

文章编号: 1007-4619(2006)02-0249-07

成像光谱数据特征选择及小麦品种识别实验研究

王长耀¹, 刘正军², 颜春燕³

(1. 中国科学院遥感应用研究所 遥感信息国家重点实验室, 北京 100101;

2. 中国测绘科学研究院, 北京 100039; 3. 中国地质大学, 北京 100083)

摘 要: 针对河北栾城获得的 MAIS 成像光谱仪数据用于小麦品种识别进行了特征选择和分类研究。利用遗传算法以 JM 距离为准则并结合实验区小麦的生物物理特性, 进行了最佳波段选择; 利用 Fuzzy-Artmap 分类器及选出的最佳波段对成像光谱数据进行了分类, 区分出了 4 种小麦品种, 小麦的总体分类精度超过 97%。

关键词: 成像光谱仪; 波段指数; 品种识别

中图分类号: TP79 **文献标识码:** A

A Experimental Study on Imaging Spectrometer Data Feature Selection and Wheat Type Identification

WANG Chang-yao¹, LIU Zheng-jun², YAN Chun-yan³(1. State Key Laboratory of Remote Sensing Science Institute of Remote Sensing Applications
Chinese Academy of Sciences Beijing 100101, China;

2. Institute of Photogrammetry and Remote Sensing, Chinese Academy of Survey and Mapping, Beijing 100039, China;

3. China University of Geosciences Beijing 100083, China)

Abstract With the development of imaging spectrometer technology, the ground objects' consecutive information from it makes it possible to identify different vegetation types though some relevant research was carried out in the past few years most are about forestry, yet few about crops. Further, there exist strong correlation between bands of imaging spectrometer, so how to reduce as much as possible the redundant information and reserve useful information appear much more important.

This paper first did feature selection based on genetic algorithm (GA) and wheat biophysical characteristics. In feature selection using GA, for the training samples, when combined bands reach 4, the JM distance of optimal combination reach much high level, when bands go on increasing, the average JM distance increases slowly until when bands reach 8, the distance does not increase further, so the optimal bands combination can be obtained. In feature selection using wheat biophysical characteristics, we found that there appear strong correlative bands for wheat protein and dry gluten with spectra, so the sensitive bands can be obtained. Combining these two feature selection steps, the ultimate optimal bands combination was given. After feature selection, we use the selected bands and classifier Fuzzy-Artmap to classify the imaging spectrometer data. It showed that for 4 wheat types, they can be identified clearly, the average classification accuracy is above 90%.

Key words imaging spectrometer; feature selection; type identification

收稿日期: 2004-11-04; 修订日期: 2004-12-28

基金项目: 国家高技术研究发展计划项目 (863-308-13-03[02]), 国家攻关计划项目 (2001DFBA0005), 国家重点基础研究发展规划项目 (G2000077902), 中国科学院知识创新工程重大项目 (KZCX1-SW-01) 资助。

作者简介: 王长耀 (1941—), 男, 中国科学院遥感应用研究所研究员, 博士生导师, 长期从事农业与生态环境遥感应用研究, 出版和发表过多本专著和多篇论文。E-mail: changyao_wang@263.net

1 引 言

改革开放以来,随着人民生活水平的提高和农业经济的发展,市场对农产品的需求不再仅仅是数量而是越来越重视其品质,使用高新技术和减少资源浪费成为提高农业生产效益的主要手段。在“精细农业”的时代,遥感也将以更高的数据质量和更加量化的分析方法在精细农业体系中扮演新的角色^[1-4]。

分类是遥感数据分析的一个基本方法,也是为农业生产管理直接提供参考的数据之一。过去的多波段遥感数据提供的信息不足以区分不同的植被类型,更谈不上区分一种作物的不同品种。随着成像光谱技术的发展,它提供的地物连续光谱信息为植被的品种识别提供了可能,人们也开展了一些利用成像光谱数据进行品种识别的工作^[5-8],但是这些工作大部分都是针对林业进行的,关于作物的还很少。

