\{A, \alpha, \beta, \gamma, n, \delta_\eta, \delta_\nu, \zeta_s, p, q, \psi, \delta_\psi, \lambda\}$, 注意到初始刚度 k_0 可以通过试验数据直接获得, 因此不包含在待定参数中。这 13 个参数可以被分为三组。其中, $\{A, \alpha, \beta, \gamma, n\}$ 是形状参数, 用于确定滞回模型的整体形状; $\{\delta_\eta, \delta_\nu\}$ 是控制刚度退化和强度退化严重程度的参数; $\{\zeta_s, p, q, \psi, \delta_\psi, \lambda\}$ 是用来控制捏拢效应的参数。此外, 为了得到热力学上稳定的模型 (例如, 在卸载时恢复力的绝对值应该减小而不是增加), 模型参数的取值需要受到一定的约束。因此, Ismail 等人在 2009 年证明^[106], 对于不考虑强度退化、刚度退化和捏拢效应的 BWBN 模型, 形状参数应该要满足 $A > 0, \beta + \gamma > 0, \beta - \gamma \geq 0$ 。除此以外, 还要满足 $\alpha \in (0, 1), n > 0$ 。再加入强度退化、刚度退化和捏拢效应后, 考虑随着加载的进行, 刚度和强度的退化会越来越严重, 随着裂缝的增多和钢筋滑移的加剧, 捏拢效应也会随之加剧, 因此: $\delta_\eta > 0, \delta_\nu > 0, 0 < \zeta_s < 1, p > 0, -1 < q < 1, \psi > 0, \delta_\psi > 0, \lambda > 0$ 。这些范围限制基本可以满足上述力学常识。

4.1.2 参数分析讨论

为展示 BWBN 模型对钢筋混凝土柱不同失效模式下滞回曲线的描述能力, 本节进一步研究 BWBN 模型的每个参数对滞回曲线的影响。首先, 不考虑强度退化、刚度退化和捏拢, 令 $\delta_\eta = \delta_\nu = \zeta_s = 0$, 研究 5 个形状参数对滞回曲线的影响。遵循从整体到局部的思路, 首先研究力-位移曲线的初始刚度和最终刚度。通过在式(4.1)两边取微分, 然后两边同时除以总位移 u 的微分得到

$$\frac{dR(u, z)}{du} = \alpha k_0 + (1 - \alpha) k_0 \frac{dz}{du} \quad (4.14)$$

其中, 等式右边第二项滞回位移对总位移的导数可以在式(4.3)两边同时除以 \dot{u} 得到

$$\frac{dz}{du} = A - |z|^n(\beta \text{sign}(zu) + \gamma) \quad (4.15)$$

显然，初始刚度对应于 $u \rightarrow 0, z \rightarrow 0$ ，所以有

$$k_i = \left. \frac{dR(u, z)}{du} \right|_{u \rightarrow 0, z \rightarrow 0} = \alpha k_0 + (1 - \alpha)k_0 A \quad (4.16)$$

最终刚度对应于 $u \rightarrow \infty$ ，此时滞回位移 z 对总位移 u 的导数等于 0，所以

$$k_f = \left. \frac{dR(u, z)}{du} \right|_{u \rightarrow \infty} = \alpha k_0 \quad (4.17)$$

最终刚度与初始刚度的比值为

$$\frac{k_f}{k_i} = \frac{\alpha}{\alpha + (1 - \alpha)A} \quad (4.18)$$

可以发现，当 $\alpha = 0$ 时，最终刚度与初始刚度的比值等于 0；当 $\alpha = 1$ 时，最终刚度与初始刚度的比值等于 1；当 $\alpha \in (0, 1)$ 时，最终刚度与初始刚度的比值随着 A 的增加而减小，最终趋向于 0。

因此，将形状参数分别设置为 $A = 1, \beta = 1, \gamma = 0, n = 1$ ，所得力-位移关系如图 4.6 所示。其中，图 4.6(a) 对应 $\alpha = 0.033$ ，图 4.6(b) 对应 $\alpha = 0.0033$ 。可以看到，随着参数 α 的减小，最终刚度与初始刚度的比值减小，并逐渐趋向于 0。从图中还可以发现，参数 α 的变化对屈服点位移和恢复力的影响不大。在此基础上，令 $\alpha = 0.033$ ，改变 $A = 9$ ，所得力-位移关系，如图 4.7 所示。可以看到，随着参数 A 的增加，最终刚度与初始刚度的比值减小，但屈服点的位移基本不变，屈服点的恢复力则增大，初始刚度增大。参数 n 的作用已经在 4.1.1 节有过详细讨论，这里不再赘述。关于刚度退化、强度退化和捏拢的参数敏感性分析，Yu 等人在 2016 年有过较为详细的分析^[99]。




图 4.6 参数 α 对 BWBN 模型的影响

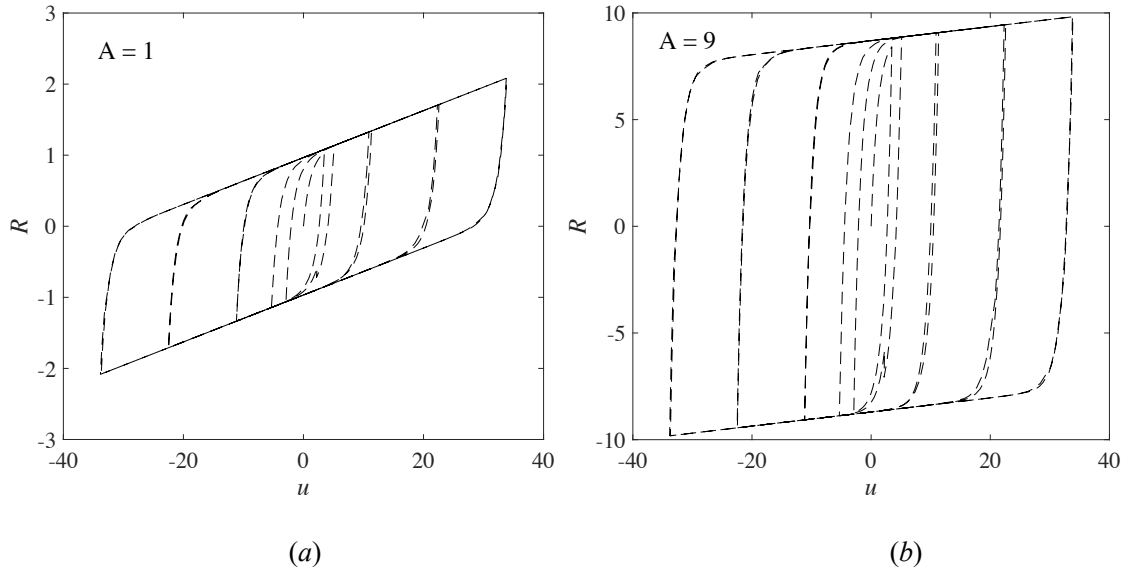


图 4.7 参数A对 BWBN 模型的影响

4.2 建立压弯耦合滞回模型

4.2.1 滞回模型的积分表示

需要指出的是，BWBN 类模型不仅可以用 4.1 节介绍的微分方程表示，还可以用积分表示方法。微分方程形式是 BWBN 模型最常用的表示方法，它确定了在滞回位移 z 和总位移 u 组成的 $z-u$ 状态空间中，给定当前 z 和 u 状态以及 u 的变化 du 时， z 的演化方式。其中，演化方程只和当前状态有关，是一种从局部考虑问题的方式。而 BWBN 模型的积分表示，则可以从整体考虑整个演化过程，其一方面可以从另一个全新的角度理解 BWBN 模型，另一方面也方便引入压弯耦合效应。为了讨论的清晰简洁，本节主要介绍式(4.3)定义的非退化 BWBN 模型的积分表示。滞回位移演化的积分表示方法，可以用斯蒂尔杰斯积分 (Stieltjes integral) 的形式表达^[107]

$$z(t) = \int_0^{\xi_s(t)} \mu(\xi_s(t) - \xi'_s) du(\xi'_s) \quad (4.19)$$

其中 u 代表总位移， $\xi_s(t)$ 为模型的内禀时间，是一个随时间单调递增的正值函数，一般定义为位移路径 $u = u(t)$ 的泛函

$$\xi_s(t) = \xi_s[u(t)] = \int_0^t |\dot{u}(t')| dt' \quad (4.20)$$

可见，给定位移路径 $u = u(t)$ ，由上式定义的 $\xi_s(t)$ 实际上就是此位移路径划过的路程长度。假设某位移路径为：先向正方向运动到 $u = 1$ 处，然后再往负方向回到 $u = 0$ 处，最终时刻的位移 $u(t_f) = 1 - 1 = 0$ ，但划过的路程长度为 $\xi_s(t_f) = 1 + 1 = 2$ 。如图 4.8 所示，左图是给定的位移路径 $u(t)$ ，右图是此位移路径对应的总位移 u 和内禀时间 ξ_s 关

系图，可以发现，在 $u - \xi_s$ 空间，一个给定加载路径是由斜率为+1和-1两种线段首尾相连构成的，当 $\dot{u} > 0$ 时，线段斜率为+1， $\dot{u} < 0$ 时，线段斜率为-1。




图 4.8 总位移 u 和内禀时间 ξ_s 的关系

在式(4.19)中， $\mu(z)$ 是用来考虑滞回现象的核函数。它是一个连续、有界、正值、非增的函数，一般取为指数核函数的形式：

$$\mu(z) = A e^{-\beta z} \quad (4.21)$$

其中， $A, \beta > 0$ 。这时，式(4.19)可以写为

$$z(t) = A \int_0^{u(t)} e^{-\beta(\xi_s(t) - \xi'_s)} du(\xi'_s) = A e^{-\beta \xi_s(t)} \int_0^{\xi_s(t)} e^{\beta \xi'_s} \frac{du}{d\xi'_s} d\xi'_s \quad (4.22)$$

替换积分变量 $\xi'_s = \xi''_s / \beta + \xi_s(t)$ ，所以 $d\xi'_s = d\xi''_s / \beta$ ，积分上下限变为 $\xi''_s: -\beta \xi_s(t) \rightarrow 0$ ，有

$$\begin{aligned} z(t) &= \frac{A}{\beta} \int_{-\beta \xi_s(t)}^0 e^{\xi''_s} \left(\frac{du}{d\xi'_s} \Big|_{\xi'_s = \xi''_s / \beta + \xi_s(t)} \right) d\xi''_s \\ &= \frac{A}{\beta} \int_{-\beta \xi_s(t)}^0 e^{\xi''_s} \text{sign}(\dot{u}(\xi''_s)) d\xi''_s \end{aligned} \quad (4.23)$$

