

文章编号: 1007-4619(2008)02-0253-10

基于蚁群智能的遥感影像分类新方法

刘小平, 黎 夏, 何晋强, 艾 彬, 彭晓鹃

(中山大学 地理科学与规划学院, 广东 广州 510275)

摘 要: 智能式遥感分类是遥感研究的新热点。提出了一种基于蚁群智能规则挖掘 (antminer) 的遥感影像分类新方法。遥感数据各波段之间存在较强的相关性, 这种相关性往往会导致分类产生误差。而 antminer 算法中的信息素是基于规则整体性能的, 信息素的动态更新能有效地处理相关性较强的数据, 所提供的正反馈信息能纠正后发式函数缺陷所造成的错误。因此, 蚁群智能算法应用于遥感分类具有一定的优势。将该方法用于广州市地区的遥感影像, 取得了较好的分类结果。并与 Seg. 0 决策树方法及最大似然方法 (MLH) 进行了对比研究, 实验结果表明, 蚁群智能算法分类精度比后两者的分类精度更高。

关键词: 蚁群算法; 遥感影像; 分类; 人工智能
中图分类号: TP751.1 **文献标识码:** A

1 引 言

土地利用 / 覆盖及其变化是全球环境变化过程中的重要因子^[1]。遥感影像分类则是获取土地利用 / 覆盖数据的一项重要手段。遥感影像分类一直是遥感研究领域里的一项重要内容^[2], 是遥感应用的基石, 因为它是遥感影像转换为可用的地理数据的核心^[3]。近 30 年来, 学者们发展了大量的遥感分类方法, 这些方法基本可归纳为三大类: 基于密度分布函数的统计学分类、基于知识的专家系统分类及基于智能计算的神经网络分类等^[4]。统计学分类中最常用的方法是最大似然分类, 该方法按待分像元与样本数据的相似程度进行分类^[5-9]。它具有计算相对简单、实施方便等优点。但是, 该方法要求训练数据为正态分布, 因此训练样本的选择和参数估计直接影响分类结果, 从而难以获得较高的分类精度。专家系统分类方法综合影像的光谱信息、空间结构信息、地物分布规律及专家经验^[7-9], 对数据没有正态分布的要求, 分类规则容易理解, 分类过程符合人类的认识及思维过程, 可以在较大程度上提高分类的精度。但该方法是一种知识驱动的分类方式, 利用专家的经验获取知识往往是一

个漫长而反复的过程, 这在很大程度上限制了该方法的应用。神经网络方法具有自适应性和进行复杂并行运算的能力^[10-12], 对数据类型及数据分布函数没有限制, 可融合多种数据进行分类。不足的是, 神经网络属于黑箱结构, 难以对结果进行解释, 并存在过学习、局部最小值和收敛速度慢的问题。

近年来, 逐步发展起来的群集智能 (swarm intelligence) 理论和方法为遥感分类提供了一种新的智能化手段, 可惜, 目前在这方面的研究非常有限。群集智能是指具有简单智能的个体通过合作能够表现出复杂的智能行为, 局部个体的相互作用“涌现”出全局的格局。本文将群集智能的一个分支——蚁群智能算法尝试性地引入到遥感图像分类中, 并进行了探索性的研究。蚁群智能算法是一种源于大自然中生物世界的仿生类人工智能算法, 最初由意大利学者 Dorigo 于 1991 年提出^[13], 其本质是一个复杂的多智能体系统, 由大量的简单智能体——人工蚂蚁所组成, 人工蚂蚁通过相互合作能够有效地完成复杂任务, 例如寻找食物的最优路径。在寻找食物的过程中, 每个蚂蚁智能体根据路径上的信息作随机选择, 系统并无中心控制, 但最终整个蚁群能够得到优化, 找到一条最短路径。蚁群智能系统具有较强的鲁棒性 (robust), 不会由于

收稿日期: 2006-10-22 修订日期: 2007-05-18
基金项目: 国家杰出青年基金资助项目 (编号: 40525002)、国家自然科学基金资助项目 (编号: 40471105)、教育部博士点基金资助项目 (编号: 20040558023)、“985 工程”GIS 与遥感的地质应用科技创新平台资助项目 (编号: 105203200400006)。
作者简介: 刘小平 (1978—), 男, 博士生, 研究兴趣为地理模拟, 人工智能及定量遥感。E-mail: yiemanh@163.com
(C)1994-2019 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