此外,成像光谱数据波段间的相关性较强,相关系数大,数据的冗余现象十分明显。由于通道的增加,使得用于分类的训练样本数目必须呈指数级增长才能使分类器对特征空间进行合理有效的划分。因此,需要研究在保留重要信息的前提下,如何将其从高维数据空间投影到低维空间,降低数据维数,同时减小类内差异,增大类间距,以便更方便、快捷、有

效、准确地提取有用的信息。

本文利用国产成像光谱仪 MAIS 数据对冬小麦品种识别进行了尝试。由于作物的不同品种间区别细微,特别是在其生长的旺季,叶片内部的主要生化成分含量基本相同,决定冠层光谱的主要因素是冠层覆盖率(即长势),因此此时即使高光谱数据也很难区分出作物的品种。相比之下,作物籽粒的成分则直接关系到农产品的品质,而随着品种的不同,籽粒的成分也表现出明显的差异。因此,我们首先通过实验探讨了腊熟期的冬小麦冠层光谱与籽粒生化成分之间的关系,在此基础上,选择了冬小麦腊熟期获取的机载成像光谱数据进行波段选择和分类,分类结果表明这个时期的高光谱数据可用于区分不同的冬小麦品种且准确性较大。

2 实验数据简介

本文所用遥感数据由中国科学院上海技术物理研究所研制的 71 波段成像光谱仪 MAIS 获得。成像时间为 2000-06-05,一共在石家庄地区飞行了 6 个航带,本文截取栾城县内的部分图像做实验。由于受记录器的限制,一次飞行最多只能记录 32 个波段,因此,实际获得的数据只有 32 个波段,各波段的光谱范围见表 1。

表 1 河北栾城成像光谱仪 MAIS 数据波段范围
Table 1 The band range of imaging spectrometer MAIS

波段	波段范围 / μm	波段	波段范围 / μm	波段	波段范围 / μm	波段	波段范围 / μm
1	0.44-0.46	9	0.66-0.68	17	1.53-1.56	25	2.10-2.13
2	0.46-0.48	10	0.68-0.70	18	1.56-1.59	26	2.13-2.16
3	0.52-0.54	11	0.70-0.72	19	1.59-1.62	27	2.16-2.19
4	0.54-0.56	12	0.94-0.96	20	1.62-1.65	28	2.19-2.22
5	0.56-0.58	13	0.96-0.98	21	1.65-1.68	29	2.22-2.25
6	0.58-0.60	14	0.98-1.00	22	1.68-1.71	30	2.31-2.34
7	0.62-0.64	15	1.00-1.02	23	2.04-2.07	31	2.34-2.37
8	0.64-0.66	16	1.02-1.04	24	2.07-2.10	32	2.37-2.40

飞机飞行成像期间,在第一、二航带的飞行方向于地面同步采集了小麦田块、水体、沙滩地等典型地物的地面光谱,以进行后续的图像反射率转换,所用仪器为美国 GER 公司研制的红外智能野外地物光谱辐射计,型号为 MARK V。

37°50',东经 114°41')位于河北省石家庄市东南 25km 中国科学院石家庄农业现代化研究所栾城实验站内。该实验区地形平坦,海拔高度 50.1m;土壤类型为褐土类潮褐土亚类,小麦、玉米一年两熟。成像时间地面种植为小麦,生育期处于腊熟期。本文选择了 4 种小麦品种试验田:高邮 503, 9204, 4185

另外还选取了一个小试验区,该试验区(北纬

及早熟品种。每种随机选 10 个点, 测取了冠层光谱和小麦籽粒的蛋白质、干 湿面筋含量等。

3 数据分析与分类结果

3.1 特征选择

特征选择是遥感图像识别与分类的重要环节之一, 可以说, 没有正确的特征选择做保障, 是不可能进行有效、准确的分类的。这一点对于成像光谱数据更为重要。与其他遥感数据相比, 成像光谱数据的光谱分辨率要高得多, 光谱信息极为丰富, 可选择的波段更多, 识别物体的能力也更强, 这是成像光谱数据的优点。但对多数分类器而言并不是使用的通道越多越好。实践证明, 通过采用不同的特征提取与特征选择技术, 可以使分类精度获得不同程度的提高。典型的特征提取与特征选择技术有前向选择与后向排除算法^[9, 10]、主成分分析 (PCA)、GA 判别技术^[11]、傅里叶分析、小波分析^[12]及基于决策边界的特征提取 (DBFE)^[13]等。这里采用的是基于遗传算法 (Genetic Algorithm, GA) 的面向样本的特征选择技术及基于研究对象生物物理特征的特征选择。

