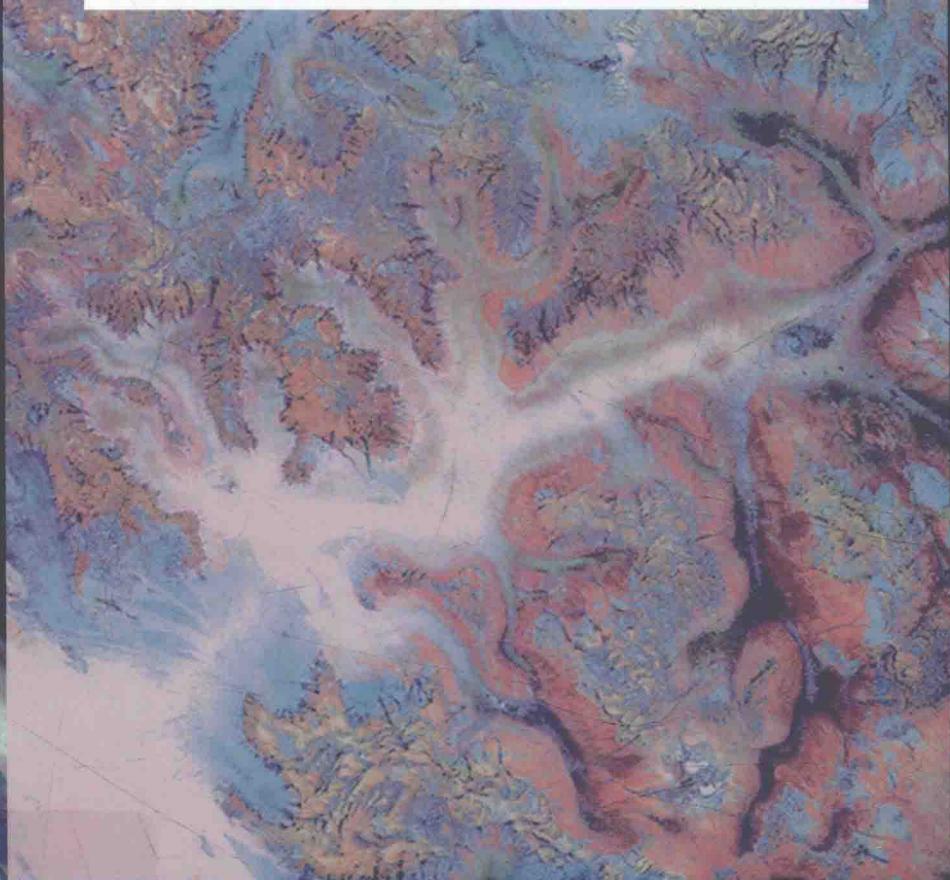


王 鑫 石爱业 著
高红民 王超 著

高分辨率遥感影像 处理方法及应用



科学出版社

高分辨率遥感影像处理 方法及应用

王 鑫 石爱业 高红民 王 超 著

科学出版社

北京

内 容 简 介

高光谱分辨率、高空间分辨率（统称高分辨率）遥感近年来发展迅速，并成为经济建设、国防安全和信息服务等方面重要的空间信息源。高分辨率影像的处理，是高分辨率遥感从数据转换为信息或知识，进而服务于城市遥感、测绘、精细农业、环境监测与评价、军事侦察等领域的重要环节，也是高分辨率遥感应用服务链的核心技术之一。本书系统介绍高分辨率遥感影像处理技术的有关概念、原理和方法，共分10章。第1章主要介绍高光谱分辨率和高空间分辨率遥感成像、预处理技术、影像分类和变化检测技术。第2~6章主要介绍高光谱分辨率遥感影像的波段选择和分类方法及应用。第7~10章主要介绍高空间分辨率遥感影像的配准、分割和变化检测方法及应用。

本书内容新颖、理论联系实际，可作为遥感技术、地球信息科学、计算机应用等相关专业的研究生和高年级本科生、科研人员、工程技术人员参考书。

图书在版编目(CIP)数据

高分辨率遥感影像处理方法及应用/王鑫等著. —北京：科学出版社，2017

ISBN 978-7-03-051935-1

I. ①高… II. ①王… III. ①高分辨率-遥感图象-图象处理-研究

IV. ①TP751

中国版本图书馆 CIP 数据核字(2017) 第 037219 号

责任编辑：惠 雪 沈 旭 / 责任校对：刘亚琦

责任印制：张 倩 / 封面设计：许 瑞

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>

文林印务有限公司 印刷

科学出版社发行 各地新华书店经销

*

2017 年 3 月第 一 版 开本：720 × 1000 1/16

2017 年 3 月第一次印刷 印张：13 1/4

字数：267 000

定价：89.00 元

(如有印装质量问题，我社负责调换)