一个或者某几个智能个体的故障而影响整个问题的求解。此外,蚁群算法具有很强的自学习能力,可根据环境的改变和过去的行为结果对自身的知识库进行更新,从而实现算法求解能力的进化。由于蚁群智能算法具有较强的鲁棒性、自适应性、正反馈、优良的分式式计算机制、易于与其他方法结合等优点^[14-15],如今已经成为人工智能领域的一个研究热点,但在遥感分类方面的应用则未见报道。

本文提出了利用基于蚁群智能的分类规则挖掘算法 (antminer)对遥感影像进行分类的新方法。其原理是通过模仿蚂蚁寻找食物的方式来构造遥感分类的规则。在 antminer算法中,信息素不断地更新,其提供的正反馈信息可以帮助纠正启发式函数缺陷所造成的错误。此外, antminer中的信息素是基于规则整体性能的,信息素的动态更新能更好地处理属性间的相互作用,因此,在处理属性之间相关性比较强的数据时,比其他算法更具有优势。遥感数据各波段之间存在较强的相关性,这种相关性往往会导致分类时产生误差,蚁群智能算法将会有效地解决数据之间的相关性,因此,非常适合于遥感分类。

2 蚁群算法的基本原理

人工蚁群算法是受到蚂蚁觅食过程中路径选择行为的启发而提出的^[14]。蚂蚁在寻找食物源时,能

在其走过的路径上释放一种蚂蚁特有的分泌物——信息素 (Pheromone),该激素随着时间的延续不断挥发。蚂蚁在运动过程中能够感知信息素的存在及其强度,并以此指导自己的运动方向。蚂蚁倾向于朝着信息素强度高的方向移动,因此,由大量蚂蚁组成的蚁群的集体行为便表现出一种信息正反馈现象。当一些路径上通过的蚂蚁越来越多时,其留下的信息素轨迹也越来越多,导致信息素强度增大,其他蚂蚁选择该路径的概率也越高。蚂蚁个体之间就是通过这种间接的通信机制达到协同搜索蚁巢到食物源的最短路径的目的。

蚂蚁在觅食过程中通过相互协作能找到蚁巢到食物源的最短路径,在没有障碍物的情况下,所形成的最短路径近乎一条直线,如图 1 (a)。蚂蚁群体不仅可以完成复杂的任务,而且能适应环境的变化,如在蚁群运动路线上突然出现障碍物时,刚开始蚂蚁按同等概率选择各条路径,如图 1 (b)。在运动过程中,蚂蚁在其经过的路径上留下信息素,由于路径 F-G-H 比路径 F-O-H 要短,选择路径 F-G-H 的蚂蚁要比选择路径 F-O-H 的蚂蚁先达到食物源,那么,此时,路径 H-G-F 的信息素浓度比路径的信息素浓度 H-O-F 要大,从而使得选择路径 H-G-F 的蚂蚁增多,如图 1 (c)。由于信息素的挥发,较长路径上的信息素逐渐消失,如此反复循环,最终,所有的蚂蚁都沿着最短路径行进,如图 1 (d)。




图 1 蚁群觅食过程图
Fig 1 The route choice behaviors of ants in seeking food

蚂蚁觅食过程中选择最优路径的现象表现为一种正反馈过程,这一过程应用于优化领域便产生了人工蚁群智能算法^[14],因此,蚁群算法是对真实蚂蚁觅食行为的一种抽象和模拟。

3 基于蚁群智能的遥感分类方法

蚁群算法具有很强的自学习能力,能够根据环

境的改变和过去的行为结果对自身的知识库进行更新,从而实现算法求解能力的进化,因此,蚁群智能可以有效地解决非线性问题,特别适合于地理复杂现象。本文将以 TM 影像为例,探讨利用基于蚁群智能的分类规则挖掘算法自动从遥感影像中挖掘出分类规则,图 2 为 antminer 遥感分类的过程。