3.1.1 基于 GA 算法的最优特征选取

GA 算法最初是受生物“自然选择”机制的启发而提出的。该算法基于以下假定: 上一代群体中具有更好的适应性的个体在其新一带群体中具有更好的生存和繁殖能力。GA 算法最基本的好处在于能够利用有限的搜索过程自动寻找其取值空间的最优解或者次优解。在 GA 算法中, 每个可能的解均采用独立的个体单元即染色体单元来表示, 染色体又由若干个基因组成。各基因可采用专门的编码方法 (如二进制 Hamming 编码等) 表示。简单的 GA 算法通过复制、杂交、变异算子等三种不同的算子来产生新一代种群个体。复制操作拷贝上一代个体中的基因到新一代个体中, 拷贝次数受个体适应性及群体的选择算法决定; 杂交操作通过对父代中不同个体的基因进行组合重新形成新的种群个体。这样, 新的个体中就可能是包含了各父代个体中的特征的结合。变异操作作用于杂交操作后形成的个体上, 通过以一定的概率 (通常取值较小, 如 0.1) 改变其中的某个或若干个基因的取值。譬如, 对二进制编码 GA 算法, 可以将基因值为 1 变异为 0; 或者将基因值为 0 变异为 1。设计良好的变异算法可以避免 GA 算法收敛于局部极大极小值, 从而得到全局最优解或次最优解。

在应用 GA 算法进行分类特征选择时, 需要确

定评价函数, 以评判不同染色体所代表的波段组合对于所给定的训练样本是否具有更加优良的可分性能。这里将评价函数用平均类别可分离性指数来表示。常用的类别可分离性指数有分离性 (Divergence)、变换可分离性、Bhattacharyya 距离、J-M 距离等。其中 J-M 距离被认为相对其他分离性指标具有更适合于表达类别间可分离性的特点。

$$B_{ij} = \frac{1}{2} (M_i - M_j)^T \left[\frac{(V_i + V_j)}{2} \right]^{-1} (M_i - M_j) + \frac{1}{2} \ln \frac{|(V_i + V_j)/2|}{\sqrt{|V_i| |V_j|}} \quad (1)$$

$$JM_{ij} = \sqrt{2(1 - e^{-B_{ij}})} \quad (2)$$

$$JM = \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^n (p_i \cdot p_j \cdot JM_{ij}) \quad (3)$$

由于 J-M 距离矩阵为一对称的三角矩阵, 因此式 (3) 又可以写为:

$$JM = \frac{2}{n(n+1)} \sum_{i=1}^{n-1} \sum_{j=i+1}^n (p_i \cdot p_j \cdot JM_{ij}) \quad (4)$$

式 (1)、(2)、(3)、(4) 中, V_i 和 V_j 分别是类别 i 和类别 j 的矩阵样本协方差, M_i 和 M_j 是其相应的样本均值向量, B_{ij} 为 Bhattacharyya 距离, p_i 、 p_j 为类别 i 、 j 样本的先验概率, JM_{ij} 为类别 i 和类别 j 之间的 J-M 距离。JM 为平均 J-M 距离。

运用 GA 算法进行高光谱图像最优波段选择的过程可以用图 1 来表示。首先, 产生任意波段的组合, 对波段组合进行编码 (通常可以采用直接编码方式, 即用整型数, 各基因取值即波段号) 形成一染色体个体。重复此过程直到满足个体数量要求, 从而形成种群。接着, 采用平均 J-M 距离计算公式, 分别计算各个体单元 (即染色体) 所代表的波段组合的平均 J-M 距离。以平均 J-M 距离作为聚合度判定指数, 从种群以一定选择算法 (如 Roulette Wheel 算法) 选择出优势个体, 并按一定的概率进行复制、杂交、变异算子等三种不同的操作来产生新一代种群个体。重复上述过程, 直至群体中存在个体达到给定的聚合度要求, 或者完成了指定的迭代次数从而退出循环过程。

