

一种结合深度置信网络与最优尺度的植被提取方法

刘祖瑾¹, 杨玲¹, 刘祖涵^{2,3}, 段琳琳¹, 乔贤贤¹, 龚娇娇¹

¹河南大学环境与规划学院, 河南 开封 475004;

²江西师范大学鄱阳湖湿地与流域研究教育部重点实验室, 江西 南昌 330022;

³南昌工程学院江西省水信息协同感知与智能处理重点实验室, 江西 南昌 330099

摘要 针对利用现有深度学习方法进行植被提取时出现的相邻地物处于同一窗口、分类结果出现一些无用破碎图斑和“椒盐现象”等问题, 提出最优分割尺度与深度置信网络相结合的方法进行植被提取研究, 并利用光谱-纹理特征等信息进行对比实验。实验结果表明, 与现有的深度学习方法相比, 本文方法分类结果的总体精度达到91.92%, Kappa系数为0.8677, 能够有效提高实验的分类精度, 而且分类结果显示本文方法能有效减轻“椒盐现象”, 并能很好地表达影像上各类地物清晰的边界。

关键词 图像处理; 图像分析; 深度学习; 深度置信网络; 植被提取; 无人机影像

中图分类号 TP751.1

文献标识码 A

doi: 10.3788/LOP55.021001

Method of Vegetation Extraction Based on Deep Belief Network and Optimal Scale

Liu Zujin¹, Yang Ling¹, Liu Zuhan^{2,3}, Duan Linlin¹, Qiao Xianxian¹, Gong Jiaojiao¹

¹College of Environment and Planning, Henan University, Kaifeng, Henan 475004, China;

²Key Laboratory of Poyang Lake Wetland and Watershed Research, Ministry of Education, Jiangxi Normal University, Nanchang, Jiangxi 330022, China;

³Jiangxi Province Key Laboratory of Water Information Cooperative Sensing and Intelligent Processing, Nanchang Institute of Technology, Nanchang, Jiangxi 330099, China

Abstract When using the existing methods of depth learning to study the vegetation extraction, there are some problems that the adjacent objects are in the same window, and some useless crushing plots and the salt and pepper phenomenon appear. We propose a method by combining the optimal segmentation scale with the deep belief network to study the vegetation extraction, and comparison experiments are carried out with spectral-texture features and other information. Experimental results show that the overall accuracy of the proposed method is 91.92% and the Kappa coefficient is 0.8677, and the proposed method can effectively improve the classification accuracy compared with the existing deep learning methods. The classification results show that the proposed method can effectively reduce the salt and pepper phenomenon, and clear express the boundaries of objects.

Key words image processing; image analysis; deep learning; deep belief network; vegetation extraction; unmanned aerial vehicle image

OCIS codes 100.3008; 100.2960; 110.2960

收稿日期: 2017-06-26; 收到修改稿日期: 2017-07-31

基金项目: 国家自然科学基金(41101450)、鄱阳湖湿地与流域研究教育部重点实验室开放基金(PK2017002)、江西省教育厅科学技术项目(GJJ161097)、江西省水信息协同感知与智能处理重点实验室开放基金(2016WICSIP012)、河南大学优秀青年科研人才培养基金(yqpy20140016)

作者简介: 刘祖瑾(1991—), 女, 硕士研究生, 主要从事遥感与摄影测量应用方面的研究。E-mail: 1041361058@qq.com

导师简介: 杨玲(1983—), 女, 博士, 副教授, 硕士生导师, 主要从事遥感与数字摄影测量、计算机视觉方面的研究。

E-mail: yangling0606@163.com(通信联系人)

1 引言

国土绿化是生态文明建设的重要内容,是实现可持续发展的重要基石。植被作为一种重要的用于国土绿化的自然资源,是反映生态环境变化的敏感指示器^[1-2]。同时因为植被对碳具有固定作用^[3],所以对全球气候变化同样发挥着重大作用^[4]。因此,对植被类型的划分及提取研究将具有实际意义。

近年来,深度学习(DL)^[5]发展迅猛,它在许多传统任务上能够提升识别率^[6],吸引了大批学者在各个领域对其进行广泛应用,并尝试解决一些前沿问题。无人机作为高分辨率遥感影像的重要获取方式,具有成本低、效率高、时效性强等特点,已逐渐成为森林资源调查、植被提取与监测的新途径。因此,本文将 DL 方法研究中常用的深度置信网络(DBN)模型应用于无人机遥感影像植被提取中。

DBN 是含有多隐含层的多层感知器的机器学习结构^[7-8],DBN 模型是主要的 DL 模型之一。DBN 通过底层特征的组合,形成了一个更为抽象的 DBN 高层特征表达方式,从而探索到更加有用的特征信息。在特征学习方面所带来的优势使 DBN 在学术界及工业界引起了热潮^[9],并已成功应用于语音识别、物体识别、信息检索以及图像识别等多个领域^[6,10]。Tokarczyk 等^[11]将 DBN 应用于高分辨率遥感影像的特征选择和特征学习中,发现当选取窗口大小为 9×9 像素邻域作为实验样本时,分类精度较高。刘大伟等^[12]结合光谱-纹理特征对高分辨率遥感影像进行 DBN 分类,实验结果表明,与支持向量机(SVM)、最近邻算法(NN)等分类方法相比,DBN 可以更加准确地挖掘遥感影像的空间分布规律,并提高分类的准确性。然而,DBN 在高分辨率遥感影像分类领域依然处于探索阶段,存在一些不足。如 Tokarczyk 等在实验中选取样本时,窗口内可能会存在相邻不同地物,分类结果也可能会出现一些无用的破碎图斑,而且采用现有 DL 方法的分类结果依然会出现“椒盐现象”。因此,本文将最优尺度与 DBN 结合应用于无人机遥感影像植被提取,以达到减轻“椒盐现象”并提高分类精度的目的。