蚁群算法在 TSP (旅行商) 问题求解、分配问题、数据聚类、组合优化和网络路由等方面取得了系列较




图 2 基于蚁群智能的遥感分类流程

Fig 2 The procedure of antminer based classification of remote sensing images

好的成果^[16-18]],但其在分类规则挖掘方面的研究还刚刚起步。基于蚁群算法的规则挖掘最初由巴西学者 Papinelli R S 于 2002 年提出^[19],主要是利用蚁群觅食原理在数据库中搜索最优规则。本文尝试将基于蚁群的规则挖掘算法引入到遥感影像分类中,定义蚁群搜索路径为属性节点和类节点的连线,其中属性节点最多只出现一次且必须有类结点,属性节点对应遥感影像波段的离散值。如图 3 所示,每条路径对应一条分类规则,分类规则的挖掘可以当作是对最优路径的搜索。刚开始时,随机产生一条规则,规则形式如下:




图 3 Antminer 算法中分类规则对应的路径

Fig. 3 Route Corresponding to Classification Rule
Derived from an miner

$$\mathbb{F} \langle \text{tem}_1 \text{ AND } \text{tem}_2 \text{ AND} \dots \rangle \text{ THEN } \langle \text{class} \rangle \quad (1)$$

数记为 $\check{f}(\check{c}_i)$, 大于断点值 $\check{c}_i$ 的实例的个数记为 $\check{f}(\check{c}_i)$, 令:

$$\check{f}(\check{c}_i) = \sum_j^r \check{f}_j(\check{c}_i) \tag{3}$$

$$\check{f}(\check{c}_i) = \sum_j^r \check{f}_j(\check{c}_i) \tag{4}$$

断点 $\check{c}_i$ 可以将集合 X 分成两个子集 X_l 和 X_r , 其信息熵分别为^[20-21]:

$$H(X_l) = - \sum_{j=1}^r p_j \log_2 p_j \quad p_j = \frac{\check{f}_j(\check{c}_i)}{\check{f}(\check{c}_i)} \tag{5}$$

$$H(X_r) = - \sum_{j=1}^r q_j \log_2 q_j \quad q_j = \frac{\check{f}_j(\check{c}_i)}{\check{f}(\check{c}_i)} \tag{6}$$

定义断点 $\check{c}_i$ 针对集合 X 的信息熵为:

$$H(\check{c}_i) = \frac{|X_l|}{|U|} H(X_l) + \frac{|X_r|}{|U|} H(X_r) \tag{7}$$

假设 $L = \{Y_1, Y_2, \dots, Y_m\}$ 是决策表已经被选取的断点的集合 P 划分得到的等价类, 那么加入新的断点 $\check{c} \notin P$ 后新的信息熵为:

$$H(\check{c}|L) = H^1(\check{c}) + H^2(\check{c}) + \dots + H^m(\check{c}) \tag{8}$$

$H(\check{c}|L)$ 越小, 说明加入此断点后将使划分的新的等价类子集的决策属性值趋于单一, 该断点的重要程度越大. 设 P 为已选取的断点的集合, L 为实例被断点集合 P 所划分成的等价类集合, B 为候选断点的集合, 对每一个 $\check{c} \in B$, $b_{\min} < \check{c} < b_{\max}$, 且 $\check{c}$ 为整数. H 为决策表信息熵. 那么, 基于信息熵的连续属性值离散化算法可描述如下^[20]:

- (1) 对每一个 $\check{c} \in B$ 计算 $H(\check{c}|L)$;
- (2) 若 $H \leq \min H(\check{c}|L)$, 则结束;
- (3) 选择使 $H(\check{c}|L)$ 最小的断点 $\check{c}_{\min}$ 加入到 P 中;
- (4) 对所有的 $X \in L$, 如果 $\check{c}_{\min}$ 把等价类 X 划分为 X_l 和 X_r , 那么, 从 L 中去掉 X 把等价类 X_l 和 X_r 加到 L 中;
- (5) 如果 L 中各个等价类中的实例都具有相同的决策, 循环结束, 否则转到步骤 (1).

