

改进的多维遥感数据的自适应遗传超平面分类器算法

李启青 程承旗

(北京大学遥感与地理信息研究所 北京 100871)

摘要: 在遥感图像数据监督分类方法中,普遍存在着通过大训练数据量提高分类精度的问题。该文在笔者已经实现的遗传超平面方法基础上,做了进一步的改进,这就使得这种遗传超平面分类器可以使用了少量的训练数据进行训练,而得到的分类精度与大训练数据量相比具有可以接受的差别;改进了分类方法中使用主成分分析后再用两个主成分进行分类的做法,使用的原始数据为多个(3个以上)波段直接进行分类,不但增加了分类输入的信息量,而且简化了技术流程。同时,在不增加分类时间的情况下扩展了算法分类的类别数。文中使用C/C++从底层实现了整个训练、分类、测试过程,通过对北京的ETM+数据进行的分类实验及其分析表明该算法分类效果很好,完全可以达到实用的要求。

关键词: 遥感图像数据, 遗传算法, 超平面分类, 分类精度

中图分类号: TP75

文献标识码: A

文章编号: 1009-5896(2005)12-1849-06

Self-adapted Genetic Hyperplane Classifier Algorithm for Multi-dimensional Remote Sensing Image

Li Qi-qing Cheng Cheng-qi

(The Institute of RS&GIS of Peking University, Beijing 100871, China)

Abstract There exists a problem that is using big quantity of training data to improve classification accuracy in remote sensing supervised classification methods. In this paper, advanced improvements are proposed for the implemented genetic hyperplane algorithm to get the advantage of using smaller quantity of training data and almost the same training effect. Generally, the principle component analysis is used to acquire the 2 principle components and the result is used to classify the data. Now that the improvement is that several bands (above 3) of remote sensing data are used simultaneously for the classification. Henceforth, the information quantity that input the classifier is incremental and the technological flow is simplified. At the same time, the number of classes from the algorithm is extended, while the time consuming is not incremental. The C/C++ is used to implement the whole process, which involve training, classification and test. The ETM+ data of Beijing is given for the classification and the good performance is acquired. The result shows that it can be fully used in practical.

Key words Remote sensing imagery data, Genetic algorithm, Hyperplane classification, Classification accuracy

1 前言

遗传算法(Genetic Algorithm, GA)是一种随机搜索和优化技术,源于达尔文的生物进化论(Goldberg, 1989)^[1-3]。本身就是一个自然选择进化过程与遗传学机理相结合的计算模型,也是一种基于群体进化的全局优化搜索算法,具有隐含的并行性。通过适应度函数值控制的遗传操作,使群体不断优化,从而找到满意解或最优解^[4]。

由于遥感图像具有多波段以及数据量大的特点,所以GA比较难于直接针对数据进行处理,一般是建立一个可以使用GA进化的模型。在遥感数据分类处理领域,Pal等提出使用GA来确定超平面的空间组合位置^[5],从而使得GA得以开始应用于遥感图像分类中。在使用遗传-超平面算法进行分类的过程中,除了要考虑GA本身的特点以外,建立一个适合遗传进化的超平面组合模型具有非常重要的意义。

通过GA进行超平面分类也是一个GA应用于模式识别的问题,在给定超平面集合的条件下,通过对训练点集中训练点进行模式描述、模式匹配然后利用GA的优异搜索性能,通过进化的方式对各种不同的模式分类方案进行比较、选择,得到最好的模式分类方案。最后扩展到整幅图像达到模式分类的目的^[6]。

在GA优化的超平面分类模型中,由超平面方程的参数经过特殊编码而成的二进制串集合形成了GA的搜索空间。这是因为特定位数的二进制串可以代表特定空间的所有超平面方程。GA通过选择、变异、交叉等遗传操作在此搜索空间内搜索最优的解,中间通过解码过程将二进制串还原为超平面的参数以计算每条染色体的适应度(目标函数)。目标函数通过分类训练的精确程度来实现,本质上来讲,这是一个自适应的迭代过程。训练过程中,训练点数与分类错误的点数之差作为一系列(套)超平面的适应度。最佳的染色体对应最优的分类方案,也就是最合适的超平面集合。通过这一系列超平面在多维空间中的区域划分得到的多维空间模式分类结果被认为是精度最高的图像分类方案^[4]。

