


HEALTH MONITORING
OF HIGH VOLTAGE TRANSMISSION TOWER

高压输电铁塔 健康监测

刘春城 著



科学出版社

高压输电铁塔健康监测

刘春城 著

科学出版社

北 京

内 容 简 介

高压输电铁塔结构健康监测是近年来土木工程和输电工程及相关领域的热门研究课题,本书根据作者在高压输电铁塔结构健康监测方面的最新研究成果编撰而成,书中全面、系统地论述了高压输电铁塔结构健康监测的概念、基本理论和方法。本书内容涉及工程结构损伤识别基本理论、高压输电铁塔损伤识别的神经网络模型和方法、小波包和小波熵分析技术、支持向量机方法和数据融合技术,以及高压输电铁塔损伤加固技术的初步研究和介绍。

本书可供高等院校土木工程、输电工程专业研究生参考,也可作为土木工程和输电工程领域的科技人员的参考用书。

图书在版编目(CIP)数据

高压输电铁塔健康监测/刘春城著. —北京:科学出版社, 2016
ISBN 978-7-03-050654-2

I. ①高… II. ①刘… III. ①高压输电线路-输电铁塔-监测-研究
IV. ①TM75

中国版本图书馆 CIP 数据核字 (2016) 第 274285 号

责任编辑:任加林 / 责任校对:陶丽荣
责任印制:吕春珉 / 封面设计:耕者设计工作室

科学出版社出版

北京东黄城根北街 16 号

邮政编码:100717

<http://www.sciencep.com>

三河市骏杰印刷有限公司印刷

科学出版社发行 各地新华书店经销

*

2016 年 11 月第 一 版 开本: B5 (720×1000)

2016 年 11 月第一次印刷 印张: 11

字数: 218 000

定价: 58.00 元

(如有印装质量问题,我社负责调换(骏杰))

销售部电话 010-62136230 编辑部电话 010-62130750 (BA08)

版权所有,侵权必究

举报电话: 010-64030229; 010-64034315; 13501151303

前 言

高压输电铁塔是重要的电力工程设施,它的运行状态直接关系到整个电网的安全稳定性,铁塔的正常运行是保证电力持续供电的重要基础。但其由于设计缺陷、自然灾害或老化病害等原因,高压输电铁塔在运行中存在着如疲劳和裂纹,松弛和蠕变,腐蚀和磨损等损伤情况,随着损伤程度的加剧,将导致输电线路倒塔断线,造成电网的中断,这不仅严重影响人们的生产建设,还会导致其他次生灾害,造成更大的经济损失。因此,对高压输电铁塔结构的健康状况进行实时监测和定期检测,及时发现和准确判断结构的损伤位置和损伤程度,对损伤倒塔提前预警,进而评定结构的可靠性和安全性,并提出加固维修策略,以及对于保证电网安全运行均具有重大的工程意义和应用价值。

基于上述问题,本书作者和研究团队成员开展了高压输电铁塔健康监测领域的研究,将其在工程应用方面的最新研究成果进行了归纳与总结,以方便土木工程和输电工程领域研究和技术人员参考。本书全面、系统地论述了高压输电铁塔结构健康监测的概念、基本理论和基本方法,内容涉及工程结构损伤识别基本理论,高压输电铁塔损伤识别的神经网络模型和方法、小波包和小波熵分析技术、支持向量机方法和数据融合技术,最后对高压输电铁塔损伤加固技术内容做了初步研究和介绍。

本书的部分研究成果得到了国家自然科学基金项目(项目编号:50978049,51278091)、吉林省科技计划项目(项目编号:20120429、20140519001JH)、吉林省高等学校新世纪优秀人才支持计划的资助,在此表示衷心感谢!