3.2 规则构造

规则构造模仿了蚂蚁的觅食行为. 蚂蚁重复选择节点直到构造一条完整路径, 理论上节点的选择可以是完全随机的, 但这可能需要漫长的计算时间作为代价. 通常可以设计一个与问题相关的启发式函数, 相当于给人工蚂蚁安上一双“眼睛”, 从而引导蚁群的搜索, 缩短收敛时间.

PaPineLLi R S 等采用基于信息熵的方法来构造启发式函数^[19], 每个属性节点的启发式函数值与其分类样例的能力成正比, 本文根据数据的统计特征(频数)来构造启发式函数, 定义条件项 tem_i 的启发式函数值 η_{ij} 为^[18]:

$$\eta_{ij} = \frac{\max \left\{ \sum_n freqT_{ij}^1, \dots, \sum_n freqT_{ij}^2, \dots, \sum_n freqT_{ij}^k \right\}}{\sum_n T_{ij}} \tag{9}$$

式中, η_{ij} 表示条件项 tem_i 基于密度的启发式函数值, T_{ij} 为满足件项 tem_i 的实例数, $freqT_{ij}^w$ 为 T_{ij} 中类别为 w 的频数. 在数据挖掘过程中, 每得到一条最终规则后, 要移除符合规则条件部分的记录, 因而, $\max \left\{ \sum_n freqT_{ij}^1, \sum_n freqT_{ij}^2, \dots, \sum_n freqT_{ij}^k \right\}$ 和 $\sum_n T_{ij}$ 在得到一条最终规则后其值会发生变化, 需要对其进行动态更新.

当第一只蚂蚁开始构造路径时, 所有路径节点的信息素浓度被初始化为相同的值:

$$\tau_{ij}(\text{time} = 0) = \frac{1}{\sum_{i=1}^a b_i} \tag{10}$$

式中, τ_{ij} 为条件项 tem_i 的信息素浓度, a 为数据库中属性(不包括类属性)总数, b_i 为属性 i 所有可能取值的数据.

赌轮机制用来选择属性节点. 对每个属性列来说, 其所属节点 tem_i 被选择的概率按下式进行计算:

$$P_{ij}(\check{c}) = \frac{\tau_{ij}(\check{c}) \times \eta_{ij}(\check{c})}{\sum_{i=1}^a \sum_{j=1}^k \tau_{ij}(\check{c}) \times \eta_{ij}(\check{c})} \tag{11}$$

选择出的属性节点被加入到路径中去. 直到所有属性(包括类属性)都被选入到路径中去, 至此, 一条完整的路径已产生, 即一条分类规则. 规则的有效性用下面公式计算:

$$Q = \left(\frac{TruePos}{TruePos + FalseNeg} \right) \times \left(\frac{TrueNeg}{FalsePos + TrueNeg} \right) \tag{12}$$

式中, $TruePos$ 表示满足规则条件, 并且和规则预测类型相同的样例数; $FalsePos$ 表示满足规则条件, 并且和规则预测类型不同的样例数; $FalseNeg$ 表示不满足规则条件, 并且和规则预测类型相同的样例数; $TrueNeg$ 表示不满足规则条件, 并且和规则预测类型不同的样例数.

3.3 规则修剪

由于产生分类规则时, 每个属性节点都被选作为规则的一个条件项, 这样得到的规则其条件项较多, 难于理解; 此外, 有些属性对于某些类别的分类结果贡献不大, 甚至会有负面影响, 因而需要对其进行修剪; 更为重要的是: 路径节点的重复选择可能会带来分类规则对样例的过度拟合。一种简单的修剪方法就是依次移去能使规则有效性得到最大提高的属性节点, 即移除多余的属性节点, 直到任一属性节点的移除都会降低规则的有效性。

3.4 信息素浓度更新

当一次迭代中的所有人工蚂蚁构造的规则经过修剪得到分类规则后, 所有路径节点的信息素浓度都将依据这种分类规则的效率进行更新。规则中被包含的路径节点的信息素浓度将增加, 而没有被包含的路径节点的信息素浓度将减小 (引入挥发系数 ρ)。属性节点的信息素浓度更新公式如下:

$$\tau_{ij}(t+1) = (1-\rho) \cdot \tau_{ij}(t) + \left[\frac{Q}{1+Q} \right] \cdot \tau_{ij}(t)$$