前　　言

高光谱分辨率、高空间分辨率、高辐射分辨率、高时间分辨率是当今对地观测技术发展的趋势，也是遥感科学技术不断追求与发展的目标。特别是高光谱分辨率、高空间分辨率（统称高分辨率）遥感的发展近年来十分迅速，并成为经济建设、国防安全和信息服务等方面重要的空间信息源。

高分辨率遥感图像处理是高分遥感从数据转换为信息或知识，进而服务于应用的重要环节，也是高分辨率遥感应用服务链的核心技术之一。高光谱遥感影像有着信息量大、光谱分辨率高等特点。但是，高光谱遥感数据丰富的光谱信息在有助于实现细致的遥感地物分类和识别的同时，其众多的波段数也导致信息的高冗余和数据处理的复杂，这不仅带来了巨大的计算量，而且还会降低应用精度。因此，在对高光谱影像进行处理、分析之前进行降维变得非常必要。分类作为一种重要的信息获取手段，可以通过光谱信息来辨识不同像元所对应的地物类别。现有的通过高光谱遥感影像丰富的光谱信息辨识不同像素中所包含的地物种类的方法精度低，需要进一步研究针对高光谱影像自身特点的分类方法。如何从高光谱影像产生的数据中进行高精度的分类目前仍是亟待解决的问题。随着高空间分辨率遥感影像在城市规划、自然灾害监测与评估等诸多领域的广泛应用，高分辨率遥感影像配准、分割、分类及变化检测等技术已经成为遥感技术领域的研究热点之一。空间分辨率的提高带来了更加丰富的地形、地物细节信息，也给相应的图像处理带来了新的挑战。近年来，由于高分辨率多时相遥感数据的获取手段的多样化，基于多时相高分辨率遥感的变化检测正成为研究热点之一。对象级变化检测算法采用面向对象的分析技术，为进一步提高变化检测精度提供了有效途径，是目前高分辨率遥感影像变化检测技术的主流和发展方向。为了实现高精度的对象级高分辨率遥感影像变化检测，不仅需要有效的变化检测方法，高效的几何配准、图像分割等相关技术也是成功实现变化检测的重要保证。

本书系统介绍高分辨率遥感图像处理技术的有关概念、原理和方法，也是作者多年研究工作的总结。

本书共分为 10 章。第 1 章主要介绍高分辨率遥感图像处理方法研究现状、意义及应用。第 2~10 章主要介绍作者所提出的高分辨率遥感图像处理相关技术，主要内容包括：基于模拟退火遗传算法的高光谱遥感影像波段选择技术、基于 Choquet 模糊积分优化的 SAGA 高光谱遥感影像波段选择技术、基于多目标粒子群优化算

法的高光谱遥感影像波段选择技术、基于后验概率支持向量机和马尔科夫场的高光谱影像分类技术、基于多示例学习和支持向量机的高光谱遥感影像分类技术、基于 JSEG 与归一化互信息的高分辨率遥感影像配准技术、基于小波变换与改进 JSEG 算法的高分辨率遥感影像多尺度分割技术、基于多尺度融合的对象级高分辨率遥感影像变化检测技术及一种对象级高分辨率 SAR 影像洪水灾害变化检测技术等。

本书第 1 章由王鑫、石爱业编写, 第 2~6 章由高红民、王鑫编写, 第 7~10 章由王超、石爱业编写, 全书由王鑫、石爱业统稿。

本书是在作者及其研究团队近年来科研工作的基础上完成的, 先后得到了国家科技支撑计划项目(编号: 2015BAB07B01)、国家自然科学基金(编号: 61603124、61601229、61374019、61271386、60901003、60872096、60774092、60374033)、江苏高校优势学科建设工程资助项目(PAPD)、教育部中央高校基本科研业务费(2015B19014)的资助。