作者特别感谢研究团队中的徐健、刘佼、张伟、苏玉成、侯尚雨、吕春蕾等研究生,他们参加了本书的有关研究工作和各章节的编排整理,为本书顺利出版付出了辛勤的劳动和汗水,书中很多计算结果和图表出自他们之手。本书重点介绍了输电铁塔损伤诊断的智能方法和技术,其中也参考了很多学者的研究成果和相关文献,这里一并对原作者表示感谢。

书中大部分内容是作者和研究团队成员近几年公开发表过的研究成果，鉴于作者的研究水平及经验所限，书中不足之处在所难免，敬请读者不吝赐教。

刘春城

2016年9月

于东北电力大学

目 录

前言

第一章 绪论	1
1.1 高压输电铁塔健康监测研究动态	1
1.2 高压输电铁塔智能损伤识别方法	2
1.2.1 神经网络方法	2
1.2.2 支持向量机方法	4
1.2.3 小波包分析方法	6
1.2.4 数据融合方法	8
1.3 高压输电铁塔多尺度数值模拟方法	12
1.4 本章小结	14
参考文献	14
第二章 结构损伤识别理论及网络参数选取	16
2.1 概述	16
2.2 结构损伤识别理论	16
2.2.1 基于固有频率变化的结构损伤识别	16
2.2.2 基于模态振型差的结构损伤识别	17
2.2.3 基于模态曲率的结构损伤识别	18
2.2.4 基于柔度差的结构损伤识别	19
2.2.5 基于模态应变能的结构损伤识别	19
2.2.6 基于统计信息的结构损伤识别	19
2.2.7 基于刚度变化的结构损伤识别	20
2.2.8 基于残余力向量的结构损伤识别	20
2.3 网络参数选取	21
2.4 多步法损伤识别理论	23
2.4.1 子结构概念	23
2.4.2 多步法损伤检测研究概述	24
2.5 本章小结	25
参考文献	26

第三章 基于频率变化参数与神经网络的输电塔结构损伤识别方法研究	27
3.1 结构算例模型及损伤识别流程	27
3.2 损伤识别第一步	29
3.2.1 损伤初步定位神经网络模型的选取	29
3.2.2 损伤初步定位神经网络输入参数的选取	29
3.2.3 PNN 网络损伤初步定位的训练和测试	29
3.2.4 PNN 网络损伤初步定位性能评价	34
3.3 损伤识别第二步	34
3.3.1 损伤具体定位神经网络模型的选取	34
3.3.2 损伤具体定位神经网络输入参数的选取	35
3.3.3 RBF 网络损伤具体定位的训练和测试	35
3.3.4 RBF 网络损伤具体定位性能评价	39
3.4 损伤识别第三步	39
3.4.1 损伤程度识别神经网络模型的选取	39
3.4.2 损伤程度识别神经网络的输入参数选取	40
3.4.3 损伤程度识别的训练和测试	40
3.4.4 RBF 网络损伤程度识别性能评价	40
3.5 本章小结	41
参考文献	41
第四章 基于支持向量机大型输电铁塔损伤识别方法研究	43
4.1 最小二乘支持向量机理论	43
4.2 输电铁塔模型简介	44
4.3 输电铁塔损伤位置识别	46
4.4 输电铁塔损伤程度识别	48
4.5 噪声对损伤识别的影响	55
4.6 本章小结	56
参考文献	57
第五章 基于小波包的输电塔损伤识别方法	58
5.1 小波包的基本原理	58
5.1.1 小波包的定义	58
5.1.2 小波包的性质	59
5.2 小波包的子空间分解	60
5.2.1 小波包的子空间分解过程	60

5.2.2 小波包的重构	61
5.3 小波包节点能量	62
5.4 模型介绍	63
5.5 结构损伤的小波熵指标	66
5.5.1 信息熵概念	66
5.5.2 相对小波能量	67
5.5.3 小波熵与相对小波熵	67
5.6 地震波的输入	67
5.7 基于小波熵的结构损伤识别	68
5.7.1 铁塔主材的损伤识别	68
5.7.2 铁塔辅助材的损伤识别	76
5.8 损伤程度识别	83
5.9 小波包能量曲率差	84
5.10 小波函数的选择	84
5.11 基于小波包能量曲率差的损伤位置识别	85
5.11.1 主材的损伤位置识别	85
5.11.2 辅助材的损伤位置识别	94
5.12 基于相对小波熵和小波包能量曲率差的损伤识别	101
5.13 本章小结	108
参考文献	108
第六章 基于数据融合的大型输电铁塔损伤识别	110
6.1 数据融合算法	110
6.2 模型介绍	111
6.3 模态损伤指标及其在铁塔损伤中的应用	111
6.3.1 模态曲率差	111
6.3.2 模态柔度差	111
6.3.3 模态柔度改变率	112
6.3.4 基于模态指标的铁塔损伤位置识别	112
6.4 基于模态指标与数据融合的铁塔损伤识别	117
6.4.1 数据融合损伤识别方法	117
6.4.2 基于数据融合的铁塔损伤识别	117
6.5 本章小结	119
参考文献	119

