



主办: 中国科学院遥感与数字地球研究所
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象图形学报

2016
07
VOL.21

ISSN1006-8961
CN11-3758/TB



人脸图像处理 P865



第21卷第7期（总第243期）

2016年7月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院
主办单位 中国科学院遥感与数字地球研究所
中国图象图形学学会
北京应用物理与计算数学研究所

主 编 顾行发
编辑出版 《中国图象图形学报》编辑出版委员会
邮政信箱 北京9718信箱
邮 编 100101
电子信箱 jig@radi.ac.cn
电 话 010-64807995
网 址 www.cjig.cn

广告经营许可证 京朝工商广字第0361号
总 发 行 北京报刊发行局
订 购 全国各地邮局
海外发行 中国国际图书贸易集团有限公司
(邮政信箱：北京399信箱 邮编：100048)
印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian

Monthly, Started in 1996

Superintended by Chinese Academy of Sciences
Sponsored by Institute of Remote Sensing and Digital Earth, CAS
China Society of Image and Graphics
Institute of Applied Physics and Computational Mathematics


Editor-in-Chief Gu Xingfa
Editor, Publisher Editorial and Publishing Board of Journal of
Image and Graphics
P.O.Box 9718, Beijing, P.R.China
Zip code 100101
E-mail jig@radi.ac.cn
Telephone 010-64807995
Website www.cjig.cn

Distributed by Beijing Bureau for Distribution of Newspapers and Journals
Domestic All Local Post Offices in China
Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China))
Printed by Beijing Kexin Printing Co., Ltd.


CN 11-3758/TB
ISSN 1006-8961
CODEN ZTTXFZ
国外发行代号 M1406
国内邮发代号 82-831
国内定价 60.00元



大规模柔体的连续碰撞检测算法(第901页)



大规模流体场景的真实感与实时模拟(第913页)



星载SAR影像上船舶方位向模糊去除算法(第951页)

图像处理和编码

低存储化压缩感知

王金铭, 叶时平, 徐振宇, 蒋燕君 835

3D-HEVC深度图像快速帧内编码方法

张洪彬, 伏长虹, 陈锐霖, 萧允治, 苏卫民 845

加权KNN的图文数据融合分类

康丽萍, 孙显, 许光奎 854

结合肤色分割与平滑的人脸图像快速美化

邱佳梁, 戴声奎 865

图像分析和识别

级联型P-RBM神经网络的人脸检测

叶学义, 陈雪婷, 陈华华, 顾亚风, 吕秋云 875

结合全局与局部信息活动轮廓的非同质图像分割

郝智慧, 郭满才, 宋杨杨 886

计算机图形学

带参数的多项式势函数与构造基于Metaball的过渡曲线

李军成, 宋来忠, 刘成志 893

大规模柔体的连续碰撞检测算法

周清玲, 刘艳, 程天翔 901

虚拟现实与增强现实

大规模流体场景的真实感与实时模拟

邵绪强, 杨晓丹, 李继荣, 阎蕾 913

医学图像处理

形状约束下活动轮廓模型冠脉血管图像多尺度分割

郭笑妍, 梅雪, 李振华, 曹佳松, 周宇 923

遥感图像处理

深度置信网络在极化SAR图像分类中的应用

邓磊, 付姗姗, 张儒侠 933

高光谱图像低秩表达与噪声水平估计

唐中奇, 付光远, 赵晓林, 陈进, 张利 942

星载SAR影像上船舶方位向模糊去除算法

邴磊, 邢前国, 邹娜娜, 李圳波, 吴樊 951

TDFA: 一种生成空间影像金字塔的方法

张云舟, 张陌, 王晋年, 张刚 959

无人机侦察视频超分辨率重建方法

张岩, 李建增, 李德良, 杜玉龙 967

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



Continuous collision detection algorithm for large-scale deformable objects (P901)



Realistic and real-time simulation of large-scale fluids (P913)



Application of deep belief network in polarimetric SAR image classification (P951)

Image Processing and Coding

- Reducing the storage space of the measurement matrix for compressive sensing
Wang jinming, Ye shiping, Xu zhenyu, Jiang yanjun 835
- Fast intra coding for depth map in 3D-HEVC
Zhang Hongbin, Fu Changhong, Chan Yuilam, Siu Wanchi, Su Weimin 845
- Fusion method via KNN with weight adjustment for the classification of image-text co-occurrence data
Kang Liping, Sun Xian, Xu Guangluan 854
- Fast facial beautification algorithm based on skin-color segmentation and smoothness
Qiu Jialiang, Dai Shengkui 865

Image Analysis and Recognition

- Cascaded probability state-restricted Boltzmann machine for face detection
Ye Xueyi, Chen Xueting, Chen Huahua, Gu Yafeng, Lyu Qiuyun 875
- Inhomogeneous image segmentation based on active contours with global and local information
Hao Zihui, Guo Mancai, Song Yangyang 886

Computer Graphics

- The polynomial potential function with a parameter and transition curve based on Metaball technology
Li Juncheng, Song Laizhong, Liu Chengzhi 893
- Continuous collision detection algorithm for large-scale deformable objects
Zhou Qingling, Liu Yan, Cheng Tianxiang 901