注意到第一个等式中括号里的导数实际上就等于 \dot{u} 的符号 $\text{sign}(\dot{u})$ 。式(4.23)中的最后一个等式中的积分可以用图表示。如图 4.9 所示，横轴代表积分变量 ξ''_s ，纵轴代表被积函数 $e^{\xi''_s} \text{sign}(\dot{u}(\xi''_s))$ 的取值，根据 \dot{u} 符号的不同分为 $e^{\xi''_s}$ 和 $-e^{\xi''_s}$ ，积分从 $\xi''_s = -\beta \xi_s(t)$ 开始到 $\xi''_s = 0$ 为止，根据 \dot{u} 符号的不同分为若干段。当 $\dot{u} > 0$ 时取上侧 $e^{\xi''_s}$ 曲线与横坐标包围的面积，图中用蓝色表示；当 $\dot{u} < 0$ 时取下侧 $-e^{\xi''_s}$ 曲线与横坐标包围的面积，图中用绿色表示；滞回位移 $z(t)$ 等于蓝色区域的面积减去绿色区域的面积。从图中可以看出，对于单调加载，随着加载的进行，这个积分趋向于 1，也就意味着最大滞回位移 $z_m = A/\beta$ ，对应 $\gamma = 0, n = 1$ 的无退化 BWBN 模型。




图 4.9 滞回位移积分表示示意图

接下证明，由式(4.22)定义的滞回位移积分形式等价于 $\gamma = 0, n = 1$ 的非退化 BWBN 模型。首先，将式(4.22)改写为

$$z(t) = Ae^{-\beta \xi_s(t)} \int_0^t e^{\beta \xi_s(t')} \frac{du}{dt'} dt' \quad (4.24)$$

对时间 t 求导得到，并注意 $\dot{\xi}_s = |\dot{u}|$

$$\dot{z} = -\beta \dot{\xi}_s z + A \dot{u} = A \dot{u} - \beta z |\dot{u}| \quad (4.25)$$

与式(4.3)对比发现，式(4.25)就是 $\gamma = 0, n = 1$ 的非退化 BWBN 模型的微分方程形式。

4.2.2 引入压弯耦合效应

基于 BWBN 模型的积分表示方法可以看到，对于单调加载，最大滞回位移为 $z_m = A/\beta$ ，当位移 $u = 3/\beta$ 时，对应的滞回位移达到最大滞回位移的 95%，对于以滞回恢复力占主导地位的构件来说 $\alpha \ll 1 - \alpha$ ，对应的恢复力约为 $0.95k_0 A/\beta$ 。由此可见，参数 A 正比于最大滞回位移和屈服点的恢复力。也就是说，参数 A 控制了最大滞回位移和恢复力的尺度大小。因此，在加入了强度退化效应后，峰值恢复力也会随着参数 A 的增加而增加。此外，由钢筋混凝土结构基本原理可以得到，偏心受压构件的受弯承载力与构件轴向力大小的关系一般可用构件的 P-M 曲线表示，如图 4.10 所示， P 代表轴力， M 代表构件的受弯承载力。轴力正值为压力，负值为拉力， P_{max} 代表构件的极限受压承载力， P_{min} 代表构件的极限受拉承载力。从图中可以看到，当轴压力较小时，构件的受弯承载力随着轴压力的增加而增加；而当轴压力较大时候，构件的受弯承载力随着轴压力的增加而减小，且一般认为轴向拉力对构件的受弯承载力有不利影响，图中用虚线表示。




图 4.10 钢筋混凝土构件 P-M 曲线

因此，对于钢筋混凝土悬臂柱，柱底部承受的弯矩等于柱顶承受的侧向力乘以柱子的高度，柱顶部的最大侧向恢复力与轴力 P 的关系类似于 P-M 关系，可以用二次曲线的关系模拟上述 P-M 关系^[100]

$$M = M_0 y(P) = M_0 \left[1 - \left(\frac{2P - P_{max} - P_{min}}{P_{max} - P_{min}} \right)^2 \right] \quad (4.26)$$

其中， M_0 对应轴力等于 0 时的受弯承载力， $y(p)$ 是以 P_{max}, P_{min} 为零点，以 $0.5(P_{max} + P_{min})$ 为对称轴，且最大值等于 1 的抛物线。接下来，我们将在 BWBN 模型中引入压弯耦合效应。由于 BWBN 模型的积分形式(4.22)中的参数 A 控制了最大恢复力。类似的，可以将参数 A 推广为和轴力相关的数 $Ay(P)$ 。因此，式(4.22)变为

$$z(t) = Ay(P) \int_0^{u(t)} e^{-\beta(\xi_s(t) - \xi'_s)} du(\xi'_s) = Ay(P) e^{-\beta \xi_s(t)} \int_0^t e^{\beta \xi_s(t')} \frac{du}{dt'} dt' \quad (4.27)$$

对式(4.27)求时间的导数，得到考虑压弯耦合的 BWBN 滞回模型的微分形式表示

$$\dot{z} = Ay(P) \dot{u} - \beta z |\dot{u}| + \frac{y'(P) \dot{P}}{y(P)} z \quad (4.28)$$

与式(4.25)对比发现，参数 A 变成了 $Ay(P)$ ，且多了一项考虑轴力变化的率相关的贡献项。式(4.28)可以进一步改写为

$$\dot{z} = \dot{u} \left(Ay(P) - |z| \text{sign}(z\dot{u}) \left(\beta - \frac{y'(P) \dot{P}}{y(P) |\dot{u}|} \right) \right) \quad (4.29)$$

由此可见，在微分形式表示中，压弯耦合效应一方面将参数 A 替换为 $Ay(P)$ ，另一方面将参数 β 替换为 $\beta - y'(P) \dot{P} / (y(P) |\dot{u}|)$ 。但注意到，当轴向压力达到极限受压承载力或极限受拉承载力时，该微分方程出现奇异值，这是因为构件此时已经发生了轴向破坏，基本已经失去了提供侧向恢复力的能力，应当停止滞回位移的进一步演化。因此，进一步，将考虑了退化、捏拢效应的 BWBN 模型微分形式(4.12)中的参数 A 和 β 做相应的替换，得到基于 BWBN 的压弯耦合滞回模型

$$\dot{z} = \frac{h}{\eta} \dot{u} \left(Ay(P) - v|z|^n \left(\left(\beta - \frac{y'(P)\dot{P}}{y(P)|\dot{u}|} \right) \text{sign}(z\dot{u}) + \gamma \right) \right) \quad (4.30)$$

其中

$$y(P) = 1 - \left(\frac{2P - P_{max} - P_{min}}{P_{max} - P_{min}} \right)^2 \quad (4.31)$$

式(4.30)中其余参数的含义在 4.1 节有详细说明，在此不再赘述。

4.2.3 常轴力与变轴力滞回曲线对比分析

式(4.30)和(4.31)定义的压弯耦合滞回模型显式地考虑了轴力变化率对构件滞回行为的影响。本节通过一个简单的数值算例，来对比分析变轴力和常轴力两种情况下构件滞回行为的异同。由于目前缺少在变轴力条件下的试验数据，本文考虑在常轴力试验的基础上，人为加入轴力随着加载步数的变化。

图 4.11 中，蓝色虚线代表归一化的位移加载历史（归一化位移和归一化恢复力的定义在 4.3.3 节有详细说明）。一共加载 5 个周期，前 2 个周期位移幅值较小，第 3 和第 4 周期位移幅值中等，最后一个周期位移幅值大。轴向压力加载历史如图 4.11 中红色实线所示。考虑到混凝土的受拉强度一般比受压强度小一个量级，因此取 $P_{min} = -0.1$, $P_{max} = 1.0$ 。考虑轴力在较低水平 $P = 0.3$ 附近波动，振幅为 0.3，因此轴力最小值为 0，最大值为 0.6，均为压应力，一共加载 5 个周期。知得一提的是，本文此处的轴力加载历史的选取具有任意性，仅用来展示压弯耦合滞回模型可以考虑变轴力的影响，进一步的分析需要实际变轴力下试验数据的支持。不失一般性，模型参数取为表 5.1 中第一条 imai86 数据的结果。分别考虑常轴力 $P = 0.3$ 与上述变轴力两种情况的滞回行为，得到的结果如图 4.12 所示。可以看到，在变轴力的作用下（红色实线），恢复力峰值有略微下降，表现出更严重的损伤。在加载后期，强度退化效应更加明显，捏拢效应也更加显著。由于轴力加载与位移加载历史具有相位差，变轴力作用下的恢复力曲线具有明显的不对称性。上述数值试验说明，本文提出的考虑压弯耦合的滞回模型，可以有效地考虑轴力变化对构件造成的损伤，反映出钢筋混凝土柱轴压力和弯矩应力的相互作用和影响。




图 4.11 归一化的位移和轴力加载随加载步数的变化




图 4.12 常轴力和变轴力滞回曲线对比

4.3 压弯耦合滞回模型参数识别

基于 BWBN 的压弯耦合模型一共有 13 个待定模型参数，分别为 $\{A, \alpha, \beta, \gamma, n, \delta_\eta, \delta_\nu, \zeta_s, p, q, \psi, \delta_\psi, \lambda\}$ ，这些模型参数通常无法通过理论推导的方式确定，因此需要结合试验数据进行识别。模型参数的识别本质上是模型参数的回归分析。回归分析最常用的技术是最小二乘法。最小二乘法是在给定试验观测数据的条件下，找到最优的模型参数，使得预测曲线与试验曲线最接近，预测和试验的接近程度一般用预测值和试验值的残差来定量表示，而最小二乘法则是对残差函数寻找最优模型参数的解答，认为使得残差最小的自变量取值为实际的模型参数取值。在最小二乘法的框架下，寻找最优解的算法繁多，典型的包括梯度类算法和启发式算法^{[108][109]}。

梯度类算法除了需要知道目标函数在某点的取值外，还需要知道目标函数在某点的梯度值，利用梯度值判断迭代的走向，使得参数点在参数空间内往最优的位置移动。显然，此类算法需要目标函数相对光滑，且具有合理的梯度定义，如果目标函数的连续性不能得到保证，或者不具有凸函数的性质，则很容易陷入局部最优，甚至无法保证算法的收敛。对于组合最优问题^[110]，梯度类算法一般无法给出较好的解决方案，譬如典型的旅行推销员问题（Traveling Salesman Problem，或者简称为 TSM）^[111]，随着参数空间维数的增加，计算复杂度呈指数上升趋势，在复杂度上属于 NP 完备问题。为处理 NP 完备问题，研究者们发展了一类启发式算法（heuristic algorithm），以较低的计算复杂度获得问题的近似解。

启发式算法主要运用了两种策略：分而治之^[112]和迭代优化^{[113][114]}。分而治之策略是将一个计算量很大的问题分解为一个一个容易被解决的子问题，然后解决这些子问题，最后把这些子问题的结果拼接在一起得到原问题的解。迭代优化策略则是从一个已有的参数空间构型出发，在下一个增量步朝着较优的方向演化。对于一般问题，由于往往不一定能被分解为子任务，而且传统的迭代优化方法容易陷入局部最优，因此需要更为一般化的方法来解决。为此，研究者们提出了一类基于统计力学的模拟退火算法。