第七章 基于多尺度模型的损伤评估及识别方法	121
7.1 多尺度模型基本理论	121
7.2 单一宏观尺度模型建立	122
7.2.1 ANSYS 建模	122
7.2.2 单塔模态分析	124
7.3 多尺度模型建立	126
7.3.1 建立约束方程	128
7.3.2 模型的拼装	129
7.4 螺栓损伤位置识别	131
7.4.1 螺栓损伤模拟	131
7.4.2 损伤位置识别	134
7.4.3 同一损伤位置	138
7.4.4 不同损伤位置	138
7.4.5 多损伤	139
7.5 损伤程度的判定	140
7.6 裂纹损伤位置识别	141
7.6.1 损伤模拟	141
7.6.2 损伤位置识别	143
7.7 损伤程度识别	146
7.8 本章小结	151
参考文献	152
第八章 高压输电铁塔损伤加固技术研究	153
8.1 几种铁塔加固方法	153
8.2 Z33102VCR 直线塔加固方案	158
8.2.1 更换大规格角钢加固方案数值模拟	159
8.2.2 更换塔材施工方案	162
8.3 本章小结	164
参考文献	164

第一章 绪 论

1.1 高压输电铁塔健康监测研究动态

高压输电铁塔具有塔体高、结构复杂、杆件众多、柔性强等高耸结构的共同特点,对地震、风和导线覆冰等环境荷载的反应较为敏感,在服役期内由于环境侵蚀、材料老化和荷载的长期疲劳效应及突发事变过载效应等因素的综合作用将不可避免地导致结构系统中的损伤积累和抗力衰减,从而使结构抵抗自然灾害甚至正常服役载荷的能力下降,容易发生极端条件下的动态倒塔破坏,导致电网大面积停电,造成重大经济损失,故对高压输电铁塔进行健康监测,及时发现损伤并对其安全状态进行评估,以提前采取补救措施进行加固维修,保证主干电网安全,具有重要工程意义。

2005年春节期间,由于连续大范围雨雪天气,在湖北、湖南和重庆地区,发生了50年来最严重的冰灾事故,导致17条输电线路处于瘫痪状态,影响人们的生产和生活长达1个多月^[1];2008年初,我国南方地区出现历史罕见的冰冻灾害性天气,输电线路由于覆冰严重而断线,输电杆塔由于严重覆冰而倒塔或变形等,造成大面积停电,而且造成南北交通大动脉的堵塞,公路、铁路和航空运输一度陷于瘫痪状态,10多个省近亿人口由于电力中断,造成财产损失或者其他损害。根据国家电网公司统计,由于覆冰导致10~110kV线路倒塔14万多基,220kV及其以上线路倒塔达1500多基,有707座变电站由于冰灾而不得不停运^[2]。

在国外,由于自然灾害导致的铁塔损伤、倒塔和断线事故也非常频繁。1998年,加拿大的蒙特利尔附近的圣劳伦斯河沿岸遭遇一场持续时间超过5d的冰冻灾害,在此次恶劣天气条件下,地面积雪厚度达75mm,由于输电线路覆冰过重,有近116条不同电压等级的线路发生了倒塔事故,造成加拿大魁北克地区40%的居民无法用电;在2005年12月15日至18日期间,美国的北卡罗来纳、弗吉尼亚、南卡罗来纳和佐治亚4个州遭遇严重冰暴袭击,造成倒塔断线,导致大面积供电中断,其中受灾最为严重的是南卡罗来纳州和北卡罗来纳州,受影响用户达到68.3万户;在2006年1月6日至9日期间,由于普降大雪,日本西部和北部出现电力线路大面积跳闸,导致138万户家庭用电中断^[3]。