Virtual Reality and Augmented Reality

- Realistic and real-time simulation of large-scale fluids
Shao Xuqiang, Yang Xiaodan, Li Jirong, Yan Lei 913

Medical Image Processing

- Multi-scale segmentation of coronary artery image based on active contour model with shape constraints
Guo Xiaoyan, Mei Xue, Li Zhenhua, Cao Jiasong, Zhou Yu 923

Remote Sensing Image Processing

- Application of deep belief network in polarimetric SAR image classification
Deng Lei, Fu Shanshan, Zhang Ruxia 933
- Low-rank representation for hyperspectral image noise level estimation
Tang Zhongqi, Fu Guangyuan, Zhao XiaoLin, Chen Jin, Zhang Li 942
- Azimuth ambiguity removal method for ship detection based on spaceborne SAR images
Bing Lei, Xing Qianguo, Zou Nana, Li Zhenbo, Wu Fan 951
- TDFA: a generation method of spatial image pyramid
Zhang Yunzhou, Zhang Mo, Wang Jinnian, Zhang Gang 959
- Super-resolution reconstruction for UAV video
Zhang Yan, Li Jianzeng, Li Deliang, Du Yulong 967

中图法分类号: TP751 文献标识码: A 文章编号: 1006-8961(2016)07-933-09

论文引用格式: Deng L, Fu S S, Zhang R X. Application of deep belief network in polarimetric SAR image classification[J]. Journal of Image and Graphics, 2016, 21(7): 933-941. [邓磊, 付珊珊, 张儒侠. 深度置信网络在极化 SAR 图像分类中的应用[J]. 中国图象图形学报, 2016, 21(7): 933-941.] [DOI:10. 11834/jig. 20160711]

深度置信网络在极化 SAR 图像分类中的应用

邓磊, 付珊珊, 张儒侠

首都师范大学资源环境与旅游学院, 北京 100048

摘要: **目的** 深度置信网络能够从数据中自动学习、提取特征, 在特征学习方面具有突出优势。极化 SAR 图像分类中存在海量特征利用率低、特征选取主观性强的问题。为了解决这一问题, 提出一种基于深度置信网络的极化 SAR 图像分类方法。**方法** 首先进行海量分类特征提取, 获得极化类、辐射类、空间类和子孔径类四类特征构成的特征集; 然后在特征集基础上选取样本并构建特征矢量, 用以输入到深度置信网络模型之中; 最后利用深度置信网络的方法对海量分类特征进行逐层学习抽象, 获得有效的分类特征进行分类。**结果** 采用 AIRSAR 数据进行实验, 分类结果精度达到 91.06%。通过与经典 Wishart 监督分类、逻辑回归分类方法对比, 表现了深度置信网络方法在特征学习方面的突出优势, 验证了方法的适用性。**结论** 针对极化 SAR 图像海量特征的选取与利用, 提出了一种新的分类方法, 为极化 SAR 图像分类提供了一种新思路, 为深度置信网络获得更广泛地应用进行有益的探索和尝试。

关键词: 极化雷达; 深度置信网络; 图像分类; 深度学习; 遥感; 特征学习

Application of deep belief network in polarimetric SAR image classification

Deng Lei, Fu Shanshan, Zhang Ruxia

College of Resource Environment and Tourism, Capital Normal University, Beijing 100048, China

Abstract: **Objective** Several problems exist in polarimetric synthetic aperture radar (SAR) image classification, such as feature selection subjectivity and low utilization efficiency of massive features. Deep belief network (DBN) has a significant advantage in feature learning, which can be used in learning and extracting effective features from massive original features. Based on this observation, a polarimetric SAR image classification method based on DBN is proposed. **Method** The proposed method is capable of level-by-level learning and abstracting for the mass original polarimetric features. First, the original polarimetric feature sets are extracted from polarimetric SAR images. Second, 20 000 samples are selected, and feature vectors are constructed. Each pixel contains 267 original polarimetric features and class labels. Thus, a pixel is a sample, namely, a feature vector. The feature vector is used as input in the DBN model. Then, the DBN model is built to extract abstract features, namely, effective features. These features are achieved through level-by-level learning. Finally, the logistic regression, a classifier at the top of the DBN model, is applied to classify the entire polarimetric SAR image. **Result** Considering AIRSAR data as an example, the overall classification accuracy can reach a high accuracy of 91.06%. The DBN method shows outstanding advantage in feature learning. Simulation experiments show that compared with the tra-

收稿日期: 2015-11-23; 修回日期: 2016-02-23

基金项目: 国家自然科学基金项目(40801172); 北京市自然科学基金项目(4142011)

第一作者简介: 邓磊(1976—), 男, 副教授, 2007 年于北京师范大学获地图学与地理信息系统专业博士学位, 主要研究方向为遥感图像处理与应用。E-mail: edenglei@qq.com

Supported by: National Natural Science Foundation of China(40801172)

ditional Wishart supervised classification algorithm, the DBN algorithm performs much better in classification. Simultaneously, the necessity of the DBN model has been proven by comparing with the logistic regression classification. The logistic regression classification classifies the polarimetric image using the original polarimetric features without any deep learning and extraction. In brief, the effectiveness of the DBN model has been validated through analysis and comparison. **Conclusion** In this study, a novel polarimetric SAR image classification method is proposed. Mass polarimetric features of the polarimetric SAR image are utilized for the first time through the DBN. The advantages and applicability of the proposed method are analyzed. Overall, a novel method is proposed for polarimetric SAR image classification, which paves the way for further research and offer beneficial attempts for the utilization of DBN in polarimetric SAR image processing.