在遥感监督分类方法中,普遍存在着通过大训练数据量提高分类精度的问题。遗传超平面分类算法所具有的计算特殊复杂性,使得这种常规的提提高分类精度的方法存在面临着时间复杂度指数级提高的危险可能性。因此,实践中,在保证适应度具有一定的统计性能的同时,使用尽量小的数据量进行训练却又不会迅速降低分类精度的做法就具有重要的意义。这样除了可以大大减少训练时间以外,也可以使训练精度迅速达到95%以上,有时甚至可以达到100%,而这时其测试分类精度的降低被控制在一定范围之内,从而达到性能与时间比最大化的算法要求。

第2节回顾了遗传-超平面分类算法的基本原理。第3节对改进的遗传-超平面算法(Improved Genetic-Hyperplane, IGH)做了详细介绍。第4节通过实现了算法并进行了ETM+数据的分类实验,给出了分类结果并做了详细分析。第5节给出结论并提出了需要进一步探讨的问题。

2 遗传超平面方法的基本原理

图像分类中,超平面实际上是多维特征空间中的判别边界,也就是一个方程。 N 维空间中的超平面方程可以表示为^[5]

$$d = \chi_N \cos \alpha_{N-1} + \beta_{N-1} \sin \alpha_{N-1} \quad (1)$$

其中

$$\beta_{N-1} = \chi_{N-1} \cos \alpha_{N-2} + \beta_{N-2} \sin \alpha_{N-2} \quad (2)$$

$$\beta_{N-2} = \chi_{N-2} \cos \alpha_{N-3} + \beta_{N-3} \sin \alpha_{N-3} \quad (3)$$

⋮

$$\beta_1 = \chi_1 \cos \alpha_0 + \beta_0 \sin \alpha_0 \quad (4)$$

α_{N-1} 表示超平面的单位法线与 X_N 轴的夹角; α_{N-2} 表示在 $X_1, X_2, \dots, X_{N-1}$ 空间法线的投影与 X_{N-1} 轴的夹角; α_1 表示二维空间的法线投影与第2个特征轴的角度; α_0 表示一维空间的法线投影与第1个特征轴的角度; $\alpha_0=0$; d 表示超平面与原点之间的垂线距离。

这样, $N-1$ 个角度 $\alpha_1, \alpha_2, \dots, \alpha_{N-1}$ 和一个垂线距离 d 就可以确定 N 维空间的一个超平面。如何确定超平面方程的这 N 个参数就是GA需要解决的问题。特殊地,二维空间中,超平面方程变为直线方程的形式:

$$d = x_2 \cos \alpha_1 + x_1 \sin \alpha_1 \quad (5)$$

只要两个参数 α_1 和 d 就可以确定一个直线方程^[5],如图1所示。




图1 使用遗传算法解决问题的一般框架

3 改进的遗传-超平面(IGH)算法

GA的主要问题是选择编码方案、进化算子和适应度函数。通过GA确定遥感图像分类中的超平面位置,要面临的主要问题是超平面方程的参数编码、进化算子、适应度函数。编码方式和适应度函数中的点模式描述及其匹配统计问题是IGH的核心问题。

3.1 编码方案

GA本身并不直接处理空间的参数,必须把它们转换成搜索空间的由基因按一定结构组成的染色体或个体。编码方案确定搜索空间,也是一个解空间向搜索空间转变的过程。GA的鲁棒性使其对编码的要求并不严格^[1,7],多数问题可以采用基于{0,1}符号集的二值编码方式。除此之外,也有进行整数编码、字符串、二维染色体编码、树结构编码甚至可变长度染色体编码的例子。