从以上的例子中我们可以看出,电网受自然灾害影响比较大,而处于运行环境下的输电铁塔结构,无论其设计可靠性有多高,也会发生局部或者部分损伤,从而造成结构性能的退化或丧失。因此,进行输电铁塔健康监测研究,可以提高

其可靠性与安全性,避免重大事故的发生,减少事故危害性,获得潜在的巨大的经济效益和社会效益。

美国 Purdue 大学的 Venkatasubramanian 和 Chari 最早将 BP 神经网络用于结构损伤识别,于 1989 年第一次运用 BP 网络对工程结构进行损伤检测与诊断,随后利用不同的网络模型,对工程结构或构件进行损伤检测与识别^[4]。通过利用神经网络的自组织、自学习能力,Wu 等^[5]提出一种基于傅里叶谱的损伤检测方法。刘春城等^[6]应用神经网络理论,选用合理的网络模型和网络参数,提出大型输电铁塔结构损伤识别的新方法,据此识别结构损伤位置和损伤程度,并以 500kV 输电铁塔为例进行损伤识别,研究表明该方法可以获得令人满意的识别精度。樊可清^[7]利用支持向量机对香港汀九大桥的 794h 的实测数据进行检测,充分证明支持向量机方法在桥梁状态监测系统中实用性和有效性。鞠彦忠等^[8]通过数值模拟和试验对某一框架结构模型进行损伤识别研究,发现将小波分析和神经网络相结合的方法具有更好的抗噪声和识别能力。丁幼亮等^[9]在研究结构损伤预警时,根据瞬态激励的特性,提出将激励和响应的时域互相关序列进行小波包分解,得到小波包能量谱,通过研究得到结构的损伤预警指标。姜绍飞等^[10]在研究复杂桥梁结构的损伤识别中,采用分层分布式的神经网络健康监测和诊断方法,并针对专家系统和神经网络两种人工智能数据融合方法的具体特点进行分析,验证将数据融合应用于结构健康监测的可行性,并采用表格的形式对各种融合方法进行对比,发现采用此方法可以将大系统分为一些小规模的系统,并利用多个神经网络,而底层神经网络面向各个子系统,并将其诊断结果当作下一级的神经网络的输入,从而较大地简化了神经网络的复杂程度,提高了计算速度。

随着高压输电铁塔结构的发展和人们防灾减灾意识的加强,建立高压输电铁塔结构的健康监测系统或检测工具成为一种发展趋势,而且对大型输电铁塔进行理论上的损伤评估研究,寻找到敏感的损伤指标和合适的识别方法,也可以将此种损伤识别方法应用到其他高耸铁塔结构(如通信塔、电视塔等)中,为以后的铁塔损伤试验研究提供理论依据。

1.2 高压输电铁塔智能损伤识别方法

1.2.1 神经网络方法

结构的动态特性及其响应会随着结构发生损伤而产生变化,换句话说,损伤前后的动态特性及其响应变化与结构的损伤位置和损伤程度存在着复杂的非线性关系。传统的声发射法、超声波法、红外线法等无损检测技术应用到大型结构上不仅费时费力,而且费用昂贵,且不能检测到有些部位,然而结构的动态特性和响应可以通过其他各种检测手段和模态分析获得。

人工神经网络 (artificial neural network, ANN) 是在现代神经生理学和心理学研究基础上, 模仿人的大脑神经元结构特性而建立的一种非线性动力学网络系统, 由大量简单的非线性处理单元 (类似人脑的神经元) 高度并联、互联而成, 具有对人脑某些基本特性进行简单数学模仿的能力。人工神经网络的最大特点是自适应, 它通过自身的学习机制能自动形成所要求的决策区域。网络的特性由其拓扑结构、特点特性、学习或训练规则所决定, 它能充分利用状态信息, 对来自不同状态的信息逐一训练得到均衡的收敛权值, 这些权值代表了网络的某些映射关系, 而且网络还可以连续学习, 当环境改变时, 这些映射关系可以自适应, 以求对对象进一步逼近。概括来说, ANN 具有高度并行性、高度非线性全局作用、良好的容错性和联想记忆功能, 以及适应性等特殊的信息处理功能^[11]。