Key words: polarimetric SAR; deep belief network; image classification; deep learning; remote sensing; feature learning

0 引言

极化合成孔径雷达(PolSAR)是一种高分辨率成像系统,具有全天时全天候、穿透云雨的能力,并且包含丰富的地物目标信息,是遥感领域发展的主要方向之一^[1-2]。极化描述的是电磁波的电场矢量端点作为时间函数形成的空间轨迹,能够反映电磁波的矢量特性。因此极化 SAR 能够通过复散射矩阵描述目标的散射机理,提供更为丰富的信息,在图像分类和识别中具有很多优势。研究表明,利用极化 SAR 数据进行土地覆盖分类能获得更高的精度^[3-5]。随着极化 SAR 系统的发展,ASAR/ENVISAT、PALSAR/ALOS 和 RADARSAT-2 等极化数据越来越丰富,极化 SAR 图像分类也成为了一项重要研究课题。

目前,极化 SAR 图像分类的主要方法为根据目标地物的散射特性提取特征,并选择合适的分类器进行图像分类^[6-7]。从极化 SAR 数据中可获取大量特征,采用多种特征组合进行图像识别与分类已得到广泛应用,如辐射信息、极化分解信息、子孔径分解信息等。虽然有些方法取得了令人鼓舞的进展,但特征选取问题一直是困扰学者们的一大难题^[8]。传统的选取方式主要依靠人工选取、依赖于专业知识并很难有效利用海量的特征数据,耗时费力^[9]。

深度置信网络(DBN)为有效的目标特征选取提供了可能性。它是几种主要深度学习(DL)模型之一,含有多层的多感知器机器学习结构^[10-11]。它通过组合原始特征形成更为抽象的高层特征表达,从而学习到更加有效的特征,是一种能够从数据中自动学习、提取特征的方法。在特征学习方面表现出的优势使得 DBN 在学术界引起了广泛的关注,并

成功应用于仿生学、语音识别、互联网以及图像识别等领域^[12-14]。但是在遥感领域的应用仍处于初步发展阶段^[15-17],尤其在图像分类方面的应用十分薄弱。吕启等人^[18]首次将深度置信网络应用于极化 SAR 图像分类中,但只是将模型与极化 SAR 数据的机械组合。到目前为止,尚未发现采用深度置信网络对极化 SAR 分类特征进行学习利用,然后进行分类的相关工作。

从极化 SAR 数据中可以提取众多分类特征,但海量分类特征在分类过程中具有很大的冗余,并且随着分类特征数量的增加,分类精度并不会提高,甚至有可能降低。另一方面,如果仅主观选取部分分类特征,由于特征利用率低,分类精度也难以达到较高的水平。因此特征的选择与利用一直是一个难题。针对极化 SAR 特征数量大、选取与利用困难的问题,提出了一种基于深度置信网络的极化 SAR 图像分类方法。利用深度置信网络模型对数据的海量分类特征进行学习,充分挖掘数据之间的深层关系,获得利于分类的有效特征进行图像分类。通过与传统的 Wishart 监督分类、逻辑回归分类方法作对比,证明了该方法的有效性。

1 DBN 图像分类模型

极化 SAR 图像包含丰富的极化信息,从中可获得丰富的分类特征参数。研究表明,分类精度强烈依赖于分类特征的选取。DBN 作为一种深度学习模型,在特征选择与特征学习方面有着显著的优势。DBN 能够进行分类特征学习,充分挖掘极化 SAR 数据中丰富的信息,从而提升分类效果。对 DBN 图像分类模型进行构建,如图 1 所示。

1.1 分类特征提取

分类特征是进行极化 SAR 图像分类的基础。




图 1 DBN 分类模型

Fig. 1 DBN classification model

分类特征提取的目的是获得丰富的、能够描述极化 SAR 信息的特征集,作为 DBN 模型的输入。对极化 SAR 数据进行分类特征提取,共获得特征参数 267

个,主要包括:极化类信息 64 个、辐射类信息 17 个、空间类信息 157 个和子孔径类信息 29 个。

1.1.1 极化类信息

极化 SAR 数据包含丰富的地物信息,极化分解是一种有效的描述地物极化信息的方法。选取不同的极化分解方法可以得到不同的分解特征参数^[19]。本文选取的极化分解方法有 Cloude 分解、Huynen 分解、Freeman2 分解、Yamaguchi4 分解等(详细分解方法及结果见表 1)。除此之外提取了描述极化散射信息的参数,例如散射差异性信息等。通过极化分解和极化散射参数的提取,共获得极化类信息特征 64 个。