2 DBN 方法介绍

DBN 由 Hinton 等^[7]在 2006 年提出,并已成功应用于语音识别、物体识别、信息检索以及图像识别等领域^[13-14]。DBN 由多层受限玻尔兹曼机

(RBM)和一层反向传播(BP)神经网络构成。DBN 结构如图 1 所示。

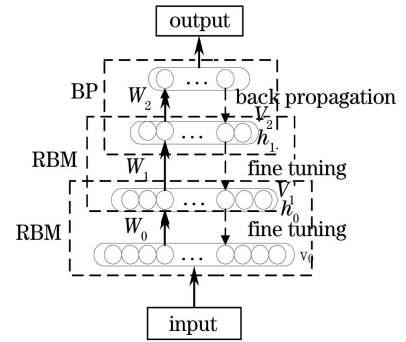


图 1 DBN 结构示意图

Fig. 1 Schematic of DBN structure

DBN 模型的训练过程分为两步:

1) 预训练。主要是将所有实验样本利用非监督方式进行 DBN 预训练,并利用贪婪算法进行逐层优化训练,在此过程中分别单独设置每层 RBM 的参数,在每一层 RBM 训练完成后,仍继续训练下一层 RBM,则该层的输入是上一层输出结果的传递,依次进行训练。

2) 微调。在设置的层数预训练完成后,再利用有监督的学习方式对最后一层 BP 神经网络进行训练,并将每层训练过程中产生的误差逐层向后传播,最后通过 BP 的方法微调 DBN 的权重。

由于传统 BP 神经网络的初始权重设置是随机的,所以会造成因训练时间长而陷入局部最优解的问题;而 DBN 的初始权重设置是预先训练好的,从而克服了传统 BP 神经网络的缺点^[12]。

RBM 模型是一个二分图模型,它包含一个随机的可见层(用 v 表示)和一个随机的隐含层(用 h 表示),所有可见层与隐含层之间存在连接,而可见层、隐含层内两两之间不存在连接,即层内节点无连接,层间节点全连接。RBM 结构如图 2 所示。




图 2 RBM 结构示意图

Fig. 2 Schematic of RBM structure

图中 m 为可见层中的神经元个数, n 为隐含层中的神经元个数; $\mathbf{v} = (v_1, v_2, \dots, v_m)^\top$ 为可见层的状态向量, v_i 为可见层中第 i 个神经元的状态; $\mathbf{h} = (h_1, h_2, \dots, h_n)^\top$ 为隐含层的状态向量, h_j 为隐含层中第 j 个神经元的状态; $\mathbf{W} = (\omega_{ij}) \in \mathbf{R}^{m \times n}$ 为隐含层与可见层间的权值矩阵, ω_{ij} 为可见层中第 i 个神经元与隐含层中第 j 个神经元的初始权值。

RBM 模型是一个能量模型, RBM 联合组态的能量函数可以表示为

$$E(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta}) = - \sum_{i=1}^m a_i v_i - \sum_{j=1}^n b_j h_j - \sum_{i=1}^m \sum_{j=1}^n \omega_{ij} v_i h_j, \quad (1)$$

式中 $\mathbf{a} = (a_1, a_2, \dots, a_m)^\top$ 为可见层的偏置向量, a_i 为可见层中第 i 个神经元的偏置; $\mathbf{b} = (b_1, b_2, \dots, b_n)^\top$ 为隐含层的偏置向量, b_j 为隐含层中第 j 个神经元的偏置; $\boldsymbol{\theta} = (\mathbf{W}, \mathbf{a}, \mathbf{b})$ 为 RBM 的参数。

利用(1)式,可以得到某个状态 (\mathbf{v}, \mathbf{h}) 的联合概率分布 $P(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta})$, 公式为

$$P(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta}) = \frac{1}{Z_{\boldsymbol{\theta}}} \exp[-E(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta})], \quad (2)$$

$$Z_{\boldsymbol{\theta}} = \sum_{\mathbf{v}, \mathbf{h}} \exp[-E(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta})], \quad (3)$$

式中 \mathbf{v} 为观测数据。与 $P(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta})$ 的边缘分布对应, 概率分布 $P(\mathbf{v} | \boldsymbol{\theta})$ 公式为

$$P(\mathbf{v} | \boldsymbol{\theta}) = P(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta}) = \frac{1}{Z_{\boldsymbol{\theta}}} \sum_{\mathbf{h}} \exp[-E(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta})]. \quad (4)$$

对于 RBM 而言, 在给定所有神经元在可见层(隐含层)状态的基础上, 各神经元在隐含层(可见层)的激活状态之间是相互独立的。隐含层(可见层)第 k 个神经元被激活的概率公式为

$$P(h_k = 1 | \mathbf{v}, \boldsymbol{\theta}) = f_{\text{sigmoid}}\left(b_k + \sum_{i=1}^m \omega_{ik} v_i\right), \quad (5)$$

$$P(v_k = 1 | \mathbf{h}, \boldsymbol{\theta}) = f_{\text{sigmoid}}\left(a_k + \sum_{j=1}^n \omega_{kj} h_j\right). \quad (6)$$