向所有的参考文献作者及为本书出版付出辛勤劳动的同志们表示衷心的感谢! 同时, 特别感谢徐立中在本书编写过程中给予的帮助。

限于作者的水平, 书中难免有缺点和不完善之处, 恳请批评指正。

王 鑫 石 爱 业

2016 年 11 月 6 日

于河海大学

目 录

前言

第 1 章 绪论	1
1.1 概述	1
1.1.1 高光谱分辨率遥感	1
1.1.2 高空间分辨率遥感	3
1.2 高光谱遥感影像降维和分类方法研究现状	3
1.2.1 数据降维方法	3
1.2.2 数据分类方法	11
1.3 基于计算智能方法的高光谱遥感应用	17
1.3.1 计算智能方法	17
1.3.2 计算智能方法在高光谱遥感上的应用	19
1.4 多时相遥感影像变化检测研究现状	20
1.4.1 遥感影像变化检测的基本概念	20
1.4.2 变化检测的基本流程及相关技术	21
1.4.3 对象级变化检测国内外研究现状	26
1.4.4 对象级变化检测面临的挑战	29
参考文献	30
第 2 章 基于模拟退火遗传算法的高光谱遥感影像波段选择	45
2.1 问题分析	45
2.2 模拟退火遗传算法	46
2.3 基于模拟退火遗传算法的高光谱遥感影像波段选择方法	48
2.3.1 子空间分解	48
2.3.2 算法实现流程	50
2.4 实验与分析	51
2.4.1 软件工具及实验数据	51
2.4.2 分类精度评价	52
2.4.3 AVIRIS 高光谱数据实验	54
2.4.4 HYDICE 高光谱数据实验	59
参考文献	61

第 3 章 基于 Choquet 模糊积分优化的 SAGA 高光谱遥感影像波段选择	64
3.1 问题分析	64
3.2 Choquet 模糊积分	65
3.3 基于 Choquet 模糊积分优化的 SAGA 高光谱遥感影像波段选择方法	66
3.3.1 子空间内波段排序	66
3.3.2 算法实现流程	68
3.4 实验与分析	69
3.4.1 AVIRIS 高光谱数据实验	69
3.4.2 HYDICE 高光谱数据实验	74
参考文献	75
第 4 章 基于多目标粒子群优化算法的高光谱遥感影像波段选择	77
4.1 问题分析	77
4.2 粒子群优化算法	78
4.3 基于多目标粒子群优化算法的高光谱遥感影像波段选择方法	78
4.3.1 基于粒子群优化算法的波段选择	78
4.3.2 适应度函数	79
4.3.3 算法实现流程	81
4.4 实验与分析	82
4.4.1 AVIRIS 高光谱数据实验	82
4.4.2 HYDICE 高光谱数据实验	86
参考文献	86
第 5 章 基于后验概率支持向量机和马尔科夫场的高光谱遥感影像分类	88
5.1 问题分析	88
5.2 支持向量机分类方法	89
5.2.1 线性分类器	89
5.2.2 最优分类超平面	90
5.2.3 支持向量机的核函数	91
5.3 SVM-MRF 模型	93
5.3.1 后验概率支持向量机模型	93
5.3.2 基于后验概率的 MRF 模型	93
5.4 模拟退火求能量最小值	96
5.5 实验与分析	96
5.5.1 AVIRIS 高光谱数据实验	96
5.5.2 HYDICE 高光谱数据实验	98

参考文献	99
第 6 章 基于多示例学习和支持向量机的高光谱遥感影像分类	102
6.1 问题分析	102
6.2 多示例学习方法	103
6.2.1 多示例学习问题	103
6.2.2 基于多示例学习的常见分类算法	106
6.3 模糊 K 均值聚类方法	109
6.4 基于多示例学习和支持向量机的高光谱遥感影像分类方法	110
6.4.1 波段选择	110
6.4.2 分割提取空间特征	110
6.4.3 聚类生成多示例包	110
6.4.4 算法实现流程	111
6.5 实验与分析	111
6.5.1 AVIRIS 高光谱数据实验	111
6.5.2 HYDICE 高光谱数据实验	114
参考文献	115
第 7 章 基于 JSEG 与归一化互信息的高分辨率遥感影像配准	117
7.1 问题分析	117
7.1.1 图像配准的基本框架	117
7.1.2 图像配准的分类	118
7.1.3 存在的问题与研究思路	119
7.2 JSEG 与 NMI 相结合的配准方法	121
7.2.1 多尺度控制点提取	121
7.2.2 基于 NMI 的控制点匹配	123
7.2.3 基于 Delaunay 三角形的图像配准	125
7.3 实验与分析	125
7.3.1 数据集 1 实验	126
7.3.2 数据集 2 实验	130
7.3.3 数据集 3 实验	133
参考文献	136
第 8 章 基于小波变换与改进 JSEG 算法的高分辨率遥感影像多尺度分割	140
8.1 问题分析	140
8.2 JSEG 算法及存在的关键问题	142
8.2.1 JSEG 算法实现	142
8.2.2 JSEG 在高分辨率遥感影像分割中的关键问题	142