使用二进制编码,角度的变化范围采用除了可以采用 $0 \sim 2\pi$,也可以采用 $-\pi \sim \pi$ 。本文采用后者进行编码。二进

制串的一部分用来代表角度, 代表角度的位数越多, 表示在此范围内可取值越多, 精度越高。如果其中的 b_1 位用来代表一个角度, 那么角度的可能值表示为

$$2b_1 \times (-\pi) \times (1/2b_1), \dots, 2 \times (-\pi) \times (1/2b_1), 1 \times (-\pi) \times (1/2b_1), 0, 1 \times \pi \times (1/2b_1), 2 \times \pi \times (1/2b_1), \dots, 2b_1 \times \pi \times (1/2b_1)$$

显然, $-2b_1, \dots, -2, -1, 0, 1, 2, \dots, 2b_1$ 这个整数序列可以由此 b_1 位二进制串的 10 进制值来表示。推而广之, $N-1$ 个角度, 需要 $(N-1)b_1$ 位表示。特殊地, 二维空间中角度只需要 b_1 位二进制串即可表示。

确定了超平面的方位之后, 还需要确定参数 d 。为了使搜索空间不至于无限扩张, d 的确定也非常重要。针对所选择的训练点空间, 统计出特征 X_i 的最大值和最小值, 这些值在超空间中组成了超矩形, 其顶点在确定 d 的过程中具有重要的意义。

通过超矩形的一个顶点, 具有同样的方位并且到原点的垂距最小的超平面称为此方位的“基超平面”。这个平面到原点的距离为给定方位超平面的最小距离 $d_{\min}$ 。令 diag 为超矩形对角线的长度。这样 $d_{\min}$ 与 diag 之和表示了此方位 d 的搜索空间。如果 b_2 位被用来代表 d , 那么 $d = d_{\min} + \text{diag} \times v_2/2b_2$, 其中 v_2 代表此 b_2 位二进制串的 10 进制值。

因而一个超平面就可以由 $(N-1)b_1 + b_2$ 位的二进制串来表示, H 个超平面需要 $H \times [(N-1)b_1 + b_2]$ 位来表示, 这就像是一条染色体的长度, 染色体是 GA 的基本结构。二维空间中, 可以用如下结构代表一条染色体:

如上所述, 一个超平面可以由 $N-1$ 个角度 $\alpha_1, \alpha_2, \dots, \alpha_{N-1}$ 和一个垂线距离 d 来确定。因此。二进制串的长度 (StringLength) 由角度 (BitsAngle) 参数精度和距离 (BitsDistance) 参数精度、空间维数 (Dimension) 和超平面个数 (HyperNum) 4 个变量确定。如式 (6) 所示:

$$\text{StringLength} = \text{HyperNum} \times [\text{BitsAngle} \times (\text{Dimension} - 1) + \text{BitsDistance}] \quad (6)$$

这样, 二进制串具有非常充分的可伸缩性, 最大限度地涵盖了整个搜索空间。

3.2 进化算子

按照个体对环境适应的程度不同进行的遗传操作作用于群体, 实现优胜劣汰的进化过程, 其 3 个基本算子为: 选择、交叉、变异。通过算子对群体的作用, 遗传操作可以进行高效有向的搜索。

从群体中选择优胜的个体, 淘汰劣质个体的操作称为选择。选择操作建立在群体中个体的适应度评估基础上, 常用的方法有适应度比例法、最佳个体保存法、期望值法、排序选择法等等。把两个父代个体的部分结构加以替换重组而生成新个体的操作称为交叉。通过交叉, GA 的全局搜索能力大大提高。常用的交叉方法有: 一点交叉、二点交叉、多

点交叉等。变异算子是对群体中的个体串的某些基因值所做的变动, 可以是完全随机的变动, 也可以是可控的变化。通过变异, 增强了 GA 的局部搜索能力并维持群体的多样性。基本的变异方式是逆转算子、重新排序等^[8]。