训练 RBM 就是通过调整参数 $\boldsymbol{\theta}$ 拟合给定的训练数据。通过对数似然函数可以得到参数 $\boldsymbol{\theta}$, 公式为

$$\boldsymbol{\theta}^* = f_{\arg \theta \max} L(\boldsymbol{\theta}) = f_{\arg \theta \max} \sum_{t=1}^T \ln P(\mathbf{v}^{(t)} | \boldsymbol{\theta}). \quad (7)$$

对最大对数似然函数求导, 可以获得 $L(\boldsymbol{\theta})$ 的最大值对应的参数为

$$\frac{\partial \ln L(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \sum_{t=1}^T \left[- \sum_{\mathbf{h}} P(\mathbf{h} | \mathbf{v}^{(t)}, \boldsymbol{\theta}) \frac{\partial E(\mathbf{v}^{(t)}, \mathbf{h} | \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} + \sum_{\mathbf{v}, \mathbf{h}} P(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta}) \frac{\partial E(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \right]. \quad (8)$$

通过 Hinton^[15] 提出的对比散度(CD)算法计算目标分布 \mathbf{v} , 并更新权重参数, 公式为

$$\Delta \tau \omega_{ij} = \epsilon (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}}), \quad (9)$$

$$\Delta a_i = \epsilon (\langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{recon}}), \quad (10)$$

$$\Delta b_j = \epsilon (\langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{recon}}), \quad (11)$$

式中 ϵ 为学习率; $\langle \cdot \rangle_{\text{data}}$ 为训练数据集定义分布上的期望值; $\langle \cdot \rangle_{\text{recon}}$ 为通过 CD 算法得到的目标分布的期望值。

3 基于 DBN 的无人机遥感影像植被提取

Tokarczyk 等^[11] 将 DBN 模型和多种特征组合, 分别进行了遥感影像分类研究。其实验结果表明, 当只使用 DL 分类时, 这几种分类方法的分类精度都不到 83%; 当采用结合了主成分分析(PCA)方法和归一化差分植被指数(NDVI)的 PCA+NDVI 方法后, 其精度仍没有得到改善; 当结合了纹理特征之后, 分类精度稍有提高, 但仍不到 84%; 当实验选取窗口大小为 9×9 像素的邻域作为实验样本时, 分类精度得到了较大提高, 超过了 84%。也就是说, 选取基于 9×9 像素的邻域的方法优于基于单个像素的分类方法。本文研究主要在文献[11]的基础上进行。

首先依照文献[11]中的方法, 选择窗口大小为 9×9 像素的邻域作为实验样本, 进行 DBN 植被提取。实验发现, 利用 9×9 像素的邻域选取实验样本时, 会出现相邻地物处于同一窗口、分类结果中出现“椒盐现象”的问题。然后提出了将遥感影像的最优分割尺度与 DBN 相结合的方法, 即在 DBN 分类前, 用最优分割尺度将影像分割成多个图斑, 以尽可能减轻“椒盐现象”。在分类过程中, 充分使用影像中的光谱纹理特征信息, 以提高分类精度。DBN 分类的流程如图 3 所示, 大致分为以下步骤。

1) 对无人机遥感影像分别进行 9×9 像素邻域的网格分割和最优尺度分割。

2) 在分割后的影像上, 选取 9×9 像素的邻域, 并提取光谱-纹理特征参数, 作为实验样本集。

3) 将选取的训练样本集输入 DBN 模型, 进行预训练和微调, 得到具有良好特征参数的 DBN。本文将地物分为 5 大类, 5 种不同的地物类别分别对应 5 种输出。