ANN 可以根据结构在各种状态下与动力特性及某种响应相关的损伤指标作为输入向量, 把各种状态下的损伤诊断结果 (损伤是否存在、损伤位置、损伤程度等) 作为输出向量, 通过学习形成映射, 并将含有这种映射关系的神经网络权值保存下来, 而在反复分析过程中无须调用分析模型。ANN 对通过学习得到的权值和通过检测得到的损伤指标进行行之有效且快速的正向运算, 在进行在线诊断时得出损伤诊断结果 (损伤是否存在、损伤位置和损伤程度)。

神经网络的基本组成单元是神经元。数学上的神经元模型和生物学上的神经细胞相对应, 即神经网络理论是用神经元这种抽象模型来描述客观世界的生物细胞的。从神经元的特性和功能可知, 神经元是一个多输入单输出的信息处理单元, 而且它对信息的处理是非线性的。根据神经元的特性和功能, 可把神经元抽象为一个简单的数学模型。工程上神经元的数学模型如图 1.1 所示。




图 1.1 神经元的数学模型

在图 1.1 中, x_i 是 i 神经元的输入, 即来自前级 n 个神经元的轴突的信息; θ_i 是 i 神经元的阈值; w_i 是 i 神经元对 x_i 的权值连接, 即突触的传递效率; y_i 是 i 神经元的输出; f 是传递函数, 决定 i 神经元受到输入 x_i 的共同作用达到阈值时以何种方式输出。

传递函数 f 有多种形式, 其中最常见有阶跃型、线性型和 S 型 3 种形式。假设:

$$U_i = \sum_{j=1}^n w_{ji} x_j - \theta_i \quad (1.1)$$

1) 阶跃型传递函数, 它的输出是电位脉冲, 故这种激发函数的神经元称离散输出模型, 即

$$f(U_i) = \begin{cases} 1 & U_i \geq 0 \\ 0 & U_i < 0 \end{cases} \quad (1.2)$$

2) 线性型传递函数, 它的输出是与输入的综合作用成正比的, 故这种神经元称线性连续型模型, 即

$$f(U_i) = KU_i \quad (1.3)$$

3) S 型传递函数, 它的输入是非线性的, 故这种神经元称非线性连续型模型, 即

$$f(U_i) = \frac{1}{1 + \exp(-U_i)} \quad (1.4)$$

以上所述的是应用最广泛且为人们最熟悉的神经元数学模型, 也是历史最长的神经元模型。若干年来, 随着神经网络理论的发展, 出现了不少新颖的神经元数学模型。这些模型包括逻辑神经元模型、模糊神经元模型等, 也渐渐受到人们的关注和重视。

1.2.2 支持向量机方法

贝尔实验室的 Vapnik^[12]于 20 个世纪 90 年代最早提出了支持向量机理论, 克服了传统神经网络方法的一些缺点。与其他机器语言相比, 支持向量机方法在有限样本的情况下可以达到现有信息的最优解; 支持向量机以风险最小为约束条件, 将经验风险与置信范围控制到最小; 在算法上为避免出现局部极值问题, 将上述极值问题转换为二次寻优问题, 以获得最优解; 最终将问题通过非线性转化到高维空间中, 高维空间中问题则表现为线性关系, 以高维空间中的线性关系来达到求解原问题的目的。支持向量机方法能够保证良好的泛化能力, 同时对维数问题加以解决, 样本维数的大小不与算法复杂性产生直接关系。

它借助最优化算法, 通过分类边界的最大化来实现结构风险的最小化。在解决小样本、非线性和高维模式识别问题上, 其具有特有的优势。支持向量机是一个二次优化问题, 其所求得的解即为全局最优解, 从而避免了神经网络等方法的网络结构难以确定、过学习、欠学习和陷于局部最小化等问题。当前, 支持向量机已经成为机器学习领域的研究热点, 并在人脸识别、手写体识别、故障诊断等^[13]很多领域得到成功运用。