模拟退火算法主要利用了自然界中一个极为普遍的规律：在热扰动趋向于 0 的时候，一个系统将会停留在它能量最小的状态，即基态。在有限的热扰动下，系统处在基态以及附近的概率也会占较大的部分。根据类比，可以将一个待优化的系统视为一个力学系统，其能量由目标函数给定，而参数空间的点则对应系统不同的状态，先给定系统一个有限的温度，利用 Metropolis 算法^{[115][116]}提供的转移概率，在参数空间内生成一个遍历的马尔科夫链，然后每隔一定的步数以较慢的速度减小系统的温度，使得最后的参数依概率的方式收敛到目标函数最小对应的构型^[117]。模拟退火算法可以解决最一般的优化问题，对于 TSM 问题，虽然不能确保每次都能够收敛到最优解，但最终的结果一般都能够合理的分布在最优解的临近处。然而，虽然模拟退火算法具有一定的普适性，但模拟退火速度的选择没有一个较好的选取规则，需要通过实际问题进行不断尝试得到，退火速度过慢会导致算法收敛速度过慢，而退火速度过快，则容易陷入局部最优解。

为此，1997 年，Storn 和 Price^[108]提出了一类微分进化算法（Differential Evolution，或者简称为 DE）。该算法模拟了生物种群进化的过程，主要包括初始化、变异、交叉遗传和选择四步，它主要通过事先给定参数空间的范围，处理连续参数空间内的函数最优化问题。算法的参数选取均有相应的经验法则，可以有效避免陷入局部最优的问题。其中，参数选择的数学收敛性问题在 2002 年被解决^[118]。研究发现，算法的收敛速度随着参数空间维数的增加增长较慢，计算效率高。因此，Yu 等人^[99]在 2016 年利

用微分进化算法对 BWBN 模型进行了参数识别，得到了很好的识别效果。但是 Yu 等人只针对剪切失效型的钢筋混凝土柱进行参数识别，而没有对弯剪失效和弯曲失效型柱进行进一步的分析。

本节利用 DE 算法，针对 3 种不同的失效模式，基于 BWBN 的压弯耦合模型，识别其中的待定参数。

4.3.1 参数识别问题阐述

BWBN 模型的待定参数识别问题，可以归结为一个最优化问题，即需要寻找一组最优的参数向量 $\mathbf{p} = [A, \alpha, \beta, \gamma, n, \delta_\eta, \delta_\nu, \zeta_s, p, q, \psi, \delta_\psi, \lambda]^T$ ，使得该参数向量确定的恢复力-位移关系和试验获得的恢复力-位移关系最为接近。因此，记试验第 i 步的恢复力为 $F_{exp}(t_i)$ ，滞回模型确定的第 i 步恢复力为 $F_{hyst}(t_i)$ ，所有时间步内的恢复力分别构成试验恢复力向量 \mathbf{F}_{exp} 和滞回模型恢复力向量 \mathbf{F}_{hyst} ，定义这两个向量的距离为

$$d(\mathbf{F}_{exp}, \mathbf{F}_{hyst}(\mathbf{p})) = \|\mathbf{F}_{exp} - \mathbf{F}_{hyst}\|_2^2 = \sum_i (F_{exp}(t_i) - F_{hyst}(t_i))^2 \quad (4.32)$$

此距离函数即为该优化问题的目标函数（损失函数），使得这个距离最小的参数向量即为待定的最优向量 $\hat{\mathbf{p}}$ 。

$$\hat{\mathbf{p}} = \arg \min_{\mathbf{p}} d(\mathbf{F}_{exp}, \mathbf{F}_{hyst}(\mathbf{p})) \quad (4.33)$$

4.3.2 微分进化算法简介

DE 算法通过模拟物种进化过程，采用初始化种群、变异、交叉、选择四个步骤使参数往最优方向不断搜索、演化。Yu 等人^[99]对 DE 算法的实现进行了详细的介绍。该算法需要确定 4 个关键参数，根据 Storn 提出的经验法则^[108]，令 DE 算法的初始化种群数 $N_p = 70$ ，权重系数 $F = 0.6$ ，交叉互换概率 $C_R = 0.6$ ，最大迭代数 $G_{max} = 200$ 。此外，若参数的搜索范围过宽，DE 算法可能会落入局部最优，为使算法获得较好的收敛性，需要对参数的范围进行合理的控制。根据 Ma 等人^[119]的研究，认为 BWBN 模型的 13 个待定参数并不是相互独立的，其中任意一个参数都可看做是冗余参数。不失一般性，令参数 $A = 1$ 。另外，Yu 等人^[99]的分析结果表明，参数 n 也可以固定为 1。因此，可以调节的参数个数变为 11 个。根据现有的研究经验^[119]，并结合基本的力学常识，确定这些可调参数的搜索范围分别为： $\alpha \in (0, 1), \beta \in (0.5, 1.5), \gamma \in (-0.5, 0.5), \delta_\eta \in (0, 0.6), \delta_\nu \in (0, 0.1), \zeta_s \in (0, 2), p \in (0, 2), q \in (-1, 1), \psi \in (0, 2), \delta_\psi \in (0, 2), \lambda \in (0, 2)$ 。

利用 DE 算法识别基于 BWBN 的压弯耦合模型的 11 个待定参数的流程如下所述，流程图，如图 4.13 所示：

1. 设定 DE 算法的基本参数，包括初始化种群数 N_p ，权重系数 F ，交叉互换概率 C_R ，最大迭代数 G_{max} 。同时，设定变异和交叉的方式。

2. 设定 11 个待优化参数的搜索上下界，并在此范围内随机生成初始化种群目标个体。
3. 根据基于 BWBN 的压弯耦合模型，按式 (4.32) 计算每个目标个体对应的目标函数，并确定种群中最优的目标个体。
4. 利用变异算符按照第 1 步定义的变异方式对种群中的目标个体进行变异操作，得到变异个体。
5. 利用交叉算符，对目标个体和变异个体进行混合，产生候选个体。
6. 通过“贪婪”方式进行选择，将变异和交叉产生的候选个体与父代目标个体进行比较，选出适应度较好的个体进入下一代。
7. 判断是否达到最大迭代次数 G_{\max} ，如果达到 G_{\max} 则退出此流程，如果尚未达到 G_{\max} 则重复 4-6 步骤。

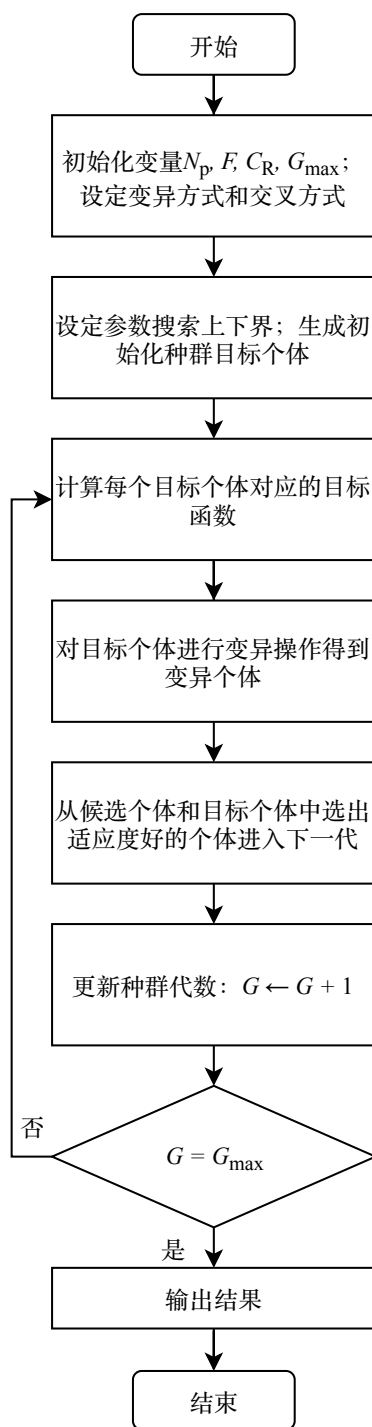


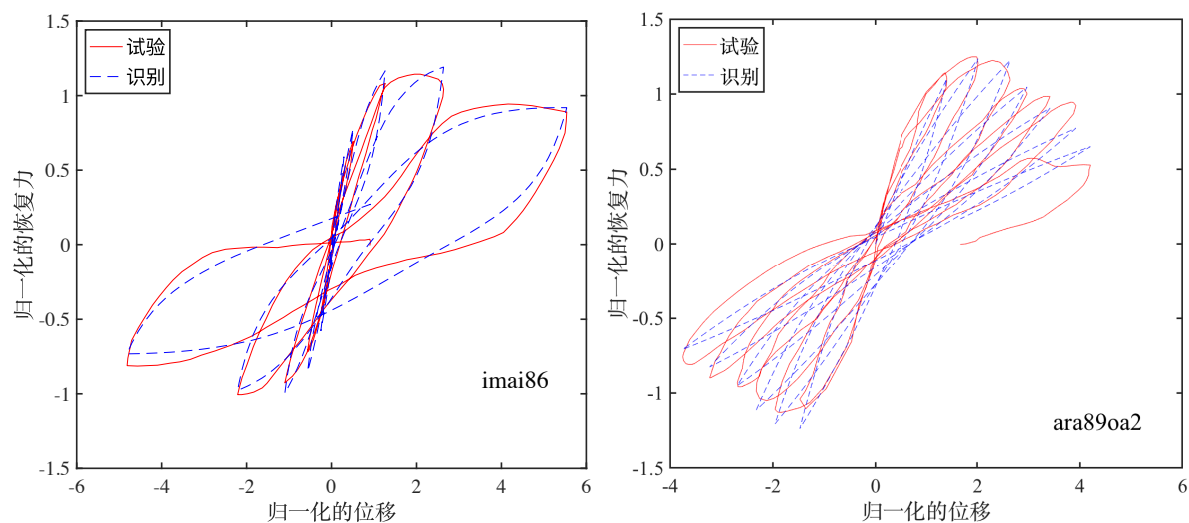
图 4.13 DE 算法流程图

4.3.3 参数识别结果讨论

参数识别采用的试验数据库仍然为 2.2 节介绍的 PEER 中心数据库，该数据库包含了 251 条矩形截面钢筋混凝土柱的试验数据^[41]。除了在 2.2 节介绍的基本设计参数之外，该数据库还提供了每个试件的拟静力循环加载试验曲线。这些曲线提供了试验得到的恢复力-位移关系，一般由几百个到几千个数据点组成，只有少数试验的恢复力-位移曲线包含了几万个数据点。对于一条试验数据，数据点越多，滞回曲线识别的效

率就越低，因此丢弃这些数据点过多的试验数据：Pujol 在 2002 年的 14 个试件。由此得到的数据库剩下 237 条试验数据，其中包括 18 条剪切失效数据、36 条弯剪失效数据、183 条弯曲失效数据。需要注意的是，在 BWBN 模型中，由式 (4.10) 定义的滞回耗能值会随位移以及恢复力单位选取的不同而发生变化，而在利用此滞回耗能的其他表达式中，也未出现可以代表某一试件耗能能力的自然单位。与此同时，还应该注意，即使是在相同的单位制下，随着构件几何构型和材料性质的变化，累计滞回耗能值会有很大的离散性。为解决这些问题，需要对恢复力-位移关系进行无量纲化处理。无量纲化处理的具体方法并不唯一，但用不同的方法得到的识别结果差异并不明显，因此本文采用传统的处理手段：通过选取滞回曲线外包络线上 0.8 倍的最大恢复力 $F_{0.8}$ 及其对应的位移 $u_{0.8}$ 作为恢复力-位移关系的两个自然单位。这样的无量纲化方法在先前的研究中也采用^[99]。