4) 将测试样本集用于测试 DBN 的分类结果。根据 DBN 的输出结果, 判别对应的输入测试样本的类别。

5) 利用测试样本进行精度验证。

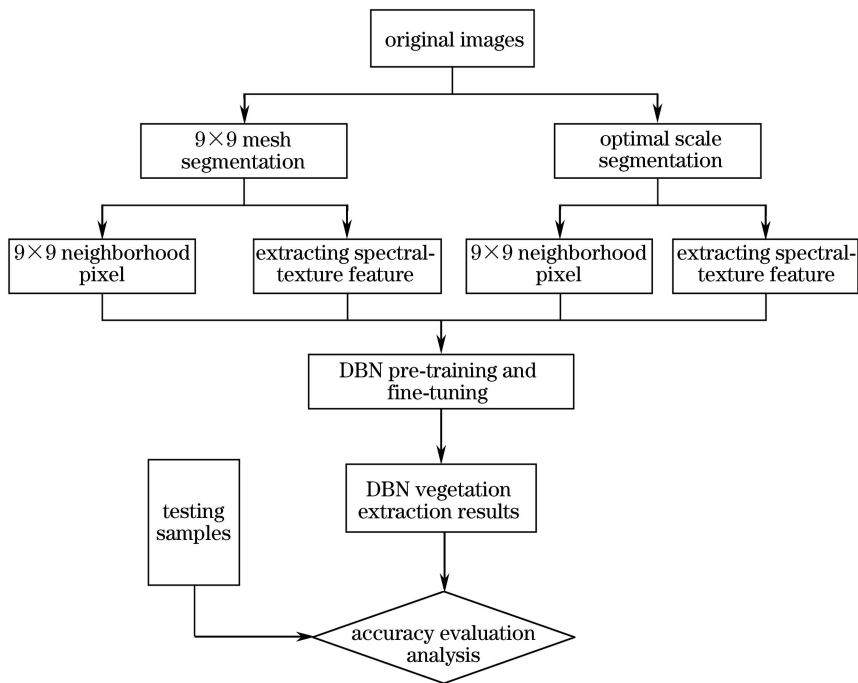


图3 DBN分类的流程图

Fig. 3 Flow chart of DBN classification

3.1 最优分割尺度计算

尺度分割是面向对象分析方法的核心和基础。因为分割的尺度对所生成的对象斑块大小和实际地物提取精度有着直接的影响,所以选择最适宜的分割尺度对遥感影像地物提取至关重要。最适宜的分割尺度不仅可以使分割后的对象斑块大小与实际地块相一致,而且能够清晰地表达每种地物类型的边界,即能用一个对象或者多个对象表示出这种地物^[16]。为了获得最适宜的分割尺度,本文提出了一种将加权均值方差、加权均值方差变化率和最大面积相结合的最优分割尺度选择方法,来进行遥感影像的最优尺度分割。实验结果表明,该方法能有效提高人为确定分割尺度的高效性和准确性。最优尺度计算流程如图4所示,具体的计算步骤如下。

1) 计算加权均值方差及方差变化率。选择熵值法确定的权重值作为各波段的权重设置,利用整幅影像中各波段方差的加权和计算加权均值方差并绘制曲线,根据曲线峰值可以初步确定相对应的最优尺度。整幅影像中各波段方差的加权和的计算公式为

$$S^2 = \sum_{L=1}^N (t_L \cdot S_L^2), \quad (12)$$

式中 N 为波段数目; L 为波段编号, $L = 1, 2, \dots, N$; t_L 为波段 L 的权重; S_L^2 为波段 L 的方差。均值

方差变化率的计算公式为

$$\Delta S^2 = S_i^2 - S_{i-1}^2, \quad (13)$$

式中 S_i^2 为对象的第 i 个像元的均值方差; S_{i-1}^2 为对象的第 $i-1$ 个像元的均值方差。

2) 确定最优分割尺度区间。将加权均值以及变化率的曲线统一到最大面积曲线平台中,三者结合可以确定最优分割尺度区间。每种地物的分割尺度范围都与相应的区间对应。

3) 将确定的最优分割尺度区间一一进行分割,根据影像整体分割效果,最终选择最优分割尺度。

3.2 基于 DBN 的实验方法

为验证本文算法的有效性,分别采用4种方法进行分类实验。

3.2.1 基于 DBN 的 9×9 像素邻域法

基于 DBN 的 9×9 像素邻域法(以下简称为“DBN+ 9×9 像素邻域法”),为避免遥感影像中的斑点噪声,对于要分类的影像上的每个像素,有必要考虑包括其周围邻域内相邻像素点的区域。依据文献[9]将整幅影像分割成 9×9 像素邻域的网格,选取窗口大小为 9×9 像素的邻域且具有代表性的实验样本进行实验,从而获得一个 243 维的特征向量,并将其作为 DBN 训练输入的向量维度。这样既增加了实验样本数量,又利用了空间相关性,以此来提高分类精度。