3.3 适应度函数

针对遥感图像分类问题, 适应度函数是正确分开的训练点数。具体描述为如果区域中的点大部分属于类 I , 那么该区域成为支持类 i 边界的区域。在该区域的其它点被认为是误分类的点。与所有区域相关的误分类的点的总和表示为 miss ; 适应度可以表示为 $n - \text{miss}$, 其中 n 为训练数据的大小^[4,5]。

在 IGH 中, 进一步采用自适应的方式计算适应度的值, 这是因为在 IGH 中, 正确的训练点数 (Number) 是由超平面分开区域 (Region) 以及训练点集与超平面组合的相对位置 (Location) 有关。而 IGH 中, 而 Region 和 Location 是两个变量。而 Region 和 Location 变量又受超平面个数 (HyperNum) 和训练点个数 (TrainNum) 等变量的影响, 这种互相影响的复杂关系必须采用自适应的方式来解决。这种自适应的计算方式是以点模式的描述和匹配统计为基础的。

我们针对遥感图像分类问题, 提出了一种训练点/分类点模式的结构体描述方法, 这种方法面向进一步的匹配和统计处理设计。训练点模式既包含了点模式串, 又包含了分类前、后的类别信息。通过对这几个量的组合, 分类后的类别信息就可以通过点模式串的类型确定。

这几个量一旦确定就可以通过比较分类前后的类别信息进一步确定适应度的值。

4 遥感图像分类实验

将上述方法应用于 ETM 图像数据的分类, 工作遵循图 2 的流程。这个结构流程通过虚线分成 3 个模块, 左边是输入数据, 中间是训练、测试和分类处理过程; 右边是输出数据。

测试过程以上述测试数据和遗传训练过程输出的训练结果作为输入, 输出训练结果的测试精度以利于进一步的分析。

图像分类过程以图像数据和经过测试的遗传训练结果作为输入, 输出最后分类结果图像^[8-10]。




图 2 遥感图像遗传分类结构图

4.1 参数选择分析

遥感图像分类的遗传训练过程中参数选择的好坏决定了训练质量的好坏。训练质量由训练精度和训练时间两个量来决定,训练精度越高,训练时间越短表明训练质量越好,相反,训练精度越低,训练时间越长说明训练质量越低。然而,训练精度与训练时间之间是矛盾的。一般在同样的情况下,训练精度与训练时间是反比关系,即训练精度越高,则训练时间越长;训练时间短,则训练精度相应降低。

遗传训练过程以训练精度作为目标,很明显,100%是可以达到的最高的训练精度。对某些训练过程而言,要达到100%的训练精度或者是很困难的,或者是需要很长的训练时间,或者是不必要的。因此,实践中一般不设置100%作为目标,而是采用90~98%之间的某个值,这样往往也会有非常好的分类结果。

在确定了训练精度以后,就需要合理地设置其他参数以用最短的训练时间达到这个训练精度。影响训练时间的参数有训练点个数、染色体长度(二进制编码中即二值串长度BiStrLength)。其中训练点个数(NumofTrain)由使用者指定。二值串长度由群体大小(PopSize)、角度参数位数(BitsAngle)、距离参数位数(BitsDistance)、空间维数(Dimension)和超平面个数(HyperNum)4个变量确定,见式(6)、式(7)。

$$\text{BiStrLength} = \text{PopSize} \times \text{StringLength} \quad (7)$$

实验和理论分析表明,其它情况相同的情况下,染色体越长,训练时间也越长。而群体大小、超平面个数、角度参数位数、空间维数、距离参数位数的数值越大,二值串越长。

根据式(7),上述参数中影响二值串长度最大的是群体大小和超平面个数。由于GA本身对群体大小有一定的限制,过小的群体数目会导致过早收敛,过大的群体数目又会导致二值串过长。超平面模式分类同样要求根据分类类别数合理