8.3 WJSEG 算法实现流程	144
8.3.1 量化与小波变换	144
8.3.2 多尺度分割	147
8.3.3 区域合并	148
8.4 实验与分析	149
8.4.1 eCognition 影像分割	149
8.4.2 数据集 1 实验与目视分析	150
8.4.3 数据集 2 实验与目视分析	152
8.4.4 定量分析	154
参考文献	156
第 9 章 基于多尺度融合的对象级高分辨率遥感影像变化检测	160
9.1 问题分析	160
9.2 研究方法	161
9.2.1 对象提取	161
9.2.2 对象特征提取及比较	162
9.2.3 多尺度融合	163
9.3 方法实现流程	165
9.4 实验与分析	165
9.4.1 数据集 1 实验	166
9.4.2 数据集 2 实验	170
9.4.3 尺度依赖性及融合策略分析	173
9.4.4 不同融合策略变化强度差异分析	175
参考文献	175
第 10 章 一种对象级高分辨率 SAR 影像洪水灾害变化检测	178
10.1 问题分析	178
10.2 研究方法	180
10.2.1 基于轮廓波变换的噪声抑制及标记点提取	180
10.2.2 基于标记点的分水岭分割及区域合并	185
10.2.3 虚假目标消除	185
10.3 实验与分析	186
10.3.1 水体提取实验	188
10.3.2 水体区域变化检测实验	194
参考文献	197
索引	201

第1章 绪论

1.1 概述

遥感 (remote sensing) 即遥远感知, 是在不直接接触的情况下获取远方信号并使之成像^[1,2], 对目标或自然现象远距离探测和感知的一种技术^[3]。

随着遥感技术的不断发展, 遥感影像呈现出覆盖范围广泛、高空间分辨率、低成本、更加丰富的光谱分辨率可供选择等发展趋势, 这些因素都有利于进一步促进利用遥感影像进行城市规划、土地覆盖、变化监测等方面的应用。

1.1.1 高光谱分辨率遥感

与传统的多光谱扫描仪相比, 高光谱影像的成像光谱仪能够得到上百通道、连续波段的影像^[4], 每个影像像元可以提取一条光谱曲线^[5]。与传统的多光谱遥感相比, 高光谱遥感有连续光谱, 因而从高光谱影像的每个影像像元都可以进一步提取出一条连续的光谱曲线^[6]。高光谱成像光谱仪进行的光谱成像是一种连续的、不间断的“面”上光谱成像, 所得到的影像数据具有高光谱分辨率、图谱合一、光谱在一定范围内连续成像等特点^[7]。与此同时, 这些影像通常有数十或数百个接近的光谱波段, 这将导致在高光谱影像分类识别时要面临高冗余度和计算量庞大的问题^[8]。高光谱遥感 (hyperspectral remote sensing) 中 “hyper”的原意是“过量的、过多的”, 这首先就意味着其光谱信息量的巨大^[9]。图 1.1 显示了一个原始高光谱影像。



图 1.1 原始高光谱影像

高光谱遥感影像的主要特点是将传统的空间维与光谱维信息融为一体，在获取地表空间影像的同时，得到地物的连续光谱，从而实现依据地物光谱特征进行反演与地物识别的目的^[10]。高光谱数据的特点决定了高光谱影像具有较其他遥感影像更强的地物识别与精细分类能力。

在高光谱数据谱分析中，一般首先借助地面测量与实验室数据分析得到具有诊断性意义的地物光谱特征，建立代表地物特性的“指纹光谱”(spectral signature)^[11]；接着针对高光谱影像中每个像元的光谱反射曲线，基于光谱匹配与特征分析，利用光谱信息直接识别地物^[12~14]；或者通过分析地物不同状态下光谱特征的细微变化，建立地物内在的特性和光谱波形形态的定量关系，实现地物精细分类以及理化参量的定量反演^[15]。

高光谱影像相对于多光谱影像而言，可以在一定范围内连续成像，因此可以更加精确地探测到地物的光谱特性。但是，在带来一系列优点的同时，高光谱影像的波段数目也大大增加，这使得一些传统的多光谱影像处理方法无法直接应用于高光谱影像处理中，需要对高光谱影像进行一定的降维处理。经过降维处理之后，多光谱影像处理中的一些算法就可以移植到高光谱影像处理中。与传统的多光谱影像处理相比，高光谱影像数据处理存在着以下问题。