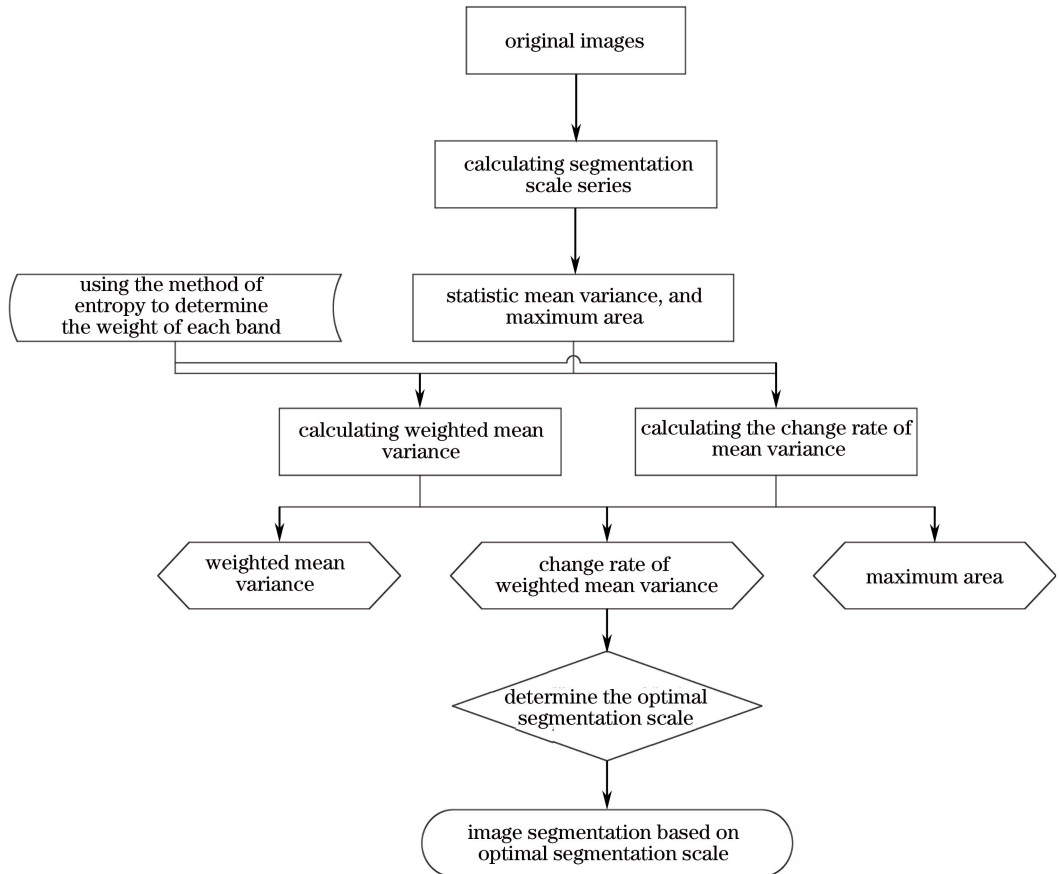


图4 最优分割尺度计算流程图

Fig. 4 Flow chart of optimal segmentation scale calculation

3.2.2 基于DBN的 9×9 像素邻域与光谱-纹理特征的结合法

基于DBN的 9×9 像素邻域与光谱-纹理特征的结合法(以下简称为“DBN+ 9×9 像素邻域+光谱-纹理特征法”),首先将整幅影像分割成 9×9 像素邻域的网格,接着将每个 9×9 像素邻域的网格面转换成点,均匀选取训练样点,并提取训练样点的光谱-纹理特征向量,共生成27维特征向量,为DBN训练提供有效的输入,然后利用DBN可以对特征向量进行逐层抽象学习,获取更加有效的分类特征,最后运用Softmax分类方法进行分类。

3.2.3 基于DBN的最优尺度与 9×9 像素邻域的结合法

基于DBN的最优分割尺度与 9×9 像素邻域的结合法(以下简称为“DBN+最优分割尺度+ 9×9 像素邻域法”),即本文方法。首先将遥感影像按照加权均值方差、加权均值方差变化率及最大面积相结合的方法选择出最优分割尺度,进行遥感影像分割,然后在具有代表性地物的分割面上选取 9×9 像素邻域的训练样本,每块 9×9 像素邻域的训练样本

代表其分割面,共生成243维特征向量,最后将其作为DBN分类输入的向量维度,进行DBN植被提取研究。

3.2.4 基于DBN的最优尺度与光谱-纹理特征的结合法

基于DBN的最优分割尺度与光谱-纹理特征的结合法(以下简称为“DBN+最优分割尺度+光谱-纹理特征法”),首先在最优分割尺度计算的基础上,将最优尺度分割后的面转换成点,接着选取具有代表性的训练样点,提取光谱-纹理特征向量,共生成27维特征向量,作为DBN分类输入的向量维度,然后利用DBN进行逐层学习,最后运用Softmax分类方法进行分类。

3.3 实验样本选取及实验参数设置

根据实地考察结果以及分析影像中研究区覆盖范围内包含的地类,将研究区划分为5大类,分别为林木、裸地、草地、道路及其他。实验采用人工方式从中均匀选取1140块图片(约 2.7×10^5 pixel)作为训练样本,选取1461块图片(约 3.5×10^5 pixel)作为测试样本,其中训练样本用于训练DBN,测试样

本用于精度评价。

实验参数依据文献[10]设置,其中学习率 ϵ 的初始值设定为0.1,隐含层偏置向量 \mathbf{b} 中各元素初始值一般设置为0,可见层偏置向量 \mathbf{a} 中各元素的计算公式为

$$a_i = \log \frac{p_i}{1 - p_i}, \quad (14)$$

式中 p_i 为第 i 个特征处于激活状态的样本所占训练样本的比例。实验将训练样本分成数个小样本集,每个小样本集均包含50个样本进行分批训练。

3.3.1 影像数据集隐含层参数设置

对于第1个实验和第3个实验中RBM隐含层节点参数设置,由于实验有效输入维度是243,且共有5种地物类别,因此输入层节点数、输出层节点数分别设置为243和5。因而DBN主要是以5为步长、5为训练起点、243为训练上限来计算不同节点数对应的重构误差。实验结果显示,在节点数为175时,重构误差最小,从而可以确定第1个隐含层的节点数为175;同理,可以采用同样方法来确定后续隐含层的节点数。

在确定DBN的深度时,参照前人的研究经验,一般将隐含层的层数设置为1~4,然后通过重构误差来确定实验参数,进行DBN训练并对影像进行分类,计算出分类后的精度系数,如图5所示。由图5可知,当隐含层数为3时,总体精度和Kappa系数最大,因此实验最终确定的DBN隐含层数为3。故DBN结构为243-175-110-80-5。DBN的第1层是可见层,共243个节点,对应输入243维特征向量;第2~4层均为隐含层,通过上述实验可知,分别有175、110和80个节点;第5层为输出层,共5个节点,分别对应5种地物类别:林木、草地、道路、裸地和其他。

3.3.2 基于光谱-纹理特征的影像数据集隐含层参数设置

对于第2个实验和第4个实验中RBM隐含层节点参数设置,由于实验有效输入维度是27,共有5种地物类别,因此输入层节点数、输出层节点数分别设置为27和5。因而DBN主要是以5为步长、5为训练起点、27为训练上限来计算不同节点数对应的重构误差。实验结果显示,在节点数为20时,重构误差最小,从而可以确定第1个隐含层的节点数为20;同理,可以采用同样方法来确定后续隐含层的节点数。

在确定DBN的深度时,参照前人研究经验,一

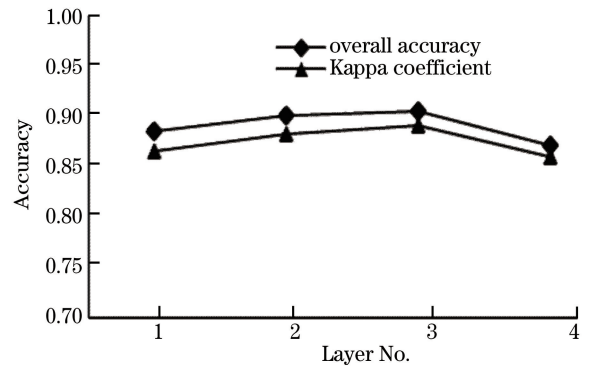


图5 DBN不同层数的分类精度(实验1和3)