支持向量机的核心思想是将结构风险最小化原则引入到分类学习算法中, 是统计学习理论最实用的部分。支持向量机方法的诸多优点使之成为目前十分受欢迎的学习方法, 其优点有通用性、鲁棒性、有效性、计算简单及理论完善等。

支持向量机回归, 即将支持向量机应用到回归分析中, 支持向量机中最大间

隔算法为更好地解决回归问题提供了优势。

线性回归情形给定的训练样本集假设为

$$S = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\} \in (X \times Y)^l \quad X \subseteq \mathbf{R}^n \quad Y \subseteq \mathbf{R} \quad (1.5)$$

寻找一个近似超平面 f 对输入数据进行建模是线性回归的最终目的, 这个平面为

$$y = f(x) = \langle \omega, x \rangle + b \quad (1.6)$$

同时, 还要使输入数据的拟合误差最小。

由高斯与勒让德提出的最小二乘法是支持向量机中最常用也是最著名的损失函数, 用以度量输入数据与拟合数据之间的误差, 它能在线性目标被高斯噪声干扰的情况下求得最优结果。

假定样本集 S 是 ε -线性近似的, 那么就存在一个近似超平面 f 使下式成立:

$$|y_i - f(x_i)| \leq \varepsilon \quad i=1, 2, \dots, l \quad (1.7)$$

Vapnik 提出 ε -不敏感损失函数, 该函数采用新的损失函数类型对实值函数进行构造, 即

$$|\xi|_\varepsilon = \begin{cases} 0 & |\xi| \leq \varepsilon \\ |\xi| - \varepsilon & |\xi| > \varepsilon \end{cases} \quad (1.8)$$

当预测值、实测值两者之差小于 ε 时, 损失为 0。

Vapnik 指出, 线性回归问题最终方式就是转化为一个二次凸优化问题, 即

$$\begin{aligned} \min \Phi(\omega, b) &= \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{s.t. } \langle \omega, x_i \rangle + b - y_i &\leq \xi_i^* + \varepsilon \quad i=1, 2, \dots, l \\ y_i - \langle \omega, x_i \rangle + b &\leq \xi_i + \varepsilon \quad i=1, 2, \dots, l \\ \xi_i, \xi_i^* &\geq 0 \quad i=1, 2, \dots, l \end{aligned} \quad (1.9)$$

式 (1.9) 中引入两个松弛变量 ξ_i 、 ξ_i^* , 是为了考虑回归分析中可能存在的误差。式 (1.9) 中右边第一项的作用就是使函数变得平坦以提高泛化能力; 第二项是为使回归误差最小而令常数 C 在两者间做出折中。

采用拉格朗日乘子法来给出原优化问题的对偶优化问题

$$\begin{aligned} \max Q(\alpha_i, \alpha_i^*) &= -\frac{1}{2} \sum_{i=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle \\ &\quad + \sum_{i=1}^l (\alpha_i - \alpha_i^*) y_i + \sum_{i=1}^l (\alpha_i + \alpha_i^*) \varepsilon \\ \text{s.t. } \sum_{i=1}^l (\alpha_i - \alpha_i^*) &= 0 \\ 0 \leq \alpha_i, \alpha_i^* &\leq C \quad i=1, 2, \dots, l \end{aligned} \quad (1.10)$$

输入数据通过非线性映射 $\phi(x)$ 可以转化到高维特征空间中, 这些数据在高维特征空间中则为线性相关的样本集, 用核函数 $K(x, y)$ 代替表示高维特征空间中的内积运算 $\langle \phi(x), \phi(y) \rangle$ 。非线性回归优化问题的对偶问题变为

$$\begin{aligned} \max Q(\alpha_i, \alpha_i^*) = & -\frac{1}{2} \sum_{i=1}^l (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(x_i, x_j) \\ & + \sum_{i=1}^l (\alpha_i - \alpha_i^*) y_i + \sum_{i=1}^l (\alpha_i + \alpha_i^*) \varepsilon \end{aligned} \quad (1.11)$$