(13)

式中, ρ 为信息素的挥发系数, Q 为分类规则的质量。所有属性节点的信息素尝试被更新, 在此基础上, 下一个蚂蚁开始它的搜索。当连续若干蚂蚁搜索到同一路径时, 就认为搜索收敛; 否则, 重复这个过程, 直到所有的蚂蚁搜索完毕。在该迭代过程中, 每只蚂蚁构造出一条规则, 这些规则当中质量较好的规则, 由于其信息素浓度逐渐增强, 从而能够得以保留, 并被视为最终分类规则。其他质量较差的规则被丢弃。迭代完成后进入下一次迭代, 直到剩余的训练样例数小于预定的样例数。

4 影像分类实验

实验中采用的数据是 2005 年 7 月 18 日获取的广州市地区的 TM 卫星数据, 选取的研究范围为 1706×1549 个像元 (分辨率为 30m), 选择的波段为 1—5 波段及 7 波段, 共 6 个波段的数据。图 4 (a) 为研究区域 5 4 3 波段所合成的假彩色影像图。

训练样本的选择是蚁群学习的关键步骤, 直接关系到所获规则的质量。根据实地调查和土地利

用图, 采用分层随机采样的方法来获取训练样本和验证数据集。训练数据集的样本数为 1000 验证数据集的样本数为 1150。

基于蚁群智能的遥感分类模型主要由两部分组成: 分类规则提取和土地利用类型的识别。分类规则主要通过 antminer 算法从训练数据挖掘出来, antminer 算法是在 Visual Basic 6.0 环境中编程所实现的。土地利用类型的识别部分则是根据 antminer 算法所挖掘出来的分类规则对遥感影像进行分类。

在运用 antminer 挖掘遥感影像分类规则时, 离散化后的各波段值作为蚂蚁路径的属性节点, 影像分类的类别作为蚂蚁路径的类节点, 每条路径对应一条分类规则。分类规则的挖掘可以当作是蚂蚁对最优路径的搜索。根据前面所选取的训练数据, 本实验利用 antminer 算法共获得了 44 条分类规则, 表 1 列出了部分的分类规则, 其中, 规则的置信度是根据该规则对训练数据的分类精度来确定的。根据所获得的分类规则, 对实验区遥感影像进行分类, 分类结果见图 4 (b)。同时, 选取与蚁群智能分类一样的训练数据, 用最大似然 (MLH) 方法和 Se5.0 决策树方法对实验区的遥感影像进行了分类, 分类结果如图 4 (c) 和图 4 (d) 所示。

表 1 Antminer 所挖掘的部分分类规则
Table 1 Part of the Classification Rules by Using AntM iner

规则 1
IF
53.5 < B ₄ < 129.5 and 132 < B ₃ < 203 and 45.5 < B ₇ < 61.5
Then
class= Urban (置信度 = 1.0)
规则 2
IF
105.5 < B ₁ < 112.5 and 60 < B ₃ < 97 and 53.5 < B ₄ < 129.5
and 41 < B ₃ < 132
Then
class= Orchard (置信度 = 0.93)
规则 3
IF
B ₃ < 60 and 129.5 < B ₄ < 159.5
Then
class= Mountain (置信度 = 1.0)
规则 4
IF
B ₄ < 53.5 and B ₇ < 13.5
Then
class= Water (置信度 = 1.0)
.....