表 1 极化类信息

Table 1 Polarization Information

名称	极化类特征
Barnes 分解	Barnes1 (T11/T22/T33) , Barnes2 (T11/T22/T33)
Huynen 分解	Huynen (T11/T22/T33)
Holm 分解	Holm1 (T11/T22/T33) , Holm2 (T11/T22/T33)
Cloude 分解	Cloude (T11/T22/T33)
Freeman 分解	Freeman2 (Vol/Grd) , Freeman (Vol/Odd/Dbl)
VanZyl3 分解	VanZyl (Vol/Odd/Dbl)
Yamaguchi 分解	Yam3 (Vol/Odd/Dbl) , Yam4 (Vol/Odd/Dbl/HI)
Neumann2 分解	Neum2 (Mod/Pha)
Krogager 分解	Krog (S/D/H)
Touzi 分解	Touzi ($\alpha/\alpha1/\alpha2/\alpha3/\tau1/\tau2/\tau3$)
H/A/Alpha 分解	H、A、 $\alpha/\alpha1/\alpha2/\alpha3$ 、PedestalHeight、DERD、ShannonEntropy、SERD、PolarizationAsymmetry、PolarizationFraction、RadarVegetationIndex
散射信息	Predominance Depolarization index、Conformity Coefficient

1.1.2 辐射类信息

散射系数矩阵、极化散射功率矩阵等参数可完全描述目标散射回波的幅度、相位等目标散特性。从极化 SAR 数据中提取的辐射类信息就是描述极化数据基本的原始辐射信息(如相位等)以及彼此间关系(如相关系数)的特征。共提取辐射类特征 17 个,如表 2 所示。

1.1.3 空间类信息

空间信息是地物目标在空间域或变换域的分布信息以及统计信息,能够对地物结构、纹理特征进行表达,是图像分类中的重要参数。分别从极化 SAR 数据的 SPAN、T11、T22、T33 提取空间类特征,包括:基于灰度共生矩阵(GLCM)的纹理信息、基于统计的空间信息和基于边缘的空间信息(详见表 3)。灰

表 2 辐射类信息

Table 2 Radiation Information

名称	辐射类特征
相干矩阵	T11/T22/T33
振幅相关系数	Coef_HH-VV
相位差	PD_HH-VV
比率	R_db (CP/XP/HH-VV)
T3 相关系数	Coef_R12 (Mod/Ph) , Coef_R23 (Mod/Ph) , Coef_R13 (Mod/Ph) , Coef_CCC (Mod/Ph)
总功率	SPAN

度共生矩阵纹理信息主要是求取 0°、45°、90°、135° 这 4 个方向的对比度、均匀性等参数;基于统计的空间信息主要是提取平均差、方差等统计特征参数。共提取空间类信息特征 157 个。

表 3 空间类信息
Table 3 Space information

名称	空间类特征
基于 GLCM 的纹理特征	mean(0/45/90/135), dissim(0/45/90/135), homo(0/45/90/135), H(0/45/90/135), contrast(0/45/90/135), unifor(0/45/90/135), Texture((VL/VA/VL/U))
基于统计的特征	mean, median, mean_deviation, variance, midian_deviation, euclidian_distance, skyw- ness, kurtosis, energy, coefficien_variation
边缘特征	Canny, POA5

1.1.4 子孔径类信息

子孔径分解是利用目标极化特性随视角不同而有所差异的原理,将极化 SAR 数据分解为多个低分辨率但视角不同的子图像。此处采用方位向分解的方式获得两幅子孔径图像,即维持距离向分辨率不变的同时,沿方位向进行分解。提取的特征包括子孔径差异特征和子孔径相干特征。子孔径差异特征主要将从两幅子孔径图像获得的 $H/A/\alpha$ 分解参数、Freeman3 分解参数、Yamaguchi4 分解参数进行差值,从而获得差异特征。子孔径相干特征主要指复相干信息、一致性信息和相位差异。共获得子孔径类特征 29 个如下:

1) 子孔径差异特征: diff_H, diff_A, diff_alpha, diff_Freeman (Vol/Odd/Dbl), diff_Yamguchi4 (Vol/Odd/Dbl/Hlx)。

2) 子孔径相干特征: Interfere_Int (HH/HV/VV), Interfere_pha (HH/HV/VV), Interfere_am (HH/HV/VV), Coherence_Int (HH/HV/VV), Coherence_pha (HH/HV/VV), Coherence_am (HH/HV/VV), Phase diversity。

1.2 DBN 学习

深度置信网络由多个堆叠的限制性玻尔兹曼机 (RBM) 单元与一个反向传播 (BP) 网络构成。在具体训练过程中分为预训练和微调两步,如图 2 所示。预训练过程采用非监督贪婪方法自低层到顶层逐层训练每个 RBM,低一层的 RBM 输出作为高一层 RBM 的输入,并在此过程中更新权重。预训练结束后得到的权重作为 DBN 网络的初始权重,然后采用监督学习的方式进行网络的微调,其原理为 BP 网络,即通过最小化顶层输出与预期输出的误差来调节整个网络。