地确定超平面个数,不能过小或者过大,过小则不能合理分类,过大则会使二值串过长,也使分类质量降低。因此如何合理地确定这两个参数非常重要。通过大量的实验,文中对5类地物的划分采用6个超平面,群体大小为30。训练点个数与训练时间的关系是线性关系、越少的训练点,其训练时间越小。超平面个数可以在一定范围内变动,超平面个数与训练时间之间不具有线性关系。群体大小也可以在一定范围内变动,群体越大,每一代所用的训练时间越长,但与训练时间也不具有线性关系。所以超平面个数的选择和群体大小的选择非常重要,选择不好会严重影响遗传训练过程。

引入每代训练时间的概念,每代训练时间去除训练精度的影响,仅仅衡量训练点数对训练时间的影响。除此之外,GA的选择概率和交叉概率对训练时间也有非常大的影响。设定训练精度为70%,即首次达到或者超过70%所用的时间表示为T70,达到这个训练精度的代数表示为Generation70。那么通过T70变量就可以比较不同的变异概率对训练时间的影响。从表1和图3可知,变异概率在0.1以下达到全局收敛的可能性较0.1以上大。所以对于GA应该取尽量小于0.1的变异概率,综合考虑,在如下的实验中采用变异概率为0.02。

表2给出了变异概率为0.02,其他参数不变的情况下,改变交叉概率的大小对训练时间的影响。可见在变异概率为0.02的情况下,多数收敛类型为全局收敛,取得比较好的训




图3 交叉概率、变异概率对训练精度之时间的影响图

表1 变异概率与训练时间、训练精度之间的关系表

(点数:500; 类别数:5类; 交叉率:0.99; 最大代数:2000; 训练精度:90%; 群体大小:30; 超平面个数:6)

变异概率	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.3	0.5
所用训练代数	1099	1118	2000	2000	2000	1558	2000	2000	2000	2000	2000	2000
收敛代数	1099	1118	1319	1884	1338	1558	1837	714	1791	1020	1093	588
正确的训练点(个)	451	454	381	448	441	467	416	364	361	362	354	359
训练精度(%)	90.2	90.8	76.2	89.6	88.2	93.4	83.2	72.8	72.2	72.4	70.8	71.8
总训练时间(s)	267	265	465	508	440	427	564	583	545	461	453	412
收敛类型	全局	全局	局部	局部	局部	全局	局部	局部	局部	局部	局部	局部
达到收敛时间(s)	267	265	306.67	478.54	294.36	426.89	518.03	208.49	487.2	235.62	248.11	121.128
每代时间(s)	0.243	0.237	0.233	0.254	0.22	0.274	0.282	0.292	0.272	0.231	0.227	0.206
Generation70	87	129	270	389	140	594	496	398	43	1020	1093	588
T70(s)	21.14	30.57	62.91	98.81	30.8	162.76	139.87	116.22	11.70	235.62	248.11	121.128

练效果。说明该算法中变异算子的选择比交叉算子的选择要重要的多。图 3(b)更表明交叉概率在 0.01 – 0.99 之间达到全局收敛的时间都是可以接受的。作为特例，交叉概率取 0.3 时，仅仅 13s就达到了全局收敛。因此，随后的研究采用 0.3 作为交叉概率。但是这并不能说明采用其他训练点时，取 0.3 就比 0.9 更优越。相关的研究可以参考^[1,6]。

显然，如果要求的训练精度偏低，所用的训练时间将会随之减少，但对相关测试精度的影响却有决定性的影响。

训练点数与训练时间和训练精度的关系表明在一定范围内(本例 500 之内)，增加训练点数其训练时间并不会增加。但是一旦超出这个范围，训练点数的增多将会使训练时间呈现指数级的增长，如表 3 所示。这样选择适当的训练点数进行训练对于训练时间的影响具有非常重要的意义。一般而言超平面个数的增加将大大增加训练时间。但是这并不能涵盖所有的情况。选择多少超平面进行分割，需要针对图像的类别数和实际情况予以确认。