对上述无量纲化后的 18 条剪切失效、36 条弯剪失效和 183 条弯曲失效数据采用 DE 算法进行识别，在最后得到的结果中各选 4 条数据展示，如图 4.14 – 4.16 所示。这些识别结果对应的 BWBN 待定参数最优解，如表 4.1 所示。从识别结果和试验结果的对比可以看出，DE 算法可以很好地识别基于 BWBN 的压弯耦合模型的待定参数。与弯剪失效和弯曲失效柱相比，剪切失效柱的刚度退化和强度退化系数数值更大，代表剪切失效柱的刚度退化和强度退化效应更加严重。






图 4.14 剪切失效柱识别结果




图 4.15 弯剪失效柱识别结果

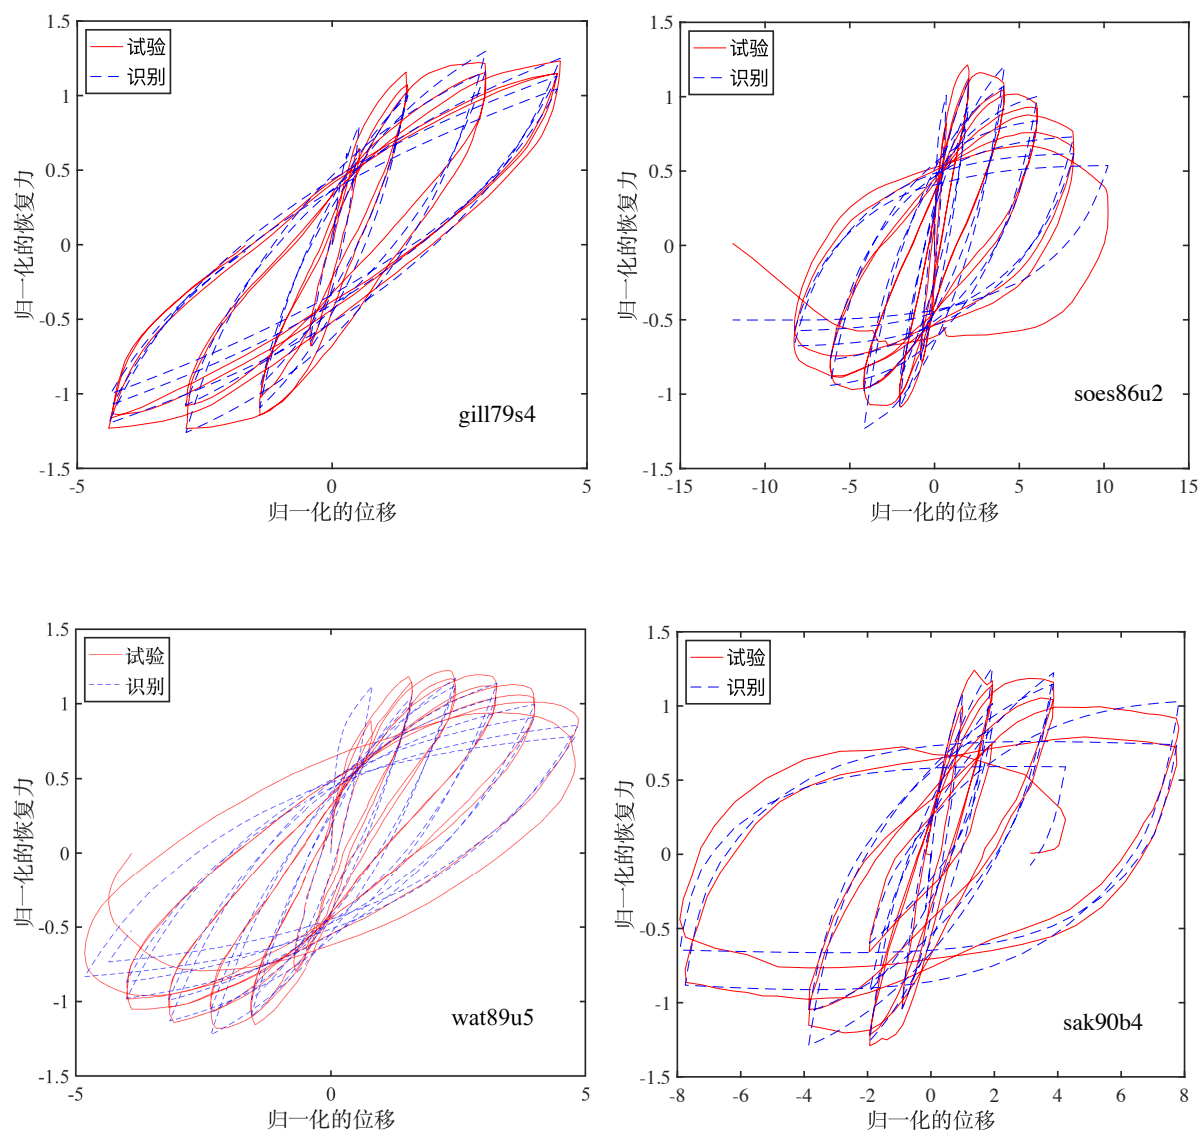


图 4.16 弯曲失效柱识别结果

表 4.1 部分识别结果

文件名	BWBN 待定参数										
	α	β	γ	δ_η	δ_ν	ζ_s	p	q	ψ	δ_ψ	λ
imai86	01.50E-06	0.63	-0.27	0.20	0.05	0.69	2.00	-0.11	0.26	0.00	2.00
ara89oa2	4.36E-02	0.50	-0.50	0.35	0.10	1.84	0.05	-0.08	1.98	1.99	2.00
ly3cmh18	6.35E-05	0.80	-0.39	0.03	0.05	0.95	1.57	-0.71	1.29	0.01	1.80
abouse3	4.39E-05	0.50	-0.34	0.06	0.02	0.79	1.96	-0.02	0.78	0.00	0.67
ono060c	2.79E-06	0.62	-0.29	0.00	0.09	0.76	0.57	-0.24	0.21	0.01	1.78
ly2clh18	7.69E-05	0.52	-0.42	0.00	0.01	0.91	2.00	-0.23	1.99	0.08	1.86
zho22309	1.32E-02	0.54	-0.17	0.00	0.02	0.75	0.38	-0.15	0.80	0.06	0.00
nag1932	5.09E-05	0.50	-0.27	0.13	0.10	0.36	2.00	-0.20	1.90	0.00	0.49
gill79s4	3.08E-02	0.81	-0.24	0.04	0.02	0.73	2.00	0.27	0.37	0.31	2.00
soes86u2	2.17E-06	0.50	-0.15	0.01	0.01	0.93	2.00	0.93	2.00	0.26	1.89
wat89u5	2.82E-04	0.50	-0.06	0.01	0.00	0.90	2.00	0.90	2.00	1.26	0.40
sak90b4	1.49E-04	0.50	-0.29	0.00	0.04	0.86	2.00	1.00	2.00	0.11	2.00

不同失效模式下，基于 BWBN 模型的压弯耦合滞回模型参数统计数字特征如表 4.2 – 4.4 所示。可以看到，参数 α 的分布集中在 0 附近，数量级大体在 $10^{-7} \sim 10^{-2}$ 之间；剪切失效柱参数 β 的 25%、50%和 75%分位数均为 0.50，所以对于剪切失效柱，参数 β 集中在 0.50 附近；弯曲失效柱的参数 β 也具有类似的特征，但 75%分位数为 0.53，因此集中程度没有剪切失效柱严重；而弯剪失效柱的参数 β 取值变化较大，25%、50%和 75%分位数分别为 0.50、0.57 和 0.77；三种失效模式柱的参数 γ 分布差异较小；对于刚度退化和强度退化系数，从各个分位数来看，剪切失效柱的取值最小，弯曲失效柱的取值最大，弯剪失效柱介于剪切失效和弯曲失效之间；对于控制捏拢行为的 6 个参数，剪切失效型柱的 ζ_s 均值最大，弯曲失效柱其次，最后是弯剪失效柱。由此可见，弯曲失效柱实际上也有较为明显的捏拢效应；其余 5 个参数的变化规律不明显，主要是由于这 5 个参数对滞回模型影响的敏感性较小^[119]。

表 4.2 剪切失效柱的模型参数统计数字特征

统计数字特征 (18 条数据)	BWBN 待定参数										
	α	β	γ	δ_η	δ_v	ζ_s	p	q	ψ	δ_ψ	λ
均值	1.97E-02	0.55	-0.28	0.17	0.05	1.16	1.29	-0.08	0.76	0.72	1.14
标准差	4.08E-02	0.10	0.21	0.19	0.03	0.58	0.83	0.35	0.68	0.89	0.77
25%分位数	8.40E-07	0.50	-0.42	0.04	0.02	0.76	0.42	-0.27	0.28	0.00	0.68
50%分位数	5.33E-05	0.50	-0.30	0.08	0.05	0.86	1.75	-0.02	0.67	0.06	1.15
75%分位数	1.64E-02	0.50	-0.25	0.25	0.08	1.90	2.00	0.08	1.17	1.64	1.95

表 4.3 弯剪切失效柱的模型参数统计数字特征

统计数字特征 (36 条数据)	BWBN 待定参数										
	α	β	γ	δ_η	δ_v	ζ_s	p	q	ψ	δ_ψ	λ
均值	1.18E-02	0.71	-0.26	0.03	0.03	0.78	1.53	0.11	1.08	0.48	1.14
标准差	3.10E-02	0.31	0.19	0.04	0.03	0.18	0.62	0.43	0.78	0.67	0.80
25%分位数	2.54E-06	0.50	-0.46	0.00	0.00	0.70	0.90	-0.19	0.22	0.01	0.41
50%分位数	1.07E-03	0.57	-0.24	0.01	0.01	0.82	2.00	0.13	1.29	0.18	1.21
75%分位数	1.20E-02	0.77	-0.13	0.03	0.03	0.93	2.00	0.29	1.83	0.66	1.99

表 4.4 弯曲失效柱的模型参数统计数字特征

统计数字特征 (183 条数据)	BWBN 待定参数										
	α	β	γ	δ_η	δ_v	ζ_s	p	q	ψ	δ_ψ	λ
均值	1.56E-02	0.59	-0.21	0.02	0.01	0.88	1.72	0.17	1.50	0.48	1.58
标准差	9.31E-02	0.19	0.20	0.06	0.02	0.16	0.53	0.58	0.61	0.64	0.56
25%分位数	5.76E-07	0.50	-0.35	0.00	0.00	0.86	1.85	-0.16	1.09	0.05	1.27
50%分位数	2.82E-04	0.50	-0.24	0.00	0.01	0.91	2.00	0.23	1.75	0.19	1.89
75%分位数	4.07E-03	0.53	-0.11	0.01	0.01	0.95	2.00	0.60	2.00	0.47	2.00