RBM 可以看为一个二部图,由可视层 (v) 和隐藏层 (h) 组成,同一层单元之间没有连接, v 层与 h




图 2 DBN 训练

Fig. 2 DBN Train




图 3 限制性玻尔兹曼机 (RBM)

Fig. 3 Restricted Boltzmann machine (RBM)

层之间通过权重 w 全连接 (如图 3 所示)。假设隐藏层与可视层神经元为二值 (0 或 1), RBM 可用联合概率分布来表示,其联合组态能量函数为

$$E(v, h | \theta) = - \sum_{i=1}^I b_i v_i - \sum_{j=1}^J a_j h_j - \sum_{i=1}^I \sum_{j=1}^J w_{ij} v_i h_j \quad (1)$$

式中, $\theta = \{w_{ij}, a_j, b_i\}$ 是 RBM 参数, w_{ij} 表示可视层与隐藏层之间的连接权重, a_j 和 b_i 分别为隐藏层和可视层单元的偏置项。由于可视层和隐藏层都满足 Boltzmann 分布,当输入可视层 v 时,可以由激活函数 $P(h | v)$ 得到隐藏层 h ,然后根据 $P(h | v)$ 可以将隐藏层 h 重建可视层单元 v' ,与此同时调节参数 θ 。反复执行上述步骤,直至由隐藏层 h 重构的可视层 v' 与原始输入的可视层 v 相同,此时获得的隐藏层就是可视层单元的另一种表达,即作为可视层输入数据的有效特征。当给定可视层或隐藏层神经元状态时,隐藏层与可视层单元的激活概率分别为

$$P(h_j = 1 | v) = \frac{1}{1 + \exp(- \sum_i w_{ij} v_i - a_j)} \quad (2)$$

$$P(v_i = 1 | h) = \frac{1}{1 + \exp(- \sum_j w_{ij} h_j - b_i)} \quad (3)$$

RBM 模型的参数优化过程可以看作对模型能量最小化过程,即使重构误差 (重构的可视层 v' 与原始的可视层 v 之间的误差) 最小。在其非监督训

练过程中通常采用对比散度 (CD) 方式来更新权重参数^[20], 即

$$\frac{\partial \ln p(v, \varphi)}{\partial W} = \Delta w = \epsilon(E_{\text{data}}(v_i h_j) - E_{\text{recon}}(v_i h_j)) \quad (4)$$

$$\frac{\partial \ln p(v, \varphi)}{\partial a} = \Delta a = \epsilon(E_{\text{data}}(h_j) - E_{\text{recon}}(h_j)) \quad (5)$$

$$\frac{\partial \ln p(v, \varphi)}{\partial b} = \Delta b = \epsilon(E_{\text{data}}(v_i) - E_{\text{recon}}(v_i)) \quad (6)$$

式中, ϵ 为学习率, $E_{\text{data}}(\cdot)$ 是将可见状态值取为训练样本值时得到的依赖数据的期望值, 为整个网络单元的联合概率分布期望值; $E_{\text{recon}}(\cdot)$ 是可见单元为随机二值状态时的期望值。

2 基于 DBN 的极化 SAR 图像分类

从极化 SAR 数据中提取丰富的分类特征, 然后利用 DBN 学习有利于图像分类的有效分类特征。首先对极化 SAR 数据进行分类特征提取, 获得包含极化类信息、辐射类信息、空间类信息和子孔径类信息 4 类特征集, 为深度置信网络提供有效的输入; 然后利用 DBN 进行逐层学习, 将分类特征进行抽象与组合, 获取有效分类特征, 用于最终的分类; 最后运用逻辑回归的方法进行分类。流程如图 4 所示。




图 4 基于 DBN 极化 SAR 分类流程图

Fig. 4 Polarimetric SAR classification flow chart based on DBN

具体算法实现步骤为:

1) 分类特征提取。对经过滤波、地理编码等预处理的极化 SAR 数据进行分类特征提取, 采用 5×5 的移动窗口, 提取极化类、辐射类、空间类和子孔径类特征共 267 个, 形成分类特征集。

2) 特征矢量构建。在分类特征集的基础上, 人工选取样本、定义类别标签。每个像元即为一个样本, 由 267 个分类特征和类别标签构成, 称之为特征矢量。通过特征矢量构建可以获得众多带标签的样本, 每个样本为 267×1 的 1 维矢量。特征矢量的构建为 DBN 提供输入。

3) DBN 提取有效分类特征。对上述样本特征矢量进行归一化处理, 作为 DBN 可视层节点的输入。DBN 结构为 267-80-80-80-6。第 1 层为可视层, 共 267 个节点, 对应输入特征矢量的 267 个特征; 第 2 层、第 3 层、第 4 层均为隐藏层, 各有 80 个节点; 第 5 层为输出层, 共 6 个节点, 对应 6 种地物类别。DBN 可以对输入的特征矢量逐层进行抽象学习, 从而获得有利于分类的有效分类特征。