Fig. 5 Classification accuracy of different DBN layers (experiments 1 and 3)

般将隐含层的层数设置为1~4,然后通过重构误差来确定实验参数,进行DBN训练并对影像进行分类,计算出分类后的精度系数,如图6所示。由图6可知,当隐含层数为3时,总体精度和Kappa系数最大,因此实验最终确定的DBN隐含层数为3。故DBN结构为27-20-20-20-5。第1层为可见层,共27个节点,对应输入27维特征向量;第2~4层为隐含层,根据上述实验可知,各有20个节点;第5层为输出层,共5个节点,分别对应5种地物类别:林木、草地、道路、裸地和其他。

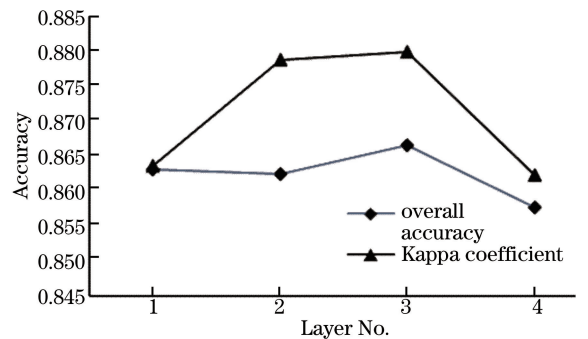


图6 DBN不同层数的分类精度(实验2和4)

Fig. 6 Classification accuracy of different DBN layers (experiments 2 and 4)

4 实验结果及分析

本文实验采用经过预处理的无人机遥感影像,数据来源于国家地球系统科学数据共享平台——黄河下游科学数据中心(<http://henu.geodata.cn>)。飞机搭载的相机型号为SONYILCE-7R,焦距为35.6268 mm,采集影像时相对航高为280 m,影像航向重叠度为81%,旁向重叠度为43%,影像地面分辨率为0.05 m。数据影像拍摄于2014年10月4日,天气晴朗。

本文以 Matlab R2010a 为实验平台,用于实现以 RBM 为基础的 DBN 模型构建,并采用熵值法确定各波段的权重。

4.1 4 种不同的基于 DBN 的实验方法的分类结果

采用 4 种不同的基于 DBN 的实验方法,无人机遥感影像植被提取得到的分类结果图分别如图 7 (a)~(d) 所示。其中鲜绿色区域为林木,深绿色区域为草地,黄色区域为裸地,灰色区域为道路,红色区域为其他。

从图 7 中可以看出:1) 基于 9×9 像素邻域窗口的分类方法能够获得较好的分类结果;2) 图 7 (b) 比图 7 (a) 的林木提取效果更好,更接近实际情况,说明通过光谱-纹理特征的分类方法能有效减少

部分地类的混分,如在林木和草地混合分布区域,能够将林地与草地区分;3) 图 7 (a) 和图 7 (b) 呈现出比较明显的“椒盐现象”,而结合最优尺度方法后,“椒盐现象”明显减轻,如图 7 (c) 与图 7 (d) 所示,由此可见,引入最优尺度的植被提取方法可以有效减轻“椒盐现象”,各类地物具有清晰边界;4) 图 7 (c) 比图 7 (d) 的分类结果更好,这是由于图 7 (d) 方法中处在阴影区域的个别地物存在相同或相近的光谱特征,使其分类结果中出现的“同物异谱”现象和“同谱异物”现象比较严重,并且某些地物无法识别,导致分类效果较差;5) 从图 7 (c) 和图 7 (d) 可以看出,最优尺度能够有效提取林木,并提取较完整的林木边缘,有利于监测植被的生长状况。