图 4 广州市实验区 TM影像土地利用分类结果
(a) TM影像(5 4 3); (b) AntMiner分类结果; (c) MLH分类结果; (d) Sees 0分类结果
Fig 4 TM image and the Result of Land Use Classification in the Study Area of Guangzhou
(a) TM image(5 4 3); (b) AntMiner classification; (c) MLH classification; (d) sees 0 classification

为了能更清楚地对这 3 种方法的分类结果进行对比, 分别将这 3 种方法的分类结果图做了局部放大处理, 如图 5 所示。对比图 5 (b), (c) 和 (d) 中的 A B C 处, 很容易发现: 最大似然方法把图 5 中的 A 处错分为果园, 实际上是山体; 决策树方法也将 A 处的左半部分错分为果园。对于 B 处, 最大似然方法将其错分为果园, 实际是较旧的居民用地及一小块水域。C 处应该是果园, 最大似然方法将其错分为农田, 决策树方法也将 C 处的部分错分为农田。而蚁群智能分类方法对这三处地方的分类结果都是正确的。

可见, 蚁群智能分类方法较真实地反映了实际的土地利用覆盖类型。

为了对比 3 种方法的精度, 用先前选取的验证数据对蚁群智能分类方法和最大似然方法进行了精度测试, 将精度评价结果分别表示为混淆矩阵, 见表 2 表 3 表 4。通过比较混淆矩阵, 蚁群智能分类方法的总体精度为 88.6%, Kappa 系数为 0.861, 最大似然方法的总精度为 83.3%, Kappa 系数为 0.796。决策树方法的总精度为 85.4%, Kappa 系数为 0.822。可见, 蚁群智能方法比 MLH 方法和决策树方法的分类效果要好。




图 5 广州市局部放大地区的土地利用分类结果

(a) TM影像; (b) AntMiner分类结果; (c) MLH分类结果; (d) SegS0分类结果

Fig 5 The result of land use classification in the local enlargement area of Guangzhou

(a) TM image; (b) AntMiner classification; (c) MLH classification; (d) SegS0 classification

表 2 广州市实验区基于蚁群智能的分类精度评价结果

Table 2 Accuracy assessment on ACO-based classification in the study area of Guangzhou

类型	居民用地	山体	水体	果园	农田	开发用地	总和	生产精度 /%
居民用地	266	0	4	3	14	7	294	90.5
山体	1	165	0	5	3	1	175	94.3
水体	2	0	124	2	2	0	130	95.4
果园	8	17	2	153	16	2	198	77.3
农田	15	4	1	14	176	3	213	82.6
开发用地	3	0	0	1	1	135	140	98.5
总和	295	186	131	178	212	148	1150	
使用精度 /%	90.17	88.7	94.7	84.8	83.0	91.2		

总精度=88.6% Kappa系数=0.861

表 3 广州市实验区最大似然的分类精度评价结果

Table 3 Accuracy assessment on MLH classification in the study area of Guangzhou

类型	居民用地	山体	水体	果园	农田	开发用地	总和	生产精度 /%
居民用地	254	1	3	4	25	10	297	85.5
山体	3	148	2	7	5	1	166	89.1
水体	2	0	121	5	3	0	131	92.4
果园	8	30	2	144	18	2	204	70.6
农田	22	7	3	18	159	3	212	75.0
开发用地	6	0	0	0	2	132	140	94.2
总和	295	186	131	178	212	148	1150	
使用精度 /%	86.1	79.6	92.4	80.9	75.0	89.9		
总精度 = 83.3% Kappa系数 = 0.796								

表 4 广州市实验区 See5 决策树的分类精度评价结果

Table 4 Accuracy assessment for the decision tree in the study area of Guangzhou

类型	居民用地	山体	水体	果园	农田	开发用地	总和	生产精度 /%
居民用地	259	0	4	3	23	9	298	86.9
山体	2	156	2	6	4	1	171	91.2
水体	2	0	122	4	3	0	131	93.1
果园	8	24	1	147	17	2	199	73.9
农田	19	6	2	17	164	2	210	78.1
开发用地	5	0	0	1	1	134	141	95.0
总和	295	186	131	178	212	148	1150	
使用精度 /%	86.1	79.6	92.4	80.9	75.0	89.9		
总精度 = 85.4% Kappa系数 = 0.822								

5 结 论

智能式遥感分类是遥感研究的新热点之一。当地表状况较复杂时,目前的遥感分类方法往往难以获得较高的分类精度,因此有必要引进智能式的方法来提高分类精度。为此,本文提出了一种基于蚁群智能算法的遥感分类新方法。蚁群智能算法实际上是一种多智能体算法,简单的智能个体通过合作能完成复杂任务,是一种“自下而上”的研究思路。蚁群算法具有较强的鲁棒性,不会由于一个或者某几个智能个体的故障而影响整个问题的求解;蚁群算法 also 具有很强的自组织性和自适应性,适合地理复杂规律的提取。