4) 逻辑回归分类。DBN 顶层为逻辑回归函数, 对学习到的有效分类特征进行决策判断, 作为最终的输出, 用来得到最终的地物类别。

3 实验与分析

3.1 实验数据

实验数据为 1994 年 NASA/JPL AIRSAR 系统 C 波段极化 SAR 图像, 地点为美国旧金山地区, 图像大小为 281×309 像素。雷达飞行方向自西向东, 方位向分辨率为 9.3 m, 距离向分辨率为 6.6 m, 如图 5 所示。通过目视解译看出, 研究区包含多种地物, 如海洋、湖泊、建筑、道路、林地等。将海洋、湖泊等合并为水体类别, 公园中茂密植被和城区中的草地等划分为草地, 由于雷达图像散射机制不同, 建筑划分为与雷达方位向平行的正建筑和与方位向有一定夹角的斜建筑。将实验区地物划分为水体 (WT)、林地 (FO)、草地 (GS)、正建筑 (OB)、斜建筑 (NB) 和道路 (RO) 6 类。

为了保证模型的实用性与分类结果评价的准确性, 采用人工选取的方式均匀选取 20 000 个像素点, 作为样本, 然后平均分为训练样本和测试样本两部分 (表 4)。训练样本用于训练深度置信网络, 测

试样本用于分类精度验证。




图5 旧金山地区 AIRSAR C 波段 Pauli 图像
Fig. 5 San Francisco AIRSAR c-band Pauli images

表4 样本数据统计表

Table 4 Sample data

地物类别	训练样本/像元数	测试样本/像元数
水体	1 222	1 256
林地	4 109	4 264
草地	972	986
正建筑	1 021	953
斜建筑	819	796
道路	1 857	1 745

3.2 参数设置

软件仿真环境为 Win7 下安装的 Matlab2012b, 电脑机器配置为 Intel (R) Xeon CPU E5-2650, 2 GHz, 64.0 GB RAM。通过参考前人经验^[21-22]与实际测试,在 Matlab 中对模型参数设置如下:DBN 网络层数为 5,结构为 267-80-80-80-6,学习率设置为 0.1,动量学习率设置为 0.05,迭代次数设为 1 000。为了提高网络的训练速度,采用批处理的方法进行训练。批训练大小为 100,即每次随机选取 100 个样本输入到网络中进行训练。

3.3 实验结果与分析

将本文提出的基于深度置信网络的分类方法与传统的 Wishart 监督分类^[23]方法进行比较,结果如图 6 所示。通过观察可发现,Wishart 分类方法对水体分类效果较好,但是总体分类表现欠佳,林地和建筑有严重的混分现象。本文方法能够清晰辨识 6 类地物,较好表现了地物类别细节,尤其是建筑的分类效果有了极大的改善,总体分类效果明显优于 Wishart 分类。为了详细论证方法的有效性,对分类

结果进行定量评价。定量评价主要包含 4 个指标因子:混淆矩阵、Kappa 系数、总体精度(OA)、用户精度(UA)和生产者精度(PA)^[24]。




图6 旧金山地区分类结果图
Fig. 6 Classification result on San Francisco
(a) Wishart classification; (b) proposed DBN classification)

3.3.1 DBN 学习对分类精度的影响

DBN 学习可以抽象出有效的分类特征。为了评估 DBN 模型对分类结果的影响,将直接采用分类特征的逻辑回归分类(LR)与 DBN 学习后的有效分类特征的逻辑回归分类(DBN-LR)进行对比,分类结果的混淆矩阵分别如表 5、表 6 所示。分类总体精度由 86.87% 上升至 91.06%,提高约为 5%。Kappa 系数由 0.825 上升至 0.881,上升约 0.6。同时,各个类别的用户精度和生产者精度均有所提升,其中道路用户精度由 81% 上升至 91%,提高为 10%;草地由 68% 上升至 77%,提升为 9%;斜建筑由 83% 上升至 88%,提升 5%;正建筑由 91% 上升至 97%,提升 6%;水体用户精度虽然没有上升但其生产者精度提升了 5%。以上结果表明,

表5 LR 方法分类精度

Table 5 Classification accuracy of logistic regression

类别	FO	WT	GS	NB	OB	RO	UA/%
FO	980	1	60	111	4	54	81
WT	1	3 990	63	0	0	97	96
GS	33	124	668	0	1	158	68
NB	100	0	0	862	39	40	83
OB	4	0	0	65	728	6	91
RO	46	137	112	57	3	1 480	81
PA/%	84	94	74	79	94	81	
OA/%	86.87			Kappa:0.825			

表 6 DBN-LR 方法分类精度
Table 6 Classification Accuracy of DBN-LR

类别	FO	WT	GS	NB	OB	RO	UA/%
FO	1 055	2	32	116	1	50	84
WT	1	4 100	94	0	0	69	96
GS	66	11	758	3	0	148	77
NB	50	0	0	838	24	41	88
OB	2	0	0	17	772	5	97
RO	17	30	87	27	1	1 583	91
PA/%	89	99	78	84	97	83	
OA/%	91.06			Kappa 0.881			