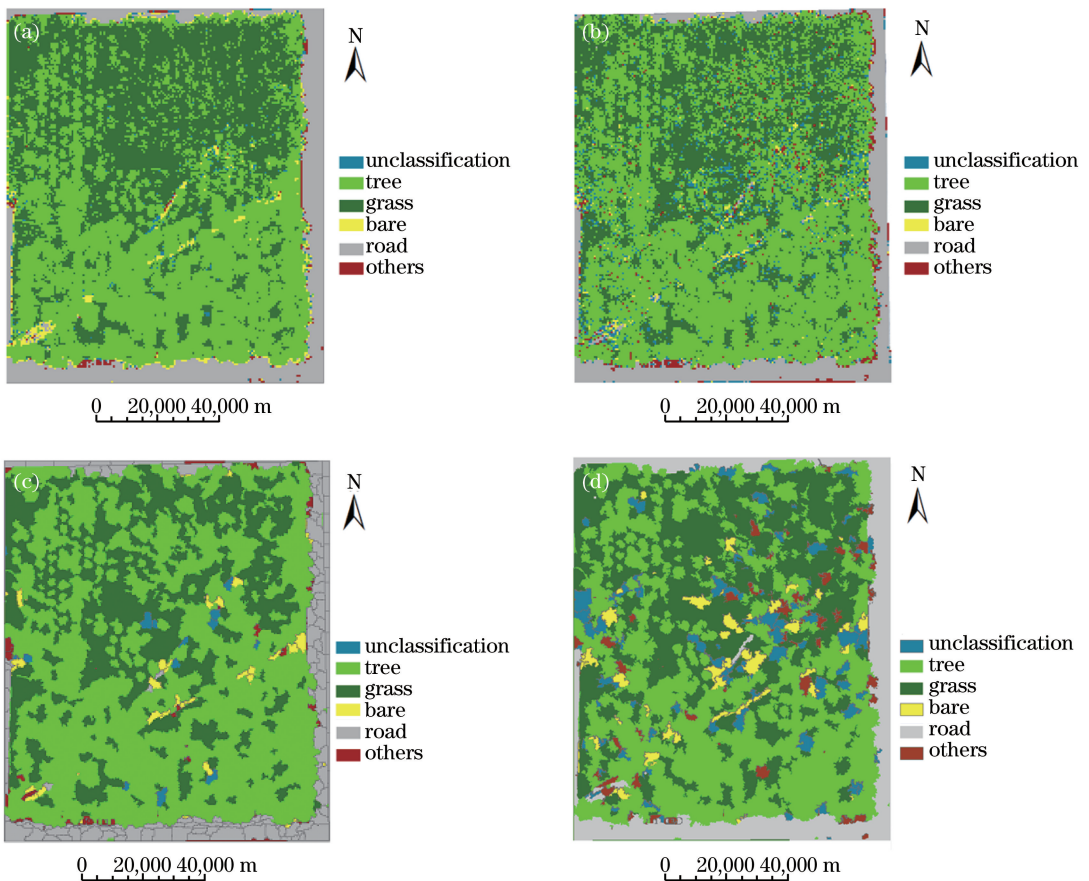


图 7 4 种不同的基于 DBN 的实验方法的分类结果图。(a) DBN+ 9×9 像素邻域;(b) DBN+ 9×9 像素邻域+光谱-纹理特征;(c) DBN+最优尺度+ 9×9 像素邻域;(d) DBN+最优尺度+光谱-纹理特征

Fig. 7 Classification maps by four different experimental methods based on DBN. (a) Classification map of DBN+ 9×9 neighborhood pixels; (b) classification map of DBN+ 9×9 neighborhood pixels+spectral-texture features; (c) classification map of DBN+optimal scale+ 9×9 neighborhood pixels; (d) classification map of DBN+optimal scale+spectral-texture features

4.2 分类精度对比评价

一般采用混淆矩阵来评估此类实验的精度。通过混淆矩阵中的指标,可以对实验结果有更清

晰的认识。不同植被提取方法的各种精度,如表 1 所示。其中,生产精度(PA)为描述正确分类的对象个数占总数的比率;用户精度(UA)为描述

地物对象被正确地分到对应地类中的比率；一般情况下,认为 Kappa 系数更能准确评价全局的分类精度。Kappa 系数为描述整幅影像的分类精度^[17]。一

表 1 不同植被提取方法的各种精度

Table 1 Various accuracies of different vegetation extraction methods

Extraction method	Accuracy				
	Kappa coefficient	Overall accuracy	PA	UA	Type
DBN+9×9 neighborhood pixels	0.8793	0.8987	0.9436	0.8856	Tree
			0.8922	0.9381	Grass
			0.8333	0.7653	Bare soil
			0.9328	0.9680	Road
			0.8435	0.8671	Others
DBN+9×9 neighborhood pixels+spectral-texture features	0.872	0.8624	0.9685	0.8865	Trees
			0.8681	0.9864	Grass
			0.5432	0.8800	Bare soil
			0.9911	0.8793	Road
			0.7632	0.8286	Others
DBN+optimal segmentation scale+9×9 neighborhood pixels	0.8677	0.9192	0.9416	0.9644	Trees
			0.9309	0.8686	Grass
			0.5714	0.6667	Bare soil
			0.9150	0.9790	Road
			0.6818	0.5000	Others
DBN+optimal segmentation scale+spectral-texture features	0.6152	0.7296	0.7973	0.8732	Tree
			0.7353	0.7453	Grass
			0.4000	0.2128	Bare soil
			0.8909	0.8167	Road
			0.5641	0.2619	Others

由表 1 可得出以下结论。

1) 4 种植被提取方法的总体分类精度由高到低依次为:DBN+最优尺度+9×9 像素邻域法、DBN+9×9 像素邻域法、DBN+9×9 像素邻域+光谱-纹理特征法、DBN+最优尺度+光谱-纹理特征法。其中 DBN+最优尺度+9×9 像素邻域法比 DBN+9×9 像素邻域法的总体分类精度更高一些,证明本文采用的分割方法和最优分割尺度选择方法具有实用性,可以保证在地物提取时的整体性,有效避免了在提取地物时过于破碎的问题;通过最优分割尺度实现了地物的合理综合,有效减少了部分地类的混分,如在林木和草地混合分布区域能够将林地与草地区分,减轻了实验结果中的“椒盐现象”。

2) 虽然应用光谱-纹理特征作为分类特征,但是处在阴影区域的个别地物存在相同或相近的光谱特征,使其分类结果中容易出现“同物异谱”现象和“同谱异物”现象,并且某些地物无法识别,因此 DBN+9×9 像素邻域+光谱-纹理特征法对植被提取的精度低于 DBN+9×9 像素邻域法,DBN+最优尺度+9×9 像素邻域法的分类精度优于 DBN+最优尺度+光谱-纹理特征法。

3) 按照文献[18]中的 Kappa 系数和分类质量的标准,可知无人机遥感影像植被提取实验结果中,除 DBN+最优分割尺度+光谱-纹理特征法外,其他 3 种植取方法的总体精度和 Kappa 系数均达到了 86%左右,实验结果达到了极高的分类质量标准。DBN+最优分割尺度+光谱-纹理特征法的总体精度为 72.96%,Kappa 系数为 61.52%,其实验结果也达到了很好的分类质量标准。