1) 计算量增加

高光谱数据量的急速增加使得计算机处理速度下降，虽然如今软硬件技术的发展可以缓解这一压力，但是数据的计算量随着数据量的增加呈四次方增长，无法满足人们对实时性处理的要求。

2) 统计参数的估计偏差增大

当影像的波段数增多时，所需的样本也随之增多。为了获得比较准确的参数估计，所需的训练样本数是已有波段一定的倍数。然而，遥感影像的训练样本数往往是有限的，如果不能获得足够多的训练样本数，就难以保证参数估计的准确性，这样就导致传统统计分类方法的性能明显下降。而在样本数不变的情况下，分类精度随所使用波段数的变化会呈现出 Hughes 现象^[16]，即在样本数一定的情况下，分类精度随波段增加上升到一定程度后不再增加反而开始下降^[17]，而降维正是消除高光谱影像分类中的 Hughes 现象的主要方法。

3) 数据冗余度高

高光谱影像的波段数目众多，但各波段之间存在着高相关性和高冗余度。因此，通过特征选择或特征提取的方法对原始数据进行降维，不会对结果造成很大的影响，反而会减少运算的时间、提高运算效率，同时也会较好地解决高光谱影像维数众多和样本数较少之间的矛盾。

可见，高光谱影像所具有的识别微弱信息和定量探测的优势，使得其成为遥感技术的主要发展趋势，对于高光谱遥感影像处理方法的研究可以提升高光谱影像

的性能，更好地识别和探测地物。因此，开展新的适用于高光谱遥感影像处理降维和分类算法研究具有重要意义。

1.1.2 高空间分辨率遥感

高空间分辨率遥感影像带来了更加丰富的空间信息，能够更好地反映地物的光谱、纹理、形状等细节特征，同时具有定位精度高、实时性强、对比度高等诸多优点。高空间分辨率遥感应用的主要领域包括：

- (1) 城市遥感。在市政基础设施建设过程中，政府部门和有关部门用高分辨率遥感数据识别和更新基础工程建设，如街道、桥梁等。
- (2) 基础理论测绘。卫星新技术的发展，为高级测绘产品的生产提供了丰富的数据源，扩大了卫星测绘应用的范围。
- (3) 精细农业。利用高空间分辨率遥感卫星可以精细划分地块作物的种类和长势，使得解译工作变得相对简单。
- (4) 环境监测与评价。可以利用高分辨率遥感影像进行排污监测与评价，取得更高的准确性。
- (5) 社会公众信息服务。近年来，国际上出现了以高空间分辨率遥感数据为背景的地理空间信息服务软件和网站，使得高空间分辨率遥感影像数据成为社会公众所熟悉和接受的主流空间信息。

目前，高空间分辨率遥感影像处理面临的挑战主要有：①数据量大；②细节复杂；③数据获取时间长而困难；④受政策影响大；⑤价格过高。

1.2 高光谱遥感影像降维和分类方法研究现状

高光谱遥感影像处理包括：辐射校正和几何纠正、影像整饰、投影变换、镶嵌、降维、分类以及各种专题处理。目前所用的高光谱影像基本上都经过了辐射校正和几何纠正，因此不必考虑。而降维与分类作为高光谱遥感影像处理中两个非常重要的部分，成为遥感领域重点研究的对象。

1.2.1 数据降维方法

目前，高光谱数据的降维方法主要是基于高光谱影像的光谱特征、空间特征或是结合光谱和空间特征，既能够针对特定地物或者像元进行光谱维特征挖掘，还能从影像空间维和光谱特征维进行综合挖掘。这些大体分成两类：第一类是对全部的波段，进行线性的或非线性的高维向低维的映射变换，这就是特征提取 (feature extraction)^[18]；第二类是从所有的几十个甚至几百个全部波段中选出最合适、最有用的波段，这就是特征选择 (feature selection)^[19]。

1.2.1.1 特征提取方法

特征提取是指通过一定的规则将原始数据变换到另一空间，在变换后的空间中，原始数据的大部分信息集中在低维，用低维数据代替原始数据来进行后续处理。特征提取方法可将信息有效地转换压缩到低维空间，因此，在高光谱影像降维中的应用十分广泛。特征提取方法以提取高光谱遥感影像的特征为目的，利用低维数据来有效地表达高维数据的特征，同时压缩数据量，有利于信息的快速提取。在特征提取过程中，原始的特征需要经过加工、处理和优化产生有效的特征空间，使之能更好地反映对象本质，适合于分类器的处理。根据不同的研究目的或者前提假设，可以设计不同的特征提取方法，从而获得不同的低维数据。低维数据的维度是原来高维数据的实际维度（或称为固有维度），是高维数据的本质属性之一，获得这种属性的方法可以是线性的，也可以是非线性的。特征提取方法的代表性算法如下。