文章首次将蚁群智能的分类规则挖掘算法尝试性地引进到遥感影像中,antmine算法模仿蚂蚁寻找食物的方式来构造分类规则。该算法所提取的分类规则毋需通过数学公式来表达,能更方便和准确地描述自然界中的复杂关系,并且这些规则比数学公式更容易让人理解。作为人工智能新的分支,蚁群智能算法具有较强的鲁棒性、自适应性、非

线性和正反馈机制,因此在提取复杂地理现象的规律(如遥感分类)时具有较为明显的优势。此外,antmine算法中的信息素是基于规则整体性能的,信息素的动态更新能更好地处理属性之间相关性比较强的数据时,对于各波段数据之间相关性较强的遥感影像来说,蚁群智能算法具有天然的优势。

将该算法应用于广州市的遥感影像分类,取得了较好的分类结果。并与最大似然分类算法进行了对比研究,其中蚁群智能分类方法的总精度为 88.6%,Kappa系数为 0.861。最大似然方法的总精度为 83.3%,Kappa系数为 0.796。决策树方法的总精度为 85.4%,Kappa系数为 0.822。这表明蚁群智能算法的分类精度比最大似然算法和决策树方法更高。

参考文献 (References)

[1] Tumer B, Meyer W B, Skole D L, Gopal J L andusey L and Cover Change toward an Integrated Study [J]. Ambio, 1994, 23 (1): 91—95.

[2] Nishii R, Eguchi S. Supervised Image Classification by Contextual AdaBoost Based on Posteriors in Neighborhoods [J]. IEEE Transaction on Geoscience and Remote Sensing, 2005, 43 (11):

- 2547—2554.
- [3] Wilkinson G G Results and Implications of a Study of Fifteen Years of Satellite Image Classification Experiments [J]. IEEE Transaction on Geoscience and Remote Sensing 2005 43 (3): 433—440
 - [4] Wilkinson G G A Review of Current Issue in the Integration of GIS and Remote Sensing Data [J]. International Journal of Geographical Information Science 1996 10 (1): 85—101
 - [5] Strahler A H The Use of Prior Probabilities in Maximum Likelihood Classification of Remotely Sensed Data [J]. Remote Sensing Environment 1980 10 135—163
 - [6] Frizzelle B G Moody A Mapping Continuous Distributions of Land Cover: A Comparison of Maximum-Likelihood Estimation and Artificial Neural Networks [J]. Photogrammetry Engineering and Remote Sensing 2001 67 (6): 693—705
 - [7] Moller-Jensen L Knowledge-Based Classification of an Urban Area Using Texture and Context Information in Landsat-TM Imagery [J]. Photogrammetry Engineering and Remote Sensing 1990 56 (6): 899—904
 - [8] Srinivasan A Richards J A Knowledge Based Techniques for Multi-Source Classification [J]. International Journal of Remote Sensing 1990 11 (3): 505—525.
 - [9] Tonjes R Glowe S Buckner J et al Knowledge-Based Interpretation of Remote Sensing Images Using Semantic Nets [J]. Photogrammetry Engineering and Remote Sensing 1999 65 (7): 811—821
 - [10] Heeman P D Khazenje N Classification of Multispectral Remote Sensing Data Using a Back-Propagation Neural Network [J]. IEEE Transaction on Geoscience and Remote Sensing 1992 30 (1): 81—88
 - [11] Bischof H Schneider W Pinz A J Multispectral Classification of Landsat Images Using Neural Networks [J]. IEEE Transaction on Geoscience and Remote Sensing 1992 30 (3): 482—490
 - [12] Serpico S B Roli F Classification of Multisensor Remote Sensing Images by Structured Neural Networks [J]. IEEE Transaction on Geoscience and Remote Sensing 1995 33 (3): 562—578
 - [13] Colomi A Dorso M Maniezzo V et al Distributed Optimization by Ant Colonies [C]. Proceedings of the 1st European Conference on Artificial Life 1991 134—142
 - [14] Dorso M Optimization Learning and Neural Algorithms [D]. Ph. D. Thesis Department of Electronics Politecnico di Milano Italy 1992
 - [15] Dorso M Maniezzo V Colomi A Ant System Optimization by a Colony of Cooperating Agents [J]. IEEE Transaction on Systems Man and Cybernetics Part B 1996 26 (1): 29—41
 - [16] Kwang M S Weng H S Multiple Ant Colony Optimization for Network Routing [A]. Proceedings of the First International Symposium on CyberWorlds [C]. 2002
 - [17] Lumber E Fajeta B Diversity and Adaptation in Populations of Clustering Ants [A]. Proceedings of the Third International Conference on Simulation of Adaptive Behavior: From Animals to Animates [C]. MIT Press/Bradford Books Cambridge MA 1994.
 - [18] Duan H B Ant Colony Algorithms: Theory and Applications [M]. Beijing: Science Press 2005 [段海滨. 蚁群算法原理及其应用 [M]. 北京: 科学出版社, 2005.]
 - [19] Parpinell R S Lopes H S Freitas A A Data Mining with an Ant Colony Optimization Algorithm [J]. IEEE Transaction on Evolutionary Computation 2002 6 (4): 321—332
 - [20] Xie H Cheng H Z Niu D X Discretization of Continuous Attributes in Rough Set Theory Based on Information Entropy [J]. Chinese Journal of Computers 2005 28 (9): 1570—1574 [谢宏, 程浩忠, 牛东晓. 基于信息熵的粗糙集连续属性离散化算法. 计算机学报 [J]. 2005 28 (9): 1570—1574]
 - [21] Theil H Economics and Information Theory [M]. North Holland Amsterdam 1967.