4.4 本章小结

本章首先介绍了 BWBN 模型的微分方程形式，分析了各个模型参数对滞回曲线形状的影响；然后引入了 BWBN 模型的积分形式，证明了 BWBN 模型积分形式和微分形式的等价性；在此积分形式的基础上，引入了压弯耦合效应，由此推导出考虑压弯耦合效应的 BWBN 模型微分方程形式。常轴力与变轴力下滞回曲线的对比结果表明，基于 BWBN 的压弯耦合滞回模型可以有效地考虑轴力变化对构件造成的损伤，反映出钢筋混凝土柱轴压力和弯曲应力的相互作用。

为了识别这个滞回模型的模型参数，我们接着介绍了若干优化算法以及它们的优缺点，并从中选出 DE 算法；然后给出该优化问题的目标函数定义，确定 DE 算法关键参数的取值，以及压弯耦合滞回模型参数的合理搜索范围；最后利用 DE 算法对目标函数进行优化。研究表明，微分进化算法可以对基于 BWBN 模型的压弯耦合滞回模型进行很好的识别，识别得到的恢复力-位移曲线与试验得到的曲线符合很好，不仅可以对延性较好的弯曲失效型柱的滞回行为进行模拟，而且可以对刚度退化、强度退化和捏拢效应严重的剪切失效型柱进行模拟。

第 5 章 结论和展望

5.1 结论

本文针对钢筋混凝土柱的不同失效模式，采用机器学习算法研究了不同失效模式的分类预测和不同失效模式下滞回曲线的描述方法。首先，将现有的剪切强度和弯曲强度预测公式进行变形，从中提取出 4 个关键的无量纲设计参数作为预测钢筋混凝土柱失效模式的输入参数，利用人工神经网络分类机建立了失效模式的预测模型；然后着重对失效模式原始数据库中存在的偏斜数据问题进行了深入研究，剖析了偏斜数据库影响预测模型结果的两点重要原因，并选用合适的高等采样方法和除噪方法对原始数据库的偏斜数据问题进行了处理，用 AdaBoost 算法建立了失效模式的预测模型；接着基于 BWBN 光滑型滞回模型，建立了压弯耦合模型，显式地考虑了轴力对钢筋混凝土柱滞回行为的影响；最后利用微分进化算法，结合 PEER 数据库，对考虑了压弯耦合效应的滞回模型参数进行了识别。本文得到的主要结论如下：

1. 结合简单的处理偏斜数据方法，人工神经网络预测机可以较好地预测钢筋混凝土柱的失效模式。神经网络预测模型的输入参数敏感性分析表明，在纵筋配筋指标和箍筋配筋指标空间，决策边界可以近似地用一条直线表示，失效模式线性可分；而在剪跨比和轴压比空间，决策边界更加复杂，在高轴压比下，随着剪跨比的变化，会出现类似于 Kani 剪切谷的模式。
2. 偏斜数据集对机器学习分类机预测能力产生不利影响的两个主要因素为：数据分类的不平衡和数据分类的重叠。利用 ENN 算法对原始的数据库进行除噪，可以解决数据分类的重叠问题；结合 OSS 算法进行欠采样和 SVM-SMOTE 算法进行过采样，可以解决数据分类的不平衡问题；联合采用 AdaBoost 算法建立失效模式预测模型，可以获得更高的分类精度。研究表明，利用处理过后的数据库建立得到的预测模型，可以在不丢弃现有数据信息的同时，解决偏斜数据集对预测模型产生的不利影响，预测模型的测试集精度与不进行数据库前处理相比，有很大的提升。
3. 钢筋混凝土柱的压弯耦合效应可以基于 BWBN 模型的积分表示形式，推导出对应的微分演化方程。建立的考虑压弯耦合效应的 BWBN 模型，不仅可以考虑传统 P-M 曲线的影响，而且可以引入了轴力变化率对滞回曲线的影响。轴力的大小和轴力的变化率分别影响原始 BWBN 模型的两个形状参数，进而影响滞回曲线的形状。
4. 微分进化算法能够很好的识别考虑压弯耦合的 BWBN 模型参数。针对不同的失效模式滞回曲线，考虑压弯耦合的 BWBN 模型不仅可以较好地描述延性较

好的弯曲失效模式柱的滞回曲线，而且可以对刚度退化、强度退化和捏拢效应特别严重的剪切失效型柱的滞回行为进行模拟。微分进化算法结合基于 BWBN 模型的压弯耦合滞回模型，对三种不同失效模式下的钢筋混凝土柱滞回曲线都有良好的识别效果。

5.2 展望

本文的工作还存在若干不足之处，下一步工作的展望如下：

1. 本文选择了 4 个无量纲设计参数作为失效模式预测机器学习模型的输入参数，但是这 4 个参数不一定可以完全反应钢筋混凝土柱失效模式之间的相互转换，还可以对输入参数的选择进行进一步的深入研究。
2. 利用主成分分析法对钢筋混凝土柱失效模式数据进行可视化分析的结果表明，不同失效模式之间的分类重叠突出，尤其是弯剪失效与弯曲失效之间、弯剪失效和剪切失效之间的分类重叠非常严重。这表明在失效模式的标定上，本身就存在很大的离散性和不确定性。因此，有必要对钢筋混凝土柱失效模式的标定本身开展进一步的研究，即如何从结构试验观测结果中有效地定义钢筋混凝土柱的失效模式。
3. 高等采样方法是在剪切失效模式柱的试验数据在极度稀缺条件下的权宜之计，为了建立更加准确有效的机器学习预测模型，需要有更多的剪切失效模式柱的试验数据作为支撑。
4. 本文提出的基于 BWBN 模型的压弯耦合滞回模型，仍然是水平向一维的恢复力-位移关系，人为地将 P-M 关系引入到一维的恢复力-位移关系中。为了更加合理、灵活地考虑轴力对水平向恢复力-位移关系的影响，可以进一步建立竖向和水平向相互耦合的恢复力-位移关系。

附录 人工神经网络分类机采用的数据库

编号	试验者	构件名称	剪跨比 α_r	轴压比 α_n	纵筋配 筋指标 α_l	箍筋配 筋指标 α_v
剪切失效						
1	Nagasaka (1982)	HPRC10-63	1.50	0.17	0.2181	0.1274
2	Imai and Yamamoto (1986)	No.1	1.65	0.07	0.3121	0.0397
3	Zhou et al. (1987)	No.104-08	1.00	0.80	0.3823	0.1976
4	Zhou et al. (1987)	No.114-08	1.00	0.80	0.3823	0.1976
5	Zhou et al. (1987)	No.124-08	1.00	0.80	0.3823	0.2936
6	Arakawa et al. (1989)	OA2	1.25	0.18	0.3347	0.0157
7	Arakawa et al. (1989)	OA5	1.25	0.45	0.3225	0.0151
8	Wight and Sozen (1973)	No.25.033E	2.87	0.07	0.3617	0.0308
9	Umehara and Jirsa (1982)	CUS	1.11	0.16	0.3803	0.0356
10	Umehara and Jirsa (1982)	CUW	1.98	0.16	0.3803	0.0178
11	Umehara and Jirsa (1982)	2CUS	1.11	0.27	0.3161	0.0542
12	Bett et al. (1985)	No.1-1	1.50	0.10	0.3770	0.0125
13	Lynn et al. (1996)	3CLH18	3.22	0.09	0.3728	0.0104
14	Lynn et al. (1996)	3CMH18	3.22	0.26	0.3634	0.0101
15	Lynn et al. (1996)	3CMD12	3.22	0.26	0.3634	0.0246
16	Lynn et al. (1996)	3SLH18	3.22	0.09	0.3728	0.0104
17	Aboutaha et al. (1999)	SC3	2.67	0.00	0.3726	0.0183
18	Aboutaha et al. (1999)	SC9	1.33	0.00	0.5100	0.0200
19	Brown and Jirsa (1971)	rv106635	5.00	0.00	0.2041	0.0617
20	Brown and Jirsa (1971)	rv108832	5.00	0.00	0.3648	0.1542
21	Brown and Jirsa (1971)	rv108834	2.50	0.00	0.3648	0.0771
22	Brown and Jirsa (1971)	rv108835	5.00	0.00	0.3648	0.0617
23	Brown and Jirsa (1971)	rv58834	2.50	0.00	0.3648	0.0771
24	Brown and Jirsa (1971)	rv58835	5.00	0.00	0.3648	0.0617
25	Otani et al. 2003	S6EW	2.50	0.00	0.2350	0.0154
弯剪失效						
26	Ohue et al. (1985)	2D16RS	2.00	0.14	0.2318	0.0474
27	Ohue et al. (1985)	4D13RS	2.00	0.15	0.3279	0.0507
28	Ono et al. (1989)	CA025C	1.50	0.26	0.2980	0.1486
29	Ono et al. (1989)	CA060C	1.50	0.62	0.2980	0.1486
30	Lynn et al. (1998)	2CLH18	3.22	0.07	0.1940	0.0085
31	Lynn et al. (1998)	2CMH18	3.22	0.28	0.2518	0.0110
32	Lynn et al. (1996)	2SLH18	3.22	0.07	0.1940	0.0085
33	Lynn et al. (1996)	3SMD12	3.22	0.28	0.3933	0.0267
34	Sezen and Moehle (2002)	No.1	3.22	0.15	0.5085	0.0451
35	Sezen and Moehle (2002)	No.2	3.22	0.61	0.5085	0.0451
36	Sezen and Moehle (2002)	No.4	3.22	0.15	0.4922	0.0437