1. 线性特征提取方法

1) 主成分分析

主成分分析 (principal components analysis, PCA) 是最基本的高光谱数据特征提取方法，是一种线性变换。它以方差为准则，将原始数据特征变换为相关性较小的几个特征，去掉变换系数相对较小的特征，因此信息量不会有太大的损失。该变换的提出有一套严密的逻辑推理过程。

PCA 变换是基于信息量的一种正交线性变换，具体为：计算输出主成分波段，第一主成分包含最大的数据方差，第二主成分包含第二大的方差，以此类推，最后的主成分波段包含很小的方差，选择前三个至四个主成分，在降低数据维数的同时最大限度地保持了原始数据的信息^[20–24]。因此，PCA 在特征提取、混合像元分解、地物分类和目标探测等领域得到了广泛的应用。

在 PCA 变换的基础上，Jia 和 Richards 提出了分块主成分分析方法^[25]，该方法利用了高相关块沿对角线分布的特点，沿相关矩阵对角线进行分组，并对每组进行主成分变换，最后将每组的变换结果结合在一起进行进一步的分析。Fraser 和 Green 提出了定向主成分分析 (directed PCA, DPCA)，该方法是计算两个比值影像的主成分，可以消除植被干扰进行矿物蚀变填图^[26]。Chavez 和 Kwarteng 提出了选择主成分分析 (selective PCA)^[27]，该方法能够准确地预测目标特征信息，并将特征信息集中于某一成分中，但该方法仅对少数具有显著光谱特征的地物（如水、植被等）具有良好的效果。

PCA 变换存在两个明显的缺陷：一是影像数值变化影响明显，二是变换后的信噪比并不一定随着主成分编号的增加而降低。针对这两个问题分别发展了标准化的 PCA(standardized PCA, SPCA) 和残差调整的 PCA(residual-scaled PCA,

RPCA)。SPCA 将协方差矩阵中各元素除以对应原始变量的标准差, 得到一个由各变量的相关系数构成的矩阵, 然后再利用该矩阵计算线性变换的系数。为了消除噪声的影响, Roger 和 Arnold 提出了 RPCA 变换^[28]。RPCA 采用了与 SPCA 类似的思想, 充分利用高光谱影像间的高相关性, 一个波段中可以利用其他波段通过多元线性预测的部分作为信号, 不能预测的残差作为噪声, 波段间的相关性越高得到的残差越接近噪声^[29]。从这一角度看, RPCA 变换与最大噪声分数变换 (MNF)、噪声调整的主成分 (NAPC) 变换原理相同, 只是噪声评估方式和噪声调整方法不同, 同样 RPCA 变换的结果与数值变化无关。此外, 针对 PCA 中噪声的影响, 后来也提出了一些优化算法, 主要有最小/最大自相关因子分析 (minimum/maximum autocorrelation factor, MAF)、最大噪声分数变换 (maximum noise fraction, MNF) 和噪声调整的主成分变换 (noise-adjusted principal component, NAPC) 等。

2) 最小/最大自相关因子分析

与 PCA 不同, 最小/最大自相关因子分析 (MAF) 主要考虑了影像的空间特征^[30]。相比于 PCA, MAF 不再是基于数据的方差, 而是基于影像数据的自相关性^[31]。

3) 最大噪声分数

Green 等以最大噪声分数 (MNF) 为准则代替方差来提取特征, 变换后的各特征以信噪比从大到小排列^[32]。MNF 变换中均设定数据之间线性相关, 但是在某些情况下这一假定会使得变换后的数据出现某些人为特征, 这样不仅没有达到去除噪声的目的, 而且新出现的特征会影响对数据的分析。为此 Gordon 提出了通用 MNF 变换 (generalized MNF, GMNF), 采用该变换不仅可以去除影像中的噪声, 而且不会产生人为特征^[33]。