DBN 方法可对粗糙的分类特征进行学习抽象, 获得更有效的分类特征, 进而提高了各地物的分类精度。

3.3.2 分类特征类型对分类结果的影响

3.2.1 节表明 DBN 学习能够获得更为有效的

分类特征。本节将进一步探讨当输入到 DBN 模型中的分类特征改变时, 对分类结果的影响。

保持数据预处理方式与 DBN 网络模型不变, 改变分类特征组合方式, 对分类特征类型的影响进行定量评估。图 7 为采用不同分类特征组合的用户精度直方图。其中 Pol 为只考虑极化类信息作为分类特征, Pol&Rad 为极化类信息与辐射类信息共同作为分类特征, Pol&Rad&TF 为极化类信息、辐射类信息和子孔径类信息共同作为分类特征, all 为本文提出的 4 类特征全部应用的分类精度。对比发现, 随着分类特征类型的增加, 各个类别的用户精度都有所提升。其中草地由 62.72% 升至 78.00%, 提高约为 15%, 正建筑由 87.97% 上升至 97.00%, 上升约 9%, 道路由 76.00% 上升至 83.00%, 上升 7%, 斜建筑由 79.62% 上升到 84%, 上升约 5%。这表明分类特征的丰富性有助于提高分类精度。




图 7 不同分类特征类型组合之用户精度
Fig. 7 User accuracy of different features combinations

图 8 显示了不同分类特征组合的分类结果细节图。通过观察发现, 当分类特征类型很少时, 如图 8(a), 草地与林地混分现象严重, 特征类型增加很大程度上改善了此类现象, 提高了草地的分类效果, 如图 8(d)。同样, 当使用的分类特征类型较少时, 如图 8(e), 道路很难被识别, 随着特征类型的增加, 如图 8(f)(g), 道路分类情况得到提高, 但脉络不连贯, 本文方法(图 8(h))能够完整连贯的对道路进行分类。图 8(i)(j) 部分建筑分为林地且道路不明显, 本文方法(图 8(l))建筑与道路

边界清晰, 分类效果较好。上述结果表明分类特征类型增加有利于提高图像分类效果, 与图 7 得出结果一致。

通过分析发现分类特征类型的增加有助于提高分类精度。其原因是分类特征类型的增加使其对极化 SAR 数据的描述更为丰富、准确, DBN 可利用的原始信息增加。虽然可能包含冗余信息, 但深度置信网络具有处理大规模海量数据的能力与良好的数据挖掘能力, 因此 DBN 模型对极化 SAR 数据的分类精度上升, 利用能力上升。




图 8 不同分类特征类型组合类细节图

Fig. 8 Classification details of different features

combinations ((a) Pol-GS; (b) Pol&Rad-GS; (c) Pol&Rad&TF-GS; (d) all-GS; (e) Pol-RO; (f) Pol&Rad-RO; (g) Pol&Rad&TF-RO; (h) all-RO; (i) Pol-NB; (j) Pol&Rad-NB; (k) Pol&Rad&TF-NB; (l) all-NB)

4 结 论

极化 SAR 数据可以提取的分类特征众多,利用 DBN 对分类特征进行学习,避免了人为选取分类特征时存在的特征利用率低、分类精度不高的状况。主要贡献在于首次将 DBN 应用于极化 SAR 的分类特征抽象、学习工作。通过 DBN 学习,不仅能够充分利用丰富的分类特征,同时避免了人为特征选择过程中存在的问题。通过传统的 Wishart 监督分类方法以及不经过特征学习的逻辑回归方法进行对比,验证了方法的有效性,实现了极化 SAR 数据的高精度分类。验证了深度置信网络在极化 SAR 分类中的可行性与有效性,对深度置信网络理论在极化 SAR 图像处理中的应用有一定的借鉴作用。由于极化 SAR 数据具有众多波段,本文研究采用 C 波段数据,因此将深度置信网络应用于不同波段极化 SAR 数据中进行分类是接下来的主要研究工作。

参考文献 (References)