约束条件与线性回归情形相同。

求解这个二次优化问题可得出 α 和 α^* 的值, 可由 KKT (karush-kuhn-tucker) 条件求得参数 b 的值。于是非线性回归的最优近似超平面可表示为

$$f(x) = \sum_{i=1}^l (\alpha_i, \alpha_i^*) K(x_i, x) + b \quad (1.12)$$

1.2.3 小波包分析方法

小波包分析是以小波分析为基础延伸形成的一种对信号能够进行更加精细分解和重构的方法。小波包不仅对尺度空间进行分解, 同时也对小波空间进行分解, 并根据被分析信号频率值的大小, 自动选择相应的频带, 使之与原信号的频谱相匹配。每次分解都能够包含原信号的所有频率, 仅分辨率不同而已。小波包分析能在整个频带对信号进行多个层次的频带划分, 不但具有良好的时频局部化优点, 而且能将小波变换没有再继续分解的高频频带做进一步分解, 提高了频率分辨率^[14]。

将小波子空间 W_j 和尺度空间 V_j 用子空间 U_j^n 来统一表示, 若假定

$$\begin{cases} U_j^0 = V_j \\ U_j^1 = W_j \end{cases} \quad j \in \mathbf{Z} \quad (1.13)$$

则 Hilbert 空间正交分解 $V_{j+1} = V_j \oplus W_j$ 即可用新子空间 U_j^n 统一表示为

$$U_{j+1}^0 = U_j^0 \oplus U_j^1 \quad j \in \mathbf{Z} \quad (1.14)$$

假定新子空间 U_j^n 是函数 $u_n(t)$ 的封闭空间, U_j^{2n} 是函数 $u_{2n}(t)$ 的封闭空间, 并假定 $u_n(t)$ 满足如下的双尺度方程, 即

$$\begin{cases} u_{2n}(t) = \sqrt{2} \sum_{k \in \mathbf{Z}} h[k] u_n(2t - k) \\ u_{2n+1}(t) = \sqrt{2} \sum_{k \in \mathbf{Z}} g[k] u_n(2t - k) \end{cases} \quad (1.15)$$

式 (1.15) 中, $g[k] = (-1)^k h(1-k)$, 即式中两系数同样满足正交关系。当 $n=0$ 时, 式 (1.15) 即为

$$\begin{cases} u_0(t) = \sqrt{2} \sum_{k \in \mathbf{Z}} h[k] u_n(2t - k) \\ u_1(t) = \sqrt{2} \sum_{k \in \mathbf{Z}} g[k] u_n(2t - k) \end{cases} \quad (1.16)$$

与在多分辨率分析中, $\phi(t)$ 和 $\psi(t)$ 满足尺度方程

$$\begin{cases} \phi(t) = \sqrt{2} \sum_{k \in \mathbf{Z}} h[k] \phi(2t - k), \{h[k]\}_{k \in \mathbf{Z}} \in l^2 \\ \psi(t) = \sqrt{2} \sum_{k \in \mathbf{Z}} g[k] \phi(2t - k), \{g[k]\}_{k \in \mathbf{Z}} \in l^2 \end{cases} \quad (1.17)$$

对比式 (1.15) 与式 (1.16) 可知, $u_0(t)$ 和 $u_1(t)$ 分别退化为尺度函数 $\phi(t)$ 与小波基函数 $\psi(t)$ 。式 (1.16) 为式 (1.14) 的一种等价表示。把这种等价关系扩展到 $\mathbf{G}$ (非负整数) 时, 就可得到式 (1.15) 的另一种等价表示

$$U_{j+1}^n = U_j^{2n} \oplus U_j^{2n+1}; j \in \mathbf{Z}, n \in \mathbf{Z}_+ \quad (1.18)$$

原始信号 $f(t)$ 的小波包分解相邻两阶的关系为

$$f_j^i(t) = f_{j+1}^{2i-1}(t) + f_{j+1}^{2i}(t) \quad (1.19)$$

$$f_{j+1}^{2i-1}(t) = H f_j^i(t) \quad (1.20)$$

$$f_{j+1}^{2i}(t) = G f_j^i(t) \quad (1.21)$$

式中, j —— 分解水平;