对原始成像光谱仪数据利用实测地面点光谱数据进行了反射率转换, 并进行了几何校正。利用 GA 算法结合各类训练样本进行特征选取, 得平均 J-M 距离随特征个数的增加之间的关系如图 2 所示。可以发现, 针对本文给定的训练样本, 当波段组合数达到 4 个时, 其中的最优波段组合的平均 J-M 距离即已达到比较高的水平 (1.4149), 当波段数继续增加时, 平均 J-M 距离增幅相对较小, 至 8 个波段组合

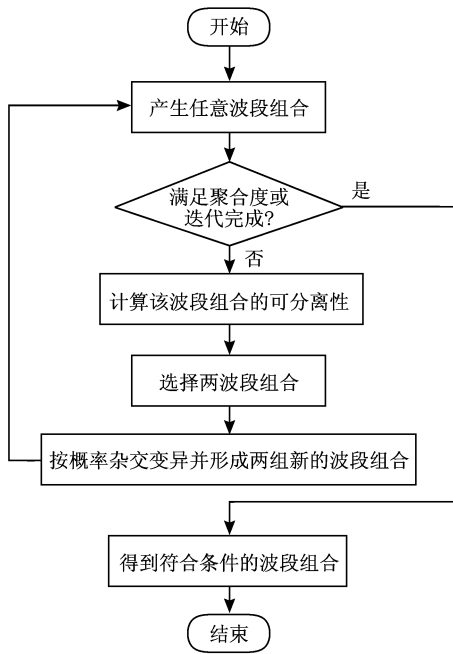


图 1 基于 GA 算法的最优特征选择

Fig 1 Optimal feature subset selection based on genetic algorithm




图 2 最优平均 J-M 距离随特征个数增加的关系

Fig 2 Relationship between optimal average J-M distance and channel number

时, J-M 距离基本不再增加。结合对平均 J-M 距离变化、Hughes 现象, 确定将选择 8 个波段 (平均 J-M 距离为 1.414207) 进行组合比较合适, 其最优波段组合为: 5, 7, 10, 14, 15, 18, 19, 30。

3.1.2 基于小麦生物物理特性的特征选择

除了利用 GA 算法进行特征选择外, 基于本文的目的, 即试图区分出 4 种小麦品种: 高邮 503, 9204, 4185 和早熟品种, 最佳波段选择还必须结合小麦的生物物理特性, 因为我们知道, 成像光谱数据提供了地物相对连续的光谱, 能够反映出地物细微处的变

化, 这为我们利用小麦生物物理特性提供了基础。

本文所用成像光谱仪数据为 2000-06-05 所得, 此时小麦处于腊熟期, 视场绝大部分为叶片和麦穗覆盖, 因此传感器接收到的信号是它们的混合。对于叶片, 已知它在绿光和近红外分别有一个次反射峰和强反射峰, 在红光区有一个吸收谷。而对于籽粒, 本文利用实测数据对 4 种小麦品种的冠层光谱和籽粒蛋白质含量、干 湿面筋含量进行了相关分析。图 3 和图 4 分别为冠层光谱与粗蛋白质和干面筋含量的相关系数。从图中可见, 对于粗蛋白, 存在一个相关区域, 从 715—730 nm (图中用箭头标出并加以放大), 相关系数均在 0.6 以上; 对于干面筋含量, 存在两个相关区域, 一个是从 748—973 nm, 另一个是从 1003—1121 nm, 相关系数也都在 0.6 以上。因此可利用这些相关区域对应的波段参与小麦品种分类。从成像光谱仪的波段设置看, 与这些区域相近的波段为 11, 15 和 16 波段。