- [1] Wang W G, Lu F, Sun Z W, et al. A novel unsupervised classifier of polarimetric SAR Images[J]. Procedia Engineering, 2011, 15: 1595-1599. [DOI: 10.1016/j.proeng.2011.08.297]
- [2] Lee J S, Pottier E. Polarimetric Radar Imaging: From Basics to Applications[M]. Boca Raton: CRC Press, 2009. [DOI: 10.1201/9781420054989.ch1]
- [3] Freitas C D C, Soler L D S, Sant'Anna S J S, et al. Land use and land cover mapping in the Brazilian Amazon using polarimetric airborne P-band SAR data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(10): 2956-2970. [DOI: 10.1109/TGRS.2008.2000630]
- [4] Formont P, Pascal F, Vasile J P, et al. Statistical classification for heterogeneous polarimetric SAR images[J]. IEEE Journal of Selected Topics in Signal Processing, 2011, 5(3): 567-576. [DOI: 10.1109/JSTSP.2010.2101579]
- [5] Ince T. Unsupervised classification of polarimetric SAR image with dynamic clustering: an image processing approach[J]. Advances in Engineering Software, 2010, 41(4): 636-646. [DOI: 10.1016/j.advengsoft.2009.12.004]
- [6] Lee J S, Hoppel K W, Mango S A, et al. Intensity and phase statistics of multilook polarimetric and interferometric SAR imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 1994, 32(5): 1017-1028. [DOI: 10.1109/36.312890]
- [7] Xu F, Jin Y Q. Deorientation theory of polarimetric scattering targets and application to terrain surface classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(10): 2351-2364. [DOI: 10.1109/TGRS.2005.855064]
- [8] VanZyl J J. Unsupervised classification of scattering behavior using radar polarimetry data[J]. IEEE Transactions on Geoscience and Remote Sensing, 1989, 27(1): 36-45. [DOI: 10.1109/36.20273]
- [9] Mao S S, Chen B, Wang S, et al. Polarimetric SAR image classification via naive Bayes combination[J]. Journal of Xidian University, 2015, 42(2): 45-51. [毛莎莎, 陈博, 王爽, 等. 贝叶斯集成框架下的极化 SAR 图像分类[J]. 西安电子科技大学学报: 自然科学版, 2015, 42(2): 45-51.] [DOI: 10.3969/j.issn.1001-2400.2015.02.008]
- [10] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554. [DOI: 10.1162/neco.2006.18.7.1511]
- [11] Bengio Y, Delalleau O. On the expressive power of deep architectures[C]//Proceedings of the 22nd International Conference. Berlin Heidelberg: Springer, 2011: 18-36. [DOI: 10.1007/978-3-642-24412-4_3]
- [12] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural

- Information Processing Systems, 2012, 25(2): 1106-1114.
- [13] Jaitly N, Nguyen P, Senior A, et al. Application of pretrained deep neural networks to large vocabulary speech recognition [C]//Proceedings of Interspeech. Portland, USA: Interspeech Communication Association, 2012.
- [14] Yu K, Jia L, Chen Y Q, et al. Deep learning: yesterday, today, and tomorrow[J]. Journal of Computer Research and Development, 2013, 50(9): 1799-1804. [余凯, 贾磊, 陈雨强, 等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799-1804.]
- [15] Lyu Q, Dou Y, Niu X, et al. Classification of land cover based on deep belief networks using polarimetric RADARSAT-2 data [C]//IEEE International Geoscience and Remote Sensing Symposium. Quebec City, QC, Canada: IEEE, 2014: 4679-4682. [DOI: 10.1109/IGARSS.2014.6947537]
- [16] Han J, Zhang D, Cheng G, et al. Object detection in optical remote sensing images based on weakly supervised learning and high-level feature Learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(6): 3325-3337. [DOI: 10.1109/TGRS.2014.2374218]
- [17] Dong C, Loy CC, He K-M, et al. Learning a deep convolutional network for image super-resolution[C]//Proceedings of the 13th European Conference. Switzerland: Springer International Publishing, 2014: 184-199. [DOI: 10.1007/978-3-319-10593-2_13]
- [18] Lyu Q, Dou Y, Niu X, et al. Remote sensing image classification based on DBN model[J]. Journal of Computer Research and Development, 2014, 51(9): 1911-1918. [吕启, 窦勇, 牛新, 等. 基于 DBN 模型的遥感图像分类[J]. 计算机研究与发展, 2014, 51(9): 1911-1918.] [DOI: 10.7544/issn1000-1239.2014.20140199]
- [19] Deng L, Yan Y N, Wang C Z. Improved POLSAR image classification by the use of Multi-Featurecombination[J]. Remote Sensing, 2015, 7(4): 4157-4177. [DOI: 10.3390/rs70404157]
- [20] Hinton G E. Training products of experts by minimizing contrastive divergence[J]. Neural Computation, 2002, 14(8): 1771-1800. [DOI: 10.1162/089976602760128018]
- [21] Hinton G E. A practical guide to training restricted Boltzmann machines[M]//Montavon G, Orr G B, Müller K R. Neural Networks: Tricks of the Trade. 2nd ed. Berlin Heidelberg, Germany: Springer, 2012: 599-619. [DOI: 10.1007/978-3-642-35289-8_32]
- [22] Bengio Y. Practical recommendations for gradient-based training of deep architectures[M]//Montavon G, Orr G B, Müller K R. Neural Networks: Tricks of the Trade. 2nd ed. Berlin Heidelberg, Germany: Springer, 2012: 437-478. [DOI: 10.1007/978-3-642-35289-8_26]
- [23] Lee J S, Grunes M R, Kwok R. Classification of multi-look polarimetric SAR imagery based on complex Wishart distribution[J]. International Journal of Remote Sensing, 1994, 15(11): 2299-2311. [DOI: 10.1080/01431169408954244]
- [24] Story M, Congalton R G. Accuracy assessment: a user's perspective[J]. Photogrammetric Engineering & Remote Sensing, 1986, 52(3): 397-399.