H, G —— 一组高通、低通的滤波器, 其可表示为

$$H\{\bullet\} = \sum_{k=-\infty}^{\infty} h(k-2t) \quad (1.22)$$

$$G\{\bullet\} = \sum_{k=-\infty}^{\infty} g(k-2t) \quad (1.23)$$

经 j 水平的小波包分解后, 原始信号 $f(t)$ 可表示为

$$f(t) = \sum_{i=1}^{2^j} f_j^i(t) \quad (1.24)$$

小波包各组分信号 f_j^i 可表示为各小波包函数 $\psi_{j,k}^i(t)$ 的线性组合, 即

$$f_j^i(t) = \sum_{k=-\infty}^{+\infty} c_{j,k}^i(t) \psi_{j,k}^i(t) \quad (1.25)$$

式中, $c_{j,k}^i(t)$ —— 小波包系数, 其计算公式为

$$c_{j,k}^i = \int_{-\infty}^{+\infty} f(t) \psi_{j,k}^i(t) dt \quad (1.26)$$

其中, 小波包系数满足正交性条件, 即

$$\psi_{j,k}^m \psi_{j,k}^n = 0 \quad (m \neq n) \quad (1.27)$$

小波包各频带能量可按式计算:

$$E_{f_j^i} = \int_{-\infty}^{\infty} f_j^i(t)^2 dt \quad (1.28)$$

当结构出现损伤时,损伤前与损伤后对应频带的能量出现变化,某些频带的信号能量减少,另一些频带的信号能量增加,小波包各频带能量对损伤十分敏感,因而可以利用小波包各频带能量来识别结构的损伤。

在研究振动信号时,谭冬梅^[15]等使用各频带能量作为识别故障的特征向量,对一空间杆系结构的振动信号进行小波包分析,完成了损伤定位识别,并表明小波包分析具有较好的抗噪声干扰能力。孙增寿^[16]等在研究一框架建筑结构模型的损伤识别时,将结构上的响应信号进行小波包组分解,研究发现小波信号的突变可以完成该结构的损伤识别。

1.2.4 数据融合方法

数据融合技术(又称信息融合技术、多传感器数据融合技术)作为一种新兴的技术逐渐出现,具有性能稳定、容错性好、能够较好地解决探测和跟踪及目标识别等特点,且改善了系统的可靠性和可维护性,提高了空间分辨率,增加了置信度并改善了探测性能,同时降低了对单个传感器的性能要求等,因此在军事和民用领域都得到了非常广泛的应用,逐渐受到人们的重视。

自20世纪80年代末以来,数据融合技术在应用领域不断扩展,它已从刚开始的只在军事领域中应用,到不断地向其他各种领域渗透,现已在医疗图像处理与诊断、智能机器人、机器设备故障诊断、天气预报和结构损伤识别等许多领域得到普遍应用,并得到惊人的发展。在我国,数据融合技术已在机器设备故障诊断和结构健康监测及损伤识别领域得到一些应用。

数据融合技术主要包括4个方面,即多传感器的安装、多信息的输入、合成规则的准确有效、结果形式的表示单一。数据融合技术是为了完成所需的决策和评估任务的信息处理过程,对来自多传感器的探测信息,使用计算机按时序和一定准则加以分析和综合,其在本质上是对多传感器不同时刻的目标信息或同一时刻多目标信息的综合处理,即协调优化多种信息。

单源数据来源比较单一,而数据融合是将同源数据进行组合,因此可得到统计上的优势,从而使数据融合处理后的结果,精度更高,具体优点如下。

1. 信息的可信度增加

为使系统获得的综合信息具有更高的可靠性和精度,常应用多传感器获取环境目标的某一特征或一组相关特征。

2. 特征目标的矢量维数增加

为使多传感器系统尽可能少地受到自然现象的破坏、干扰和迷惑,系统可以提取任何单一传感器难以获得的独立特征信息,使传感器性能相互补充,并使其不相关特征在收集的信息中增加。