综合以上分析, 我们选用 5, 7, 10, 11, 14, 15, 18, 19, 30 作为输入波段进行分类识别。需要提出的是, 结合小麦生物特性, 本文选出了 16 波段, 而最终与遗传算法选出的波段综合分析后却没有采用, 这是因为考虑到 14, 15, 16 波段间相关性, 从波段间的相关性 (结果略) 可看到, 16 和 14 及 15 的相关性更大, 因此为了尽量的减少信息冗余, 便将 16 波段除去了。

3.2 分类算法 Fuzzy ARTMAP

Fuzzy ARTMAP 神经网络利用了模糊子集计算与通过特征空间搜索和学习的自适应反馈动态类型选择方法两者之间的形式相似性, 从而有效地综合了模糊逻辑和自适应反馈原理 (Adaptive Resonance Theory: ART) 两者的优点。Fuzzy ARTMAP 具有自组织反馈、增量式学习、高度复杂映射等特点, 与 BP 神经网络相比较, 更接近于模拟人的感知记忆系统。因此适合于应用在高维空间的映射和分类中。

3.2.1 基本结构

Fuzzy ARTMAP 神经网络的基本结构如图 5 所示, 它可以分为两个模块, ART_a 模块和 ART_b 模块^[14]。从功能上来划分, 每个模块又可以分为两个子系统, 即注意子系统和取向子系统。注意子系统处理已学习的模式, 对已经熟悉的模式建立起精确的内部表示和微调; 取向子系统处理新出现的模式, 当出现不熟悉的事件时, 它回调注意子系统, 在内部建立新的内部编码来表示不熟悉的事件。这与 ART-1、ART-2 的原理大体相同^[15]。不同之处在于




图 3 籽粒粗蛋白含量与冠层光谱的相关(右边为左边箭头处的放大)

Fig 3 The correlation between grain coarse protein and canopy spectra




图 4 籽粒干面筋含量与冠层光谱的相关(右边为左边箭头处的放大)

Fig 4 The correlation between grain dry gluten and canopy spectra

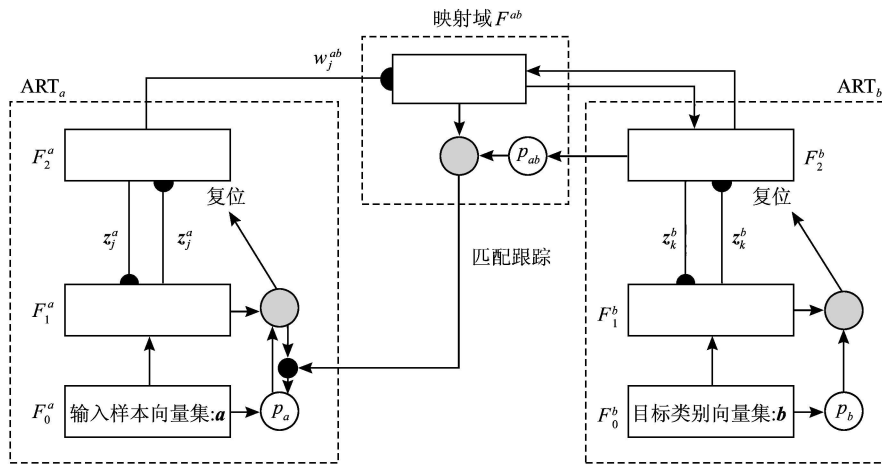


图 5 Fuzzy ARTMAP神经网络体系结构

Fig 5 Fuzzy ARTMAP neural net system structure

加入了模糊处理功能。

从结构上,每个模块分别由 3 层组成:输入层 F_0 ,比较层 F_1 及识别层 F_2 。分别有 M, N 个神经元单元(节点),以及一些附属于上述 3 层的控制连接。 F_1

是特征检测器,它应有足够的节点以便将输入模式编码。 F_2 层上的节点代表对应于输入样本的分类类别。每个 F_2 中的节点 j 存储一个代表这种类型的原型向量 z_j 。 F_1, F_2 都属于短期记忆; F_1, F_2 间的连接