4.2 分类结果及其分析

本研究用北京的ETM+数据做了实验，轨道号为 123/32，影像获取时间是 2003 年 5 月，空间分辨率为 30m，影像像元数为 2020×2000 列。首先进行几何校正，然后选取其中通道 1 – 6 的 6 个波段图像。通过掩膜的方法获取数据样本集合，随后统计数据样本集合中每个波段的最小、最大值作为统计数据输入。按照一定的比例从中选取训练数据，其余

作为测试数据^[11]。遗传训练过程如图 2，以上述统计数据 and 训练数据作为输入，以超平面参数作为训练参数输出，同时输出训练精度作为分析依据。

通过 3000 代的遗传计算，使用统计的训练数据所得的训练成功率为 95.6%，分类成功率可以达到 86%。

通过 5 类目标地物训练点对超平面方程的训练所确定的超平面方程对整幅图像的分类结果如图 4(a)所示，与统计数据对应可见，水体的分类效果是最好的。从分类结果图像与原始图像图 4(b)总体对应结果来看，超平面对于地物类别分类的效果与实际是比较符合^[12,13]。




图 4 ETM+数据分类结果图像与原始图像的对比

表 2 交叉概率与训练时间、训练精度之间的关系表

(点数:500; 类别数:5 类; 变异概率:0.02; 最大代数:2000; 训练精度:90%; 群体大小:30; 超平面个数:6)

交叉概率	0.02	0.05	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	0.99
所用训练代数	733	639	664	1180	66	891	238	380	2000	1905	630	1118
收敛代数	733	639	664	1180	66	891	238	380	1645	1905	630	1118
正确的训练点(个)	451	454	452	454	453	452	453	450	432	458	450	454
训练精度(%)	90.2	90.8	90.4	90.8	90.6	90.4	90.6	90	86.4	91.6	90	90.8
总训练时间(s)	148	132	135	245	13	184	43	77	403	404	106	207
收敛类型	全局	全局	全局	全局	全局	全局	全局	全局	局部	全局	全局	全局
达到收敛时间(s)	148	132	135	245	13	184	43	77	331.47	404	106	207
每代时间(s)	0.202	0.207	0.203	0.208	0.197	0.207	0.181	0.203	0.202	0.212	0.168	0.185

表 3 训练点数与训练时间、训练精度之间的关系

(类别数:5 类; 交叉概率为 0.3; 变异概率:0.02; 最大代数:2000; 群体大小:30; 超平面个数:6)

训练点数(个)	100	200	300	400	500	1000	1500	2000	4000
所用训练代数(代)	629	290	171	444	66	2000	2000	2000	2000
收敛代数(代)	629	290	171	444	66	1994	1943	1074	1977
正确的训练点(个)	92	190	271	363	453	852	1195	1635	2745
实际训练精度(%)	92	95	90.3	90.8	90.6	85.2	79.5	81.8	68.6
总训练时间(s)	30	25	23	79	15	892	1448	1763	3205
收敛类型	全局	全局	全局	全局	全局	局部	局部	局部	局部
达到收敛时间(s)	30	25	23	79	15	889.3	1406.7	946.7	3168.1
每代时间(s)	0.048	0.086	0.135	0.173	0.227	0.446	0.724	0.882	1.603

5 结论与讨论

在遥感图像监督分类方法中,普遍存在着通过大训练数据量提高分类精度的问题。本文所给出并实现的遗传超平面改进方法(IGH),使得使用少量的训练数据进行训练所得到的分类器可以满足分类精度的需求。改进了原来的分类方法中仅仅使用主成分分析后二个主成分进行分类的做法,使用原始数据的多个波段直接进行分类,不但增加了分类输入的信息量,而且简化了技术流程。遗传超平面分类算法具有的计算特殊复杂性使得采用大训练数据量提高分类精度的方法面临着时间复杂度指数级提高的危险。实践中,在保证适应度具有一定的统计性能的同时,使用尽量小的数据量进行训练同时又不降低分类精度的做法就具有重要的意义。这样除了可以大大减少训练时间以外,也可以使训练精度迅速达到 90%以上,有时甚至可以达到 100%,此时测试精度的改变被控制在一定范围(5%)之内。从而达到性能与时间比的最大化。