37	Zhou et al. (1985)	No.806	1.00	0.60	0.1841	0.0412
38	Zhou et al. (1985)	No.1007	1.00	0.70	0.1749	0.0391
39	Zhou et al. (1985)	No.1309	1.00	0.90	0.1813	0.0405
40	Zhou et al. (1987)	No.204-08	2.00	0.80	0.3588	0.1855
41	Zhou et al. (1987)	No.223-09	2.00	0.90	0.3588	0.2755
42	Zhou et al. (1987)	No.302-07	3.00	0.70	0.2629	0.1359
43	Zhou et al. (1987)	No.312-07	3.00	0.70	0.2629	0.1359
44	Zhou et al. (1987)	No.322-07	3.00	0.70	0.2629	0.2019
45	Nagasaka (1982)	HPRC19-32	1.50	0.35	0.2244	0.2293
46	Xiao and Martirosyan (1998)	HC4-8L16- T6-0.1P	2.00	0.10	0.1459	0.0392
47	Xiao and Martirosyan (1998)	HC4-8L16- T6-0.2P	2.00	0.19	0.1459	0.0392
48	Amitsu et al. (1991)	CB060C	1.16	0.74	0.3924	0.0805
49	Wight and Sozen (1973)	No.40.033aE	2.87	0.12	0.3502	0.0298
50	Wight and Sozen (1973)	No.40.033aW	2.87	0.12	0.3502	0.0298
51	Wight and Sozen (1973)	No.40.048E	2.87	0.15	0.4656	0.0661
52	Wight and Sozen (1973)	No.40.048W	2.87	0.15	0.4656	0.0661
53	Wight and Sozen (1973)	No.40.033E	2.87	0.11	0.3617	0.0308
54	Wight and Sozen (1973)	No.40.033W	2.87	0.11	0.3617	0.0308
55	Wight and Sozen (1973)	No.25.033W	2.87	0.07	0.3617	0.0308
56	Wight and Sozen (1973)	No.40.067E	2.87	0.11	0.3638	0.0723
57	Wight and Sozen (1973)	No.40.067W	2.87	0.11	0.3638	0.0723
58	Wight and Sozen (1973)	No.40.147E	2.87	0.11	0.3627	0.1419
59	Wight and Sozen (1973)	No.40.147W	2.87	0.11	0.3627	0.1419
60	Wight and Sozen (1973)	No.40.092E	2.87	0.11	0.3627	0.0852
61	Wight and Sozen (1973)	No.40.092W	2.87	0.11	0.3627	0.0852
弯曲失效						
62	Muguruma et al. (1989)	BL-2	2.50	0.42	0.1311	0.0454
63	Tanaka and Park (1990)	No.3 No.10-3-	4.00	0.20	0.2907	0.1379
64	Pujol (2002)	2.25S	2.25	0.10	0.4051	0.1080
65	Matamoros et al. (1999)	C5-40S	3.00	0.36	0.2904	0.1351
66	Watson and Park (1989)	No.6	4.00	0.50	0.1789	0.0291
67	Matamoros et al. (1999)	C10-05S	3.00	0.05	0.1625	0.0584
68	Saatcioglu and Ozcebe (1989)	U4	2.86	0.15	0.4394	0.1322
69	Galeota et al. (1996)	BA4	4.56	0.20	0.0812	0.0430
70	Paultre and Legeron (2000)	No.10013040	6.56	0.37	0.0930	0.0345
71	Soesianawati et al. (1986)	No.4	4.00	0.30	0.1684	0.0191
72	Zahn et al. (1986)	No.8	4.00	0.39	0.1657	0.0988
73	Paultre and Legeron (2000)	No.1006040	6.56	0.39	0.0987	0.0792
74	Gill et al. (1979)	No.4	2.18	0.60	0.2856	0.1664
75	Bechtoula, Kono, Arai and Watanabe (2002)	D1N60	2.50	0.60	0.2979	0.0645
76	Bayrak and Sheikh (1996)	AS-5HT	6.04	0.45	0.1151	0.1132

77	Galeota et al. (1996)	CB3	4.56	0.30	0.3241	0.0865
78	Soesianawati et al. (1986)	No.3	4.00	0.30	0.1531	0.0347
79	Zhou et al. (1987)	No.214-08	2.00	0.80	0.3588	0.1855
80	Park and Paulay (1990)	No.9	2.97	0.10	0.3019	0.1202
81	Bayrak and Sheikh (1996)	ES-8HT	6.04	0.47	0.1146	0.0852
82	Saatcioglu and Grira (1999)	BG-9	4.70	0.46	0.4127	0.0870
83	Galeota et al. (1996)	CA3	4.56	0.20	0.0812	0.0865
84	Wehbe et al. (1998)	B2	3.83	0.23	0.3539	0.0548
85	Galeota et al. (1996)	CB4	4.56	0.30	0.3241	0.0865
86	Galeota et al. (1996)	AA3	4.56	0.20	0.0812	0.0290
87	Saatcioglu and Grira (1999)	BG-6	4.70	0.46	0.3218	0.1794
88	Azizinamini et al. (1988)	NC-4	3.00	0.31	0.2140	0.0805
89	Atalay and Penzien (1975)	No.10	5.50	0.27	0.1826	0.0448
90	Watson and Park (1989)	No.9	4.00	0.70	0.1789	0.1771
91	Ohno and Nishioka (1984)	L2	4.00	0.03	0.2073	0.0393
92	Muguruma et al. (1989)	AH-2	2.50	0.63	0.1772	0.1479
93	Zahn et al. (1986)	No.7	4.00	0.22	0.2348	0.1103
	Thomsen and Wallace					
94	(1994)	D3	3.92	0.20	0.1637	0.0709
95	Watson and Park (1989)	No.7	4.00	0.70	0.1704	0.0953
96	Sugano (1996)	UC15L	2.00	0.35	0.0619	0.1533
97	Matamoros et al. (1999)	C10-10S	3.00	0.10	0.1632	0.0759
98	Bayrak and Sheikh (1996)	AS-6HT	6.04	0.46	0.1149	0.1340
	Thomsen and Wallace					
99	(1994)	C3	3.92	0.20	0.1425	0.1095
100	Galeota et al. (1996)	BB2	4.56	0.20	0.3241	0.0968
101	Bayrak and Sheikh (1996)	ES-1HT	6.04	0.50	0.1625	0.0893
		No.10-2-				
102	Pujol (2002)	2.25S	2.25	0.08	0.3180	0.0848
103	Paultre and Legeron (2000)	No.10013015	6.56	0.14	0.1023	0.0355
104	Atalay and Penzien (1975)	No.4S1	5.50	0.10	0.2534	0.0487
105	Galeota et al. (1996)	AA1	4.56	0.30	0.0812	0.0290
106	Wehbe et al. (1998)	A2	3.83	0.24	0.3656	0.0425
107	Pujol (2002)	No.10-3-1.5N	2.25	0.09	0.3457	0.1370
108	Tanaka and Park (1990)	No.6	3.00	0.10	0.1996	0.0762
	Bechtoula, Kono, Arai and					
109	Watanabe (2002)	L1D60	2.00	0.57	0.1673	0.1123
110	Saatcioglu and Grira (1999)	BG-4	4.70	0.46	0.3926	0.0889
111	Tanaka and Park (1990)	No.4	4.00	0.20	0.2907	0.1379
	Xiao and Martirosyan	HC4-8L19-				
112	(1998)	T10-0.1P	2.00	0.10	0.2382	0.1054
113	Wehbe et al. (1998)	B1	3.83	0.09	0.3539	0.0548
	Saatcioglu and Ozcebe					
114	(1989)	U3	2.86	0.14	0.3966	0.0810
115	Mo and Wang 2000	C3-1	3.50	0.11	0.4029	0.1010
	Saatcioglu and Ozcebe					
116	(1989)	U6	2.86	0.13	0.3761	0.0968

117	Matamoros et al. (1999)	C10-20N	3.00	0.21	0.1686	0.0784
118	Kanda et al. (1988)	85PDC-2	3.00	0.11	0.2172	0.0725
119	Paultre et al. (2001)	No.1008040	6.56	0.37	0.0920	0.1108
120	Pujol (2002)	No.10-1- 2.25N	2.25	0.08	0.3041	0.0811
121	Thomsen and Wallace (1994)	B3	3.92	0.20	0.1239	0.0626
122	Thomsen and Wallace (1994)	A1	3.92	0.00	0.1234	0.0479
123	Atalay and Penzien (1975)	No.2S1	5.50	0.09	0.1949	0.0437
124	Xiao and Martirosyan (1998)	HC4-8L16- T10-0.1P	2.00	0.10	0.1459	0.0931
125	Galeota et al. (1996)	CA1	4.56	0.20	0.0812	0.0865
126	Bechtoula, Kono, Arai and Watanabe (2002)	L1N60	2.00	0.57	0.1673	0.1123
127	Matamoros et al. (1999)	C5-00N	3.00	0.00	0.2914	0.1355
128	Muguruma et al. (1989)	BL-1	2.50	0.25	0.1311	0.0454
129	Takemura and Kawashima (1997)	JSCE-4	3.11	0.03	0.1598	0.0205
130	Thomsen and Wallace (1994)	B1	3.92	0.00	0.1274	0.0643
131	Ang et al. (1981)	No.4	3.00	0.21	0.2579	0.0974
132	Galeota et al. (1996)	AA2	4.56	0.30	0.0812	0.0290
133	Atalay and Penzien (1975)	No.11	5.50	0.28	0.1909	0.0734
134	Thomsen and Wallace (1994)	C1	3.92	0.00	0.1727	0.1327
135	Gill et al. (1979)	No.3	2.18	0.42	0.3137	0.1055
136	Mo and Wang 2000	C2-1	3.50	0.11	0.4204	0.1090
137	Matamoros et al. (1999)	C5-00S	3.00	0.00	0.2919	0.1358
138	Ang et al. (1981)	No.3	3.00	0.38	0.2732	0.1532
139	Saatcioglu and Grira (1999)	BG-10	4.70	0.46	0.4127	0.1794
140	Pujol (2002)	No.10-3-3N	2.25	0.10	0.3712	0.0742
141	Watson and Park (1989)	No.5	4.00	0.50	0.1746	0.0635
142	Bayrak and Sheikh (1996)	AS-7HT	6.04	0.45	0.1148	0.0632
143	Bayrak and Sheikh (1996)	AS-3HT	6.04	0.50	0.1631	0.0936
144	Tanaka and Park (1990)	No.1	4.00	0.20	0.2907	0.1379
145	Atalay and Penzien (1975)	No.5S1	5.50	0.20	0.2378	0.0813
146	Takemura and Kawashima (1997)	JSCE-5	3.11	0.03	0.1607	0.0206
147	Thomsen and Wallace (1994)	D2	3.92	0.20	0.1340	0.0682
148	Saatcioglu and Grira (1999)	BG-7	4.70	0.46	0.3926	0.0870
149	Tanaka and Park (1990)	No.8	3.00	0.30	0.1990	0.0921
150	Atalay and Penzien (1975)	No.12	5.50	0.27	0.1861	0.0434
151	Pujol (2002)	No.20-3-3N	2.25	0.16	0.3049	0.0610
152	Kanda et al. (1988)	85PDC-1	3.00	0.12	0.2443	0.0568
153	Sakai et al. (1990)	B3	2.00	0.35	0.0926	0.0207

154	Sugano (1996)	UC10H	2.00	0.60	0.0619	0.0971
155	Soesianawati et al. (1986)	No.1	4.00	0.10	0.1448	0.0352
156	Paultre and Legeron (2000)	No.1006025	6.56	0.28	0.0991	0.0779
157	Galeota et al. (1996)	AB4	4.56	0.20	0.3241	0.0290
158	Sakai et al. (1990)	B4	2.00	0.35	0.0926	0.0566