4) 噪声调整的主成分变换

噪声调整的主成分变换 (NAPC) 基本等同于 MNF 变换, 只是将其中的广义特征值求解的问题简化而已^[34]。经 NAPC 变换得到的对角矩阵中, 对角线元素要求满足大于等于 1 的条件, 一般 NAPC 变换后, 最后几个成分的特征值接近于 1。当采用中值滤波方法对噪声矩阵进行评估时, 得到的对角矩阵部分元素特征值小于 1, 主要是因为在 NAPC 变换中假定信号和噪声不相关, 且噪声在空间上也不相关, 而在噪声估计过程中一般不满足该要求。如采用中值滤波时, 得到的噪声影像通常包含原始影像的高频成分, 含有一定的轮廓信息, 这些信息在空间上具有很强的相关性。

在 NAPC 变换方法基础上, Roger 提出了一种 Fast-NAPC 变换方法^[35], 对原有的算法进行了进一步的改进。

5) 典型分析

前几种特征提取方法的目的是采取一定的映射变换将原特征空间变换到新的

特征空间，使之达到某种意义上的最优化。然而典型分析 (canonical analysis, CA) 是以分类目标为准则，使变换后类内样本分布得到集聚，而类间距离相对拉开^[36]。基于 CA 变换的特征提取方法类内与类间距离，可以通过选择不同的变换矩阵来实现。

这种方法的好处是，总的类内离散度矩阵的秩为满秩 n ，可以得到 n 个互不相关的特征，根据可分离性判据的性质，逐步增加特征数量，可以使分类精度得到逐步提高。

6) 小波变换

小波变换法作为一种新的降维方法在高光谱影像降维中得到越来越多的应用^[37]。由于高光谱影像的每个像元都可以获得一条连续的光谱响应曲线，通过对每个像元的光谱曲线进行小波分解，可以较好地提取光谱特征。小波变换是一种局部变换，可以较好地保持地物的局部特性，从而更有利于地物的分类和识别。

7) 非负矩阵分解

在科学的研究中，讨论利用矩阵分解来解决实际问题的分析方法很多，如 PCA 等，但在所有方法中，原始的大矩阵 V 被近似分解为低秩的 $V = WH$ 形式。Lee 和 Seung 提出了一种新的矩阵分解思想，也是就是非负矩阵分解 (non-negative matrix factorization, NMF) 算法^[38]。这种算法具有收敛速度快等特点。

8) 最佳基特征提取法

用于高光谱分类的最佳基特征提取法由 Kumar 等提出，该方法可以将相邻波段子集提取成特征更少的子集，有 TD-GLDB (top-down generalized local discriminant bases) 和 BU-GLDB(bottom-up generalized local discriminant bases) 两种方法^[39]。前者是进行自上而下的搜索，每次回归地将数据分成两个子集，并用均值代替后一个子集；后者是自下而上地进行积累，将相邻的波段构造成累积树后，再进行特征提取。

9) 类间可分性特征提取

类间可分性特征提取 (discriminant analysis feature extraction, DAFFE) 的目的是找到一个变换矩阵 A 使得数据 Y 的类间可分性最大^[40]。类间可分性通过类内的变化和类间平均变化之比来衡量，类内变化通过类内散度变化矩阵来表示，类间变化通过类间散度矩阵来表示。该方法的优点是不需要知道数据的分布形式，缺点是当类别不单一时，利用该方法进行特征提取的效果不是很理想。

10) 投影寻踪法

投影寻踪方法 (projection pursuit, PP) 是一种专门处理高维数据的特征提取方法^[41,42]，已被成功地推广到多元回归、多元密度估计、时间序列分析和神经网络学习等领域，其思想在高光谱特征提取与分类方面有着广泛的应用^[43]。

投影寻踪就是寻找使投影指标达到最优的投影 (矩阵) A ，它的一般过程为：选

定投影指标，它反映何种结构是我们感兴趣的；寻找使投影指标最优的投影 A ，这意味着投影后的数据含有最多我们感兴趣的结构信息；将这部分结构信息从原始数据中“剔除”，得到改进了的结构，然后重复寻优过程，寻找新的投影，直到数据的任何投影都不再显著地含有我们感兴趣的结构为止。

2. 非线性特征提取方法

1) 独立成分分析

独立成分分析 (independent component analysis, ICA) 是揭示隐藏在随机变量、测量或信号集里的统计和计算方法，主要目的是解决盲源分离问题 (blind source separation, BSS)^[44,45]。ICA 定义了所观察到的多变量数据模型，它通常表示为数据库中一个大的样本。在该模型中，数据变量被假定为一些未知潜在变量的线性混合，而且混合系统也是未知的。潜在变量被假定是非高斯的且相互独立，它们被称为观察到数据的独立成分。这些独立成分，也称为源或因素，可以通过 ICA 被发现。ICA 将源信号的独立性作为分解依据，采用了高阶统计量，而且处理过程常常要引入非线性环节，因此 ICA 技术要高于常用的基于二阶统计量的线性处理技术，如 PCA 等^[46]。