实验分析表明,本文给出的算法从时间复杂度分析和分类精度分析方面都达到了实用的要求。这样,遥感数据分类方法体系中就增加了以GA为基础的分类方法。这种方法结合了GA和超平面模式分类的思想,优于其它分类器之处在于应用GA的优化搜索性能确定判别界面,也在于抽象扩展了空间的概念以更精确的描述多维尤其是大于三维的遥感数据^[4]。

特征空间维数的增加会使超平面方程角度参数的个数增加,这样就会使染色体长度迅速增加,算法虽然克服了实现的难度,但是增加了时间上的消耗,下一步的改进是采用GA研究的新成果,采用多群体并行进化技术,进一步提高遗传训练、分类的速度和精度。由于综合影响遗传训练过程的参数很多,本文给出的分析虽具有较高的参考意义,但仍需要从算法复杂度的角度结合具体问题做进一步的研究。

参 考 文 献

- [1] 陈国良. 遗传算法及其应用. 北京: 人民邮电出版社, 1996, 第 1 章—第 3 章.
- [2] 庄家礼, 陈良富. 用遗传算法反演连续植被的组分温度. 遥感学报, 2001, 5(1): 1—7.
- [3] Davidson J L, Xia Hua, Ashlock D. A comparison of genetic algorithm, gression, and Newton's method for parameter estimation of texture models. In Proceedings IEEE Southwest Symposium on Image Analysis and Interpretation, San Antonio, TX, 1996
- [4] 李启青, 马建文, 哈斯巴干等. 遥感数据的遗传—超平面分割算法. 遥感学报, 2003, 7(6): 485—489.
- [5] Pal S K, Bandyopahayay S, Murthy C A. Genetic classifiers for remotely sensed images: comparison with standard methods. *International Journal of Remote Sensing*, 2001, 22(13): 2545—2569
- [6] Engebretson C, Davidson J, Ashlock D. Genetic Algorithms and Metropolis Algorithm for Model Selection. Technical Report, Department of Electrical and Computer Engineering, Iowa State University, Ames, IA, 1996
- [7] Jianwen Ma, HuaDong Guo, Changlin Wang, Ge Chen, Vern Singhroy. Extraction of polymetallic mineralization information from multispectral thematic mapper data using the Gram-Schmidt Orthogonal Projection(GSOP) method. *International Journal of Remote Sensing*, 2001, 22(17): 3323—3337.
- [8] 朱述龙, 张占睦. 遥感图像获取与分析. 北京: 科学出版社, 2000, 第 7 章.
- [9] 哈斯巴干, 马建文, 李启青等. 基于小波融合的 ASTER 数据自组织特征映射神经网络分类研究. 中国科学(D), 2003, 33(9): 895—902.
- [10] Cover T M, Hart P E. Nearest neighbour pattern classification. *IEEE Trans. on Information Theory*, 1968, 13: 21—27.
- [11] Schriever J R, Congalton R G. Evaluation seasonal variability as an aid to cover-type mapping from landsat thematic mapper data in the northeast. *Photogrammetric Engineering and Remote Sensing*, 1995(3): 321—327.
- [12] 马建文, 赵忠明, 布和. 遥感数据模型与处理方法. 北京: 中国科学技术出版社, 2001, 第 1 章.
- [13] 李启青, 马建文, 哈斯巴干等. 基于贝叶斯网络模型的遥感数据处理技术. 电子与信息学报, 2003, 25(10): 1321—1327.

李启青: 男, 1977 年生, 博士后, 主要研究领域为图像处理、GA 和贝叶斯网络.

程承旗: 男, 1961 年生, 教授, 主要研究领域为地理信息系统、高分辨率遥感、空间信息应用工程.