参考文献

- [1] 韩本毅. 中国城市化发展进程及展望 [J]. 西安交通大学学报: 社会科学版. 2011, 31(3): 18-22.
- [2] 上海市统计局. 上海统计年鉴 [M]. 中国统计出版社, 2018.
- [3] 周一航, 刘刚, 刘璐, 周硕文. 我国混凝土结构设计规范基本构造措施的发展与展望 [J]. 建筑科学. 2019(1): 22.
- [4] Pan Z, Li B. Truss-arch model for shear strength of shear-critical reinforced concrete columns [J]. *Journal of Structural Engineering*, 2012, 139(4): 548-60.
- [5] Elwood KJ. Modelling failures in existing reinforced concrete columns [J]. *Canadian Journal of Civil Engineering*, 2004, 31(5): 846-59.
- [6] Sezen Halil, Chowdhury T. Hysteretic model for reinforced concrete columns including the effect of shear and axial load failure [J]. *Journal of structural engineering*, 2009, 135(2): 139-46.
- [7] 清华大学土木工程结构专家组, 西南交通大学土木工程结构专家组, 北京交通大学土木工程结构专家组, 叶列平, 陆新征. 汶川地震建筑震害分析 [J]. *建筑结构学报*, 2008(04): 1-9.
- [8] 罗开海, 黄世敏. 《建筑抗震设计规范》发展历程及展望 [J]. *工程建设标准化*. 2015(7): 73-8.
- [9] 建工业与民用建筑抗震设计规范: TJ11-78 [S]. 中国建筑工业出版社, 1979.
- [10] 建筑抗震设计规范: GBJ11-89 [S]. 中国建筑工业出版社, 1989.
- [11] 建筑抗震设计规范(GB 50011—2001) [S]. 中国建筑工业出版社, 2002.
- [12] 建筑抗震设计规范(GB 50011-2010) [S]. 中国建筑工业出版社, 2010.
- [13] 邵楠. 青海玉树地震建筑震害浅析 [J]. *工程抗震与加固改造*. 2011, 33(4): 136-40.
- [14] 王成. 玉树 4·14 地震建筑结构震害调查与分析 [J]. *建筑结构*. 2010(8): 106-9.
- [15] 郑建军, 廖永石, 杜雷, 牛金亮. 青海玉树地震民用建筑震害调查和分析 [J]. *建筑结构*. 2013(S1): 1051-4.
- [16] Setzler EJ, Sezen H. Model for the lateral behavior of reinforced concrete columns including shear deformations [J]. *Earthquake Spectra*, 2008, 24(2): 493-511.
- [17] Zhu L, Elwood KJ, Haukaas T. Classification and seismic safety evaluation of existing reinforced concrete columns [J]. *Journal of Structural Engineering*, 2007, 133(9): 1316-1330.
- [18] Ning CL, Feng DC. Probabilistic indicator to classify the failure mode of reinforced-concrete columns [J]. *Magazine of Concrete Research*. 2018, 71(14): 734-48.
- [19] Ning CL, Li B. Probabilistic approach for estimating plastic hinge length of reinforced concrete columns [J]. *Journal of Structural Engineering*. 2015, 142(3): 04015164.
- [20] Ning CL, Li B. Probabilistic development of shear strength model for reinforced concrete squat walls [J]. *Earthquake Engineering & Structural Dynamics*. 2017, 46(6): 877-97.
- [21] Ma Y, Gong JX. Probability Identification of Seismic Failure Modes of Reinforced Concrete Columns based on Experimental Observations [J]. *Journal of Earthquake Engineering*. 2018, 22(10): 1881-99.
- [22] Sengupta P, Li B. Hysteresis modeling of reinforced concrete structures: state of the art [J]. *ACI Structural Journal*, 2017, 114(1): 25.
- [23] Veletsos AS, Newmark NM, Chelapati CV. Deformation spectra for elastic and elastoplastic systems subjected to ground shock and earthquake motions [J]. In *Proceedings of the 3rd world conference on earthquake engineering 1965*, 2: 663-82.

- [24] Clough RW. Effect of stiffness degradation on earthquake ductility requirements [J]. In Proceedings of Japan earthquake engineering symposium 1966.
- [25] Takeda T, Sozen MA, Nielsen NN. Reinforced concrete response to simulated earthquakes [J]. Journal of the Structural Division, 1970, 96(12): 2557-73.
- [26] Haselton CB, Liel AB, Taylor-Lange SC, Deierlein GG. Calibration of Model to Simulate Response of Reinforced Concrete Beam-Columns to Collapse [J]. ACI Structural Journal. 2016, 113(6): 1141-52
- [27] Vecchio FJ, Collins MP. The modified compression-field theory for reinforced concrete elements subjected to shear [J]. ACI J.. 1986, 83(2): 219-31.
- [28] Sezen H, Moehle JP. Bond-slip behavior of reinforced concrete members [J]. In Proceedings of FIB symposium on concrete structures in seismic regions 2003.
- [29] Sezen H, Setzler EJ. Reinforcement slip in reinforced concrete columns [J]. ACI Structural Journal. 2008, 105(3): 280.
- [30] Ozcebe G, Saatcioglu M. Hysteretic shear model for reinforced concrete members [J]. Journal of Structural Engineering. 1989, 115(1): 132-48.
- [31] Saatcioglu M, Alsiwat JM, Ozcebe G. Hysteretic behavior of anchorage slip in R/C members [J]. Journal of Structural Engineering. 1992, 118(9): 2439-58.
- [32] ASCE/SEI 41-13, 2013, Seismic Rehabilitation of Existing Buildings [S], American Society of Civil Engineers Structural Engineering Institute, Reston, VA, 518 pp
- [33] Li YA, Hwang SJ. Prediction of lateral load displacement curves for reinforced concrete short columns failed in shear [J]. Journal of Structural Engineering. 2016, 143(2): 04016164.
- [34] ACI (American Concrete Institute). (2014). Building code requirements for structural concrete (ACI 318-14) and commentary (ACI 318R-14) [S]. ACI Committee 318, Farmington Hills, MI
- [35] Hwang SJ, Lee HJ. Strength prediction for discontinuity regions by softened strut-and-tie model [J]. Journal of Structural Engineering. 2002, 128(12): 1519-26.
- [36] Sezen H, Moehle JP. Seismic tests of concrete columns with light transverse reinforcement [J]. ACI structural journal. 2006, 103(6): 842.
- [37] 混凝土结构设计规范(GB 50010-2010) [S]. 中国建筑工业出版社, 2010
- [38] Sezen H, Moehle JP. Shear strength model for lightly reinforced concrete columns [J]. Journal of Structural Engineering. 2004, 130(11): 1692-703.
- [39] MacGregor JG. Shear strength of reinforced concrete members [J]. Journal of the Structural Division. 1973, Proc Paper.
- [40] Priestley MN, Verma R, Xiao Y. Seismic shear strength of reinforced concrete columns [J]. Journal of structural engineering. 1994, 120(8): 2310-29.
- [41] Berry M, Parrish M, Eberhard M. 2004, PEER Structural Performance Database and User's Manual, Pacific Engineering Research Center, Berkeley, CA, <http://nisee.berkeley.edu/spd>
- [42] Weiss GM. Mining with rarity: a unifying framework [J]. ACM Sigkdd Explorations Newsletter. 2004, 6(1): 7-19.
- [43] Dihoru L and Alessandro B. Seismic Engineering Research Infrastructures for European Synergies (SERIES), University of Trento, 2010.
- [44] Jain AK, Mao J, Mohiuddin KM. Artificial neural networks: A tutorial [J]. Computer. 1996, 29(3): 31-44.
- [45] Lautrup B. Neural networks: computers with intuition [M]. World Scientific; 1990.

- [46] Anderson PW. More is different [J]. *science*. 1972, 177(4047): 393-6.
- [47] Landau LD. On the theory of phase transitions [J]. *Ukr. J. Phys.*. 1937, 11: 19-32.
- [48] Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks [C]. *Advances in neural information processing systems 2012* (pp. 1097-1105).
- [49] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*. 2015, 521(7553): 436
- [50] Alpaydin E. *Introduction to machine learning* [M]. MIT press; 2009 Dec 4.
- [51] Hastie T, Tibshirani R, Friedman J. *The elements of statistical learning: data mining, inference, and prediction* [M]. Springer Science & Business Media; 2009.
- [52] Zhang C, Bengio S, Hardt M, Recht B, Vinyals O. Understanding deep learning requires rethinking generalization. *arXiv preprint arXiv:1611.03530*. 2016.
- [53] Belkin M, Hsu D, Ma S, Mandal S. Reconciling modern machine learning and the bias-variance trade-off. *arXiv preprint arXiv:1812.11118*. 2018.
- [54] Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks [C]. In *Advances in neural information processing systems 2012*: 1097-105.
- [55] Huang Y, Cheng Y, Bapna A, Firat O, Chen D, Chen M, Lee H, Ngiam J, Le QV, Wu Y. Gpipe: Efficient training of giant neural networks using pipeline parallelism [C]. In *Advances in Neural Information Processing Systems 2019*: 103-12.
- [56] Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, Rabinovich A. Going deeper with convolutions [C]. In *Proceedings of the IEEE conference on computer vision and pattern recognition 2015*: 1-9.
- [57] Radford A, Wu J, Child R, Luan D, Amodei D, Sutskever I. Language models are unsupervised multitask learners. *OpenAI Blog*. 2019, 1(8).
- [58] Nakkiran P, Kaplun G, Bansal Y, Yang T, Barak B, Sutskever I. Deep double descent: Where bigger models and more data hurt. *arXiv preprint arXiv:1912.02292*. 2019.
- [59] Mei S, Montanari A. The generalization error of random features regression: Precise asymptotics and double descent curve. *arXiv preprint arXiv:1908.05355*. 2019.
- [60] Goodfellow I, Bengio Y, Courville A. *Deep learning* [M]. MIT press; 2016.
- [61] Koo I, Lee N, Kil RM. Parameterized cross-validation for nonlinear regression models [J]. *Neurocomputing*. 2008, 71(16-18): 3089-95.
- [62] Huang H, Liu Y, Du Y, Perou CM, Hayes DN, Todd MJ, Marron JS. Multiclass distance-weighted discrimination [J]. *Journal of Computational and Graphical Statistics*. 2013, 22(4): 953-69.
- [63] Kani GN. The Riddle of Shear Failure and its Solution [J], *ACI Journal Proceedings*, 1964, 61(4): 441-67.
- [64] Kani GN. Basic facts concerning shear failure [C]. In *Journal Proceedings 1966*, 63(6): 675-92.
- [65] He H, Garcia EA. Learning from imbalanced data [J]. *IEEE Transactions on knowledge and data engineering*. 2009, 21(9): 1263-84.
- [66] Blake C, and Merz C. *UCI Repository of Machine Learning Databases*, 1998. <http://www.ics.uci.edu/~mllearn/MLRepository.html>.
- [67] Batista GE, Prati RC, Monard MC. A study of the behavior of several methods for balancing machine learning training data [J]. *ACM SIGKDD explorations newsletter*. 2004, 6(1): 20-9.
- [68] Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, Blondel M, Prettenhofer P, Weiss R, Dubourg V, Vanderplas J. *Scikit-learn: Machine learning in Python*. *Journal of machine learning research*. 2011;12(Oct): 2825-30.