2) 非线性主成分分析

非线性主成分分析，也称为核主成分分析 (kernel PCA, KPCA)，是在确保原始数据信息量丢失最小的原则下，在各个变量相关关系研究的基础上，将多个变量的信息压缩为几个能反映原始数据特征的综合变量指标，并据此特征信息指标对数据进行综合分析，可以有效地处理变量间的非线性关系，为解决多指标的综合评价提供一种很好的手段^[47]。KPCA 是核方法的一种，其原理是将核方法运用到 PCA 上，以解决传统 PCA 无法提取非线性特征的问题，从而优化特征提取结果。核方法的基础是样本空间到特征空间的一种非线性映射，利用核方法可以高效地计算内积和有效地降低分类平面的复杂度，并且使样本空间映射到任意维特征空间变成可能，有效地解决传统线性特征提取中丢失非线性特征的问题。

3) 基于流形学习的方法

非线性降维是一种对高维数据进行数据挖掘的手段。“流形学习”(manifold learning) 是非线性降维中采用的主要方法之一，这类方法建立在如下基本假设上：高维数据在特征空间中对应的点分布在“低维流形”上。因此，只要找到各个点在“低维流形”上的坐标，就可以实现降维。由于“低维流形”通常是非线性的，所以将流形学习归为非线性降维方法。基于流形学习的非线性降维最大的特点是保持数据的相对几何结构，即在高维空间中靠近的点，在低维空间中仍然靠近。流形学习的具体实现方法包括局部线性嵌入 (locally linear embedding, LLE)^[48]、等距映射 (isometric feature mapping, ISOMAP)^[49]、拉普拉斯特征映射 (Laplacian eigenmap)。

在数据的全局几何结构未知(通常呈非线性)的情况下,欧氏距离只在很小的邻域内才有意义。因此,需要用这些已知的局部欧氏距离来逼近能有效表征数据全局几何结构的测地距离^[50]。ISOMAP 算法^[51]的主要思想是使用流形上的测地线距离代替不能表示内在流形结构的欧氏距离,然后应用多维尺度(multidimensional scaling, MDS)算法,进而发现潜藏在高维空间的低维坐标。所谓任意两点在流形上的测地线距离是两点之间沿着流形的最短路径。

1.2.1.2 特征选择方法

在高光谱遥感影像降维中,特征选择主要是围绕从所有的几十或者几百个波段中选出若干个波段,这些波段保证是最有效的组合方式,用于后续的高光谱影像的分类识别或目标检测等,该波段组合能够在识别或检测过程中得到最高的精度、最好的效果。它针对特定应用目标,从海量信息中选取若干有效波段用于分析,在保证精度的同时降低数据量、提高运算效率。特征选择是选出原始特征空间中的某个子集,该子集是一个简化的特征空间,包含了主要的光谱特征。

对于高光谱影像来说,每个波段都可以看做是一个特征,因此特征选择的过程也可看做是波段选择的过程。目前,高光谱影像的波段选择方法主要有以下几种。

1. 基于信息量的波段选择方法

影像的信息量可以用多种标准来衡量,但因为高光谱影像数据之间的高相关性,那些相关性高的波段组合未必能获得最高的信息量。因此,基于信息量进行波段选择时,应选出那些信息量大而相关性小的波段组合,波段选择时主要考虑的因素是熵、方差、协方差矩阵行列式以及最佳指数。

1) 熵与方差

熵^[52]可以用来表征信息量,它是总体平均意义上的概念,一幅 8bit 的影像 X 上的每个像元所携带的平均信息量可用熵 H 来表示:

$$H(X) = \sum_{i=0}^{255} P_i \log_2 P_i \quad (1.1)$$

其中, P_i 为影像像素灰度值为 i 的概率。

方差代表影像中像元的灰度值与均值的偏离程度,是影像信息大小的一种度量。作为特征选择的准则,影像的方差越大,其所包含的信息也越丰富。第 i 个波段的方差定义为

$$\sigma_i^2 = \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N [f_i(x, y) - \bar{f}_i]^2 \quad (1.2)$$

其中, $M \times N$ 为影像的大小, $f_i(x, y)$ 为第 i 个波段 (x, y) 位置处的像素灰度值, \bar{f}_i 为窗口内像素灰度的平均值。