C lassification of R emote Sensing I mages based on A nt C olony O Ptim izati on

LU X iao-ping LIX iu HE Jin-qiang A I Bin PENG X iao-juan

(School of Geography and Planning Sun Yat sen University Guangdong Guangzhou 510275 China)

Abstract This paper presents a bottom-up approach to improve the classification performance for remote sensing applications. Top-down approaches such as statistical classifiers have inherited limitations in dealing with complicated relationships in classification. For example, data correlation between bands of remote sensing imagery has caused problems in generating satisfactory classification with statistical methods. In this paper, ant colony optimization (ACO) based on swarm intelligence is used to improve classification performance. Actually, ACO is a complex multi-agent system in which agents with simple intelligence can complete complex tasks through cooperation such as classification problems. Ants guide their route selection based on pheromone, which is accumulated from the collective movements of individual ants. In this way, an ant learns from the past experience of others. AntMiner is different from decision tree approaches. The entropy measure is a local heuristic measure, which considers only one attribute at a time, and so it is sensitive to attribute correlation problems. Whereas in AntMiner, pheromone updating tends to cope better with attribute correlation, since pheromone updating is directly based on the performance of the rule as a whole. Thus, AntMiner should have great potential in improving remote sensing classification. In this study, an AntMiner program for discovering classification rules is developed for the classification of remote sensing images. In the AntMiner program, the route search by an ant colony is to find the best links between attribute nodes and class nodes. An attribute node corresponds to a band value of remote sensing images. An attribute node can only be selected once and must be associated with a class node. Each route corresponds to a classification rule, and discovering a classification rule can be regarded as searching for an optimal route. To enable ACO to effectively classify remote sensing imagery of very large data sets, original band values are sliced into a number of intervals by using a discretization technique. The ACO method is more explicit and comprehensible than mathematical equations. Our study in Guangzhou city indicates that the ant colony based classifier yields better accuracy than conventional maximum likelihood classifiers and decision tree classifiers. The overall accuracy of the ACO method is 88.6%, with a Kappa coefficient of 0.861. The decision tree method has an accuracy of 85.4% and a Kappa coefficient of 0.822. The maximum likelihood method has an accuracy of 83.3% and a Kappa coefficient of 0.796. The results clearly support the conclusion that the method explored in this paper can be more effective than conventional classification methods.

Key words ant colony optimization; remote sensing data; classification; artificial intelligence