4) 综合来看,在 2 种引入最优尺度的分类方法中其他和裸地两种类别的样本数量比另外 2 种无最优尺度的 DBN 分类方法的样本数量偏少,2 种引入最优尺度的分类方法的实验结果分类精度比其余 2 种无最优分割尺度的 DBN 分类方法的实验结果分类精度偏低。由此可见,实验样本数量的多少对 DL 的分类精度有一定程度的影响,增加其样本数量可提升分类精度。

5 结 论

针对文献[11]中选择窗口大小为 9×9 像素邻域的实验样本进行植被提取研究时会出现的相邻不同地物位于同一窗口、分类结果出现“椒盐现象”等

问题,提出了将最优尺度与 DBN 算法相结合的植被提取方法。研究与分析了实验过程中的实验样本选取与 DBN 实验参数设置,并对 4 种不同的基于 DBN 的实验方法的分类结果进行了精度验证评价。实验结果表明,最优尺度与 DBN 算法相结合,实验结果的总体精度达到 91.92%, Kappa 系数为 0.8677,提高了实验的总体分类精度。通过最优分割尺度,实现了地物的合理综合,使得各类地物具有了清晰边界,可以有效减轻“椒盐现象”。本文方法可以广泛应用于植被提取以及其他类似的实验分类,且能够达到较好的分类质量标准。

参 考 文 献

- [1] Chen J Y, Tian Q J. Vegetation classification based on high-resolution satellite image [J]. *Journal of Remote Sensing*, 2007, 11(2): 221-227.
陈君颖, 田庆久. 高分辨率遥感植被分类研究 [J]. *遥感学报*, 2007, 11(2): 221-227.
- [2] Fu Y Y, Zhao Y S, Zhao W L, *et al.* Studies of typical urban vegetation classification based on brightness temperature from multiple sources [J]. *Laser & Optoelectronics Progress*, 2015 (7): 072801.
浮媛媛, 赵云升, 赵文利, 等. 基于多源亮度温度的城市典型植被分类研究 [J]. *激光与光电子学进展*, 2015(7): 072801.
- [3] Oberbauer S F, Tenhunen J D, Reynolds J F. Environmental effects on CO₂ efflux from water track and tussock tundra in arctic Alaska, USA [J]. *Arctic and Alpine Research*, 1991, 23(2): 162-169.
- [4] Jung M, Henkel K, Herold M, *et al.* Exploiting synergies of global land cover products for carbon cycle modeling [J]. *Remote Sensing of Environment*, 2006, 101(4): 534-553.
- [5] Lecun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*, 2015, 521(7553): 436-444.
- [6] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks: advances in neural information processing systems [J]. *Communications of the ACM*, 2017, 60 (6): 84-90.
- [7] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [8] Bengio Y, Delalleau O. On the expressive power of deep architectures [C]// *International Conference on Algorithmic Learning Theory*, Springer-Verlag, 2011: 18-36.
- [9] Huang H, He K, Zheng X L, *et al.* Spatial-spectral feature extraction of hyperspectral imagery based on deep learning [J]. *Laser & Optoelectronics Progress*, 2017, 54(10): 101001.
黄鸿, 何凯, 郑新磊, 等. 基于深度学习的高光谱图像空-谱联合特征提取 [J]. *激光与光电子学进展*, 2017, 54(10): 101001.
- [10] Jaitly N, Nguyen P, Senior A, *et al.* Application of pretrained deep neural networks to large vocabulary conversational speech recognition [C]// *13th Annual Conference of the International Speech Communication Association*, 2012(3): 2577-2580.
- [11] Tokarczyk P, Montoya J, Schindler K. An evaluation of feature learning methods for high resolution image classification [J]. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2012(1-3): 389-394.
- [12] Liu D W, Han L, Han X Y. High spatial resolution remote sensing image classification based on deep learning [J]. *Acta Optica Sinica*, 2016, 36 (4): 0428001.
刘大伟, 韩玲, 韩晓勇. 基于深度学习的高分辨率遥感影像分类研究 [J]. *光学学报*, 2016, 36 (4): 0428001.
- [13] Lü 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.
- [14] Li X G, Huang X Q. Deep neural networks based on hyperspectral image classification [J]. *Electronic Measurement Technology*, 2016, 39(7): 81-86.
李新国, 黄晓晴. 一种基于 DBN 的高光谱遥感图像分类方法 [J]. *电子测量技术*, 2016, 39(7): 81-86.
- [15] Hinton G E. Training products of experts by minimizing contrastive divergence [J]. *Neural Computation*, 2002, 14(8): 1771-1800.
- [16] Li N, Bao N S, Wu L X, *et al.* Study of optimal segmentation scale in object based classification for rehabilitated vegetation in coal mining site [J]. *Science of Surveying and Mapping*, 2016, 41(4): 66-71, 76.
李娜, 包妮沙, 吴立新, 等. 面向对象矿区复垦植被分类最优分割尺度研究 [J]. *测绘科学*, 2016, 41 (4): 66-71, 76.

- [17] Zhuang X, Engel B A, Xiong X P, *et al.* Analysis of classification results of remotely sensed data and evaluation of classification algorithms [J]. *Photogrammetric Engineering and Remote Sensing*, 1995, 61(4): 427-433.
- [18] Zhu Z J. Study on mine area information extraction based on object-oriented high-resolution remote sensing image classification and its application [D]. Beijing: China University of Geosciences, 2010.
祝振江. 基于面向对象分类法的高分辨率遥感影像矿山信息提取应用研究 [D]. 北京: 中国地质大学(北京), 2010.