- [69] Guyon I. Design of experiments of the NIPS 2003 variable selection benchmark [C]. In NIPS 2003 workshop on feature extraction and feature selection 2003 Jul.
- [70] Fernández A, García S, Galar M, Prati RC, Krawczyk B, Herrera F. Learning from Imbalanced Data Sets [M]. Springer; 2018
- [71] Hart P. The condensed nearest neighbor rule (Corresp.) [J]. IEEE transactions on information theory. 1968, 14(3): 515-6.
- [72] Kubat M, Matwin S. Addressing the curse of imbalanced training sets: one-sided selection [C]. In IJML 1997, 97: 179-86.
- [73] Chawla NV, Bowyer KW, Hall LO, Kegelmeyer WP. SMOTE: synthetic minority over-sampling technique [J]. Journal of artificial intelligence research. 2002, 16: 321-57.
- [74] Tomek I. Two modifications of CNN [J]. IEEE Trans. Systems, Man and Cybernetics. 1976, 6: 769-72.
- [75] Wilson DL. Asymptotic properties of nearest neighbor rules using edited data [J]. IEEE Transactions on Systems, Man, and Cybernetics. 1972, 408-21.
- [76] Laurikkala J. Improving identification of difficult small classes by balancing class distribution [C]. In Conference on Artificial Intelligence in Medicine in Europe 2001: 63-6. Springer, Berlin, Heidelberg.
- [77] Haykin S. Neural Networks and Learning Machines [M], 3/E. Pearson Education India; 2010.
- [78] He H, Ma Y, editors. Imbalanced learning: foundations, algorithms, and applications [M]. John Wiley & Sons; 2013.
- [79] Ertekin S, Huang J, Giles CL. Active learning for class imbalance problem [J]. In SIGIR 2007, 7: 823-24.
- [80] Provost F. Machine learning from imbalanced data sets 101 [C]. In Proceedings of the AAAI'2000 workshop on imbalanced data sets 2000, 68(2000): 1-3. AAAI Press.
- [81] Branco P, Torgo L, Ribeiro RP. A survey of predictive modeling on imbalanced domains [J]. ACM Computing Surveys (CSUR). 2016, 49(2): 31.
- [82] Krawczyk B. Learning from imbalanced data: open challenges and future directions [J]. Progress in Artificial Intelligence. 2016, 5(4): 221-32.
- [83] Han H, Wang WY, Mao BH. Borderline-SMOTE: a new over-sampling method in imbalanced data sets learning [C]. In International conference on intelligent computing 2005: 878-87. Springer, Berlin, Heidelberg.
- [84] Wang HY. Combination approach of SMOTE and biased-SVM for imbalanced datasets [C]. In 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence) 2008: 228-31. IEEE.
- [85] Nguyen HM, Cooper EW, Kamei K. Borderline over-sampling for imbalanced data classification [C]. In Proceedings: Fifth International Workshop on Computational Intelligence & Applications 2009, 2009(1): 24-9. IEEE SMC Hiroshima Chapter.
- [86] Lemaître G, Nogueira F, Aridas CK. Imbalanced-learn: A python toolbox to tackle the curse of imbalanced datasets in machine learning [J]. The Journal of Machine Learning Research. 2017, 18(1): 559-63.
- [87] Schapire RE. The boosting approach to machine learning: An overview [M]. In Nonlinear estimation and classification 2003: 149-71. Springer, New York, NY.
- [88] Leo Breiman. Arcing classifiers [J]. The Annals of Statistics, 26(3):801-49, 1998.

- [89] Drucker H, Cortes C. Boosting decision trees [C]. In Advances in neural information processing systems 1996: 479-85.
- [90] Quinlan JR. Bagging, boosting, and C4.5 [C]. In AAAI/IAAI, 1996, 1: 725-30.
- [91] Saiidi M, Sozen MA. Simple and complex models for nonlinear seismic response of reinforced concrete structures [D]. University of Illinois Engineering Experiment Station. College of Engineering. University of Illinois at Urbana-Champaign. 1979.
- [92] Ozcebe G, Saatcioglu M. Hysteretic shear model for reinforced concrete members [J]. Journal of Structural Engineering. 1989, 115(1): 132-48.
- [93] Dowell OK, Seible F, Wilson EL. Pivot hysteresis model for reinforced concrete members [J]. ACI Structural Journal. 1998, 95: 607-17.
- [94] Sucuoğlu H, Erberik A. Energ-based hysteresis and damage models for deteriorating systems [J]. Earthquake engineering & structural dynamics. 2004, 33(1): 69-88.
- [95] Ibarra LF, Medina RA, Krawinkler H. Hysteretic models that incorporate strength and stiffness deterioration [J]. Earthquake engineering & structural dynamics. 2005, 34(12): 1489-511.
- [96] Bouc R. Forced vibrations of mechanical systems with hysteresis [C]. In Proc. of the Fourth Conference on Nonlinear Oscillations, Prague, 1967.
- [97] Baber TT, Wen YK. Random vibration hysteretic, degrading systems [J]. Journal of the Engineering Mechanics Division. 1981, 107(6): 1069-87.
- [98] Baber TT, Noori MN. Random vibration of degrading, pinching systems [J]. Journal of Engineering Mechanics. 1985, 111(8): 1010-26.
- [99] Yu B, Ning CL, Li B. Hysteretic model for shear-critical reinforced concrete columns [J]. Journal of Structural Engineering. 2016, 142(9): 04016056.
- [100] Colangelo F. Interaction of axial force and bending moment by using Bouc-Wen hysteresis and stochastic linearization [J]. Structural Safety. 2017, 67: 39-53.
- [101] Zhang H, Foliente GC, Yang Y, Ma F. Parameter identification of inelastic structures under dynamic loads [J]. Earthquake engineering & structural dynamics. 2002, 31(5): 1113-30.
- [102] Xu SY, Zhang J. Hysteretic shear-flexure interaction model of reinforced concrete columns for seismic response assessment of bridges [J]. Earthquake Engineering & Structural Dynamics. 2011, 40(3): 315-37.
- [103] Loh CH, Mao CH, Huang JR, Pan TC. System identification and damage evaluation of degrading hysteresis of reinforced concrete frames [J]. Earthquake Engineering & Structural Dynamics. 2011, 40(6): 623-40.
- [104] Sengupta P, Li B. Modified Bouc-Wen model for hysteresis behavior of RC beam-column joints with limited transverse reinforcement [J]. Engineering Structures. 2013, 46: 392-406.
- [105] Sengupta P, Li B. Hysteresis behavior of reinforced concrete walls [J]. Journal of Structural Engineering. 2014, 140(7): 04014030.
- [106] Ismail M, Ikhrouane F, Rodellar J. The hysteresis Bouc-Wen model, a survey [J]. Archives of Computational Methods in Engineering. 2009, 16(2): 161-88.
- [107] Erlicher S, Bursi OS. Bouc-Wen-type models with stiffness degradation: thermodynamic analysis and applications [J]. Journal of engineering mechanics. 2008, 134(10): 843-55.
- [108] Storn R, Price K. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces [J]. Journal of global optimization. 1997, 11(4):341-59.

- [109] Kirkpatrick S, Gelatt CD, Vecchi MP. Optimization by simulated annealing [J]. *science*. 1983, 220(4598): 671-80.
- [110] Lawler EL. Combinatorial optimization: networks and matroids [J]. Courier Corporation; 2001.
- [111] Dantzig G, Fulkerson R, Johnson S. Solution of a large-scale traveling-salesman problem [J]. *Journal of the operations research society of America*. 1954, 2(4): 393-410.
- [112] Karp RM. A patching algorithm for the nonsymmetric traveling-salesman problem [J]. *SIAM Journal on Computing*. 1979, 8(4): 561-73.
- [113] Dunham B, Fridshal D, Fridshal R, North JH. Design by natural selection [M]. In *Form and Strategy in Science 1964*: 306-11. Springer, Dordrecht.
- [114] Lin S. Heuristic programming as an aid to network design [J]. *Networks*. 1975, 5(1): 33-43.
- [115] Metropolis N, Rosenbluth AW, Rosenbluth MN, Teller AH, Teller E. Equation of state calculations by fast computing machines [J]. *The journal of chemical physics*. 1953, 21(6): 1087-92.
- [116] Hastings WK. Monte Carlo sampling methods using Markov chains and their applications. *Biometrika*. 1970, 57(1): 97-109.
- [117] Krauth W. *Statistical mechanics: algorithms and computations* [M]. OUP Oxford; 2006.
- [118] Zaharie D. Critical values for the control parameters of differential evolution algorithms [C]. In *Proc. of MENDEL 2002, 8th Int. Conf. on Soft Computing 2002*: 62-7.
- [119] Ma F, Ng CH, Ajavakom N. On system identification and response prediction of degrading structures [J]. *Structural Control and Health Monitoring: The Official Journal of the International Association for Structural Control and Monitoring and of the European Association for the Control of Structures*. 2006, 13(1): 347-64.
- [120] Elwood KJ and Eberhard M. Effective Stiffness of Reinforced Concrete Columns [J]. *ACI Structural Journal*. 2009, 106(4): 476-84.
- [121] Tran CTN and Li B. Initial stiffness of reinforced concrete columns with moderate aspect ratios [J]. *Advances in Structural Engineering*. 2012, 15(2): 265-276.

致谢

硕士学位论文是一次让我能够把十多年所习得的知识 and 理论用于分析、解决实际问题的绝佳机会。伟大的物理学家费曼曾经说过：最重要的一点就是你不能欺骗你自己，然而你就是最容易被自己欺骗的。学习过程中，尤其是学习艰深难懂的理论知识中，最怕的就是错把“熟悉”一种知识当做是“理解”一种知识。熟悉知识只是对其本身有一定的了解，习以为常了，而理解知识意味着触类旁通，举一反三，把知识学活了，应用到现实世界中，甚至是自己生活的点点滴滴之中。研究生以前的阶段我们接触到的更多的是从课本学习、到完成作业习题，最后再到应付考试这样的过程。这锻炼的是始终存在于自己脑袋里创造出的一套逻辑体系，意味着我们非常熟悉做题的方法，但这种逻辑体系并没有经受过现实的考验，实际上最多只能作为饭后闲聊的话题，但还没达到所谓的“理解”。硕士学位论文提供了一个实际的问题，我们需要考虑用怎样的知识、如何去处理这个问题，才能更合理、更加完美地反映现实世界的现象。然而第一次接触这样的任务，处理这么繁杂的现实问题，我显得有点力不从心。但多亏有我的导师任晓丹老师和宁超列老师的指导，为我和现实世界的首次遭遇战中提供了绝佳的战略指导方案。

在研究工作遇到困难的时候，我总能非常方便地联系到两位导师寻求帮助，在和两位导师的交谈中，我总能发现新的思路和解决问题的可能路径，这大大提高了我科研工作的效率。除了科研上的具体问题给予我协助，两位导师还教导了我科研应该有的严肃态度和治学严谨的重要意义。

最后还要感谢父母对我的支持和鼓励，还有教研室梯队的同门、室友和各位大学本科和研究生的同学与我在学术上的讨论和帮助。

个人简历、在读期间发表的学术论文与研究成果

个人简历:

吕欣亮, 男, 1995 年 2 月生。

2017 年 6 月毕业于同济大学土木工程学院, 获工程学士学位。

2017 年 9 月入同济大学攻读硕士研究生。

已发表和已接收论文:

- [1] 吕欣亮, 任晓丹, 宁超列. 剪切失效型钢筋混凝土柱滞回模型参数识别与经验预测[J]. 防灾减灾工程学报, 2020