方式是全连接,它起长期记忆的作用^[9,10]。ART_a和ART_b两者通过一个映射域 F^{ab}连接起来。ART_a通过学习在 F₀^a层的输入样本向量集 a 而获得的 F₂^a层的原形类别向量;ART_b通过学习在 F₀^b层的目标类别向量集 b 而获得 F₂^b层的原形类别向量。F₂^a与 F^{ab}之间通过关联连接权 w_k^{ab}连接起来,其强度值随学习过程而调整;F₂^b与 F^{ab}之间通过双向的、一一映射的、无调整的方式连接起来。F^{ab}和其他一些内部控制器一起作用在 ART_a的 F₂层产生最少数量的提交的节点且符合 ART_b模块的期望精度。

3.2.2 分类学习算法

若分类样本具有 M 个波段,分类后共具有 L 类地面目标类型。则可设 ART_a模块的 F₀层有 M 个节点, F₁层有 M 个节点, F₂层有 N 个节点。给定 M 维输入样本集 a 中的样本向量 $x = [x_1, \dots, x_M]$, 其中 x_i为像元各波段光谱反射率, $x_i \in [0, 1]$ 。原形向量 z_j表示 F₁层和 F₂层之间的双向连接权值向量。ART_b模块的 F₀层有 L 个节点, F₁层有 L 个节点, F₂层有 K 个节点。b 为 L 维期望输出类型向量。给定 $0 \leq \rho \leq 1$ 为系统警戒阈值, $0 \leq \eta \leq 1$ 为系统的学习速度。

基本的学习步骤如下:

网络根据 x 与 F₂层存储的各类型单元的原形向量 z_j的相似性来确定归为哪一类别。对 F₂层的任一节点 j 其选择函数为:

$$T_j(x) = \frac{|x \wedge z_j|}{\beta + |z_j|} \quad (5)$$

此处 $\beta > 0$ 为选择参数,逻辑“与”运算符 \wedge 定义为:

$$(p \wedge q)_i \equiv \min(p_i, q_i) \quad (6)$$

模 |·| 定义为对 M 维向量 P, 有:

$$|P| \equiv \sum_{i=1}^M P_i \quad (7)$$

网络在此基础上选择 F₂层的节点 J, 其中有:

$$T_J = \max\{T_j; j = 1, 2, \dots, N\} \quad (8)$$

这样, F₁层的活动向量成为 $x \wedge z_j$ 并与当前输入样本向量 x 做比较得匹配强度 k, 其值定义为:

$$k = \frac{|x \wedge z_j|}{|x|} \quad (9)$$

k 与系统警戒阈值 ρ 比较, 如果匹配强度 $k \geq \rho$ 则该类型被赋予 F₂层该节点 J 同时调整原形向量如下:

$$z_j^{(new)} = \eta(x \wedge z_j^{(old)}) + (1 - \eta)z_j^{(old)} \quad (10)$$

式中, z_j^(new) 为调整后的权值向量, η 为学习速度。式(10)右边第一项反映了新的输入样本向量对于调整后的权值向量的贡献量, η 越大, 其贡献量越大, 匹配强度 k 越大, 贡献量越小, 表明对于相似度大的样本“注意力”低; 反之, 若匹配强度 k 越小, 贡献量越大, 表明对于相似度小的样本“注意力”高。式(10)右边第二项反映了旧的权值向量对于调整后的权值向量的贡献量。

如果 $k < \rho$ 则在余下的节点中按(8)式分配一个新的 F₂节点, 重新进行以上过程的网络训练。继续检验直到最终在 F₂层中找到节点满足 $k \geq \rho$ 为止。

当无法在当前系统警戒阈值的条件下达到期望的训练精度时, ART_b通过 F^{ab}以及匹配跟踪技术自动增大警戒阈值 ρ 从而使 ART_a的 F₂层产生新的提交的节点来满足 ART_b模块的期望精度。

3.3 分类结果

以节 3.1 中筛选出的波段做为输入波段, 利用 Fuzzy ARTMAP 分类器对栾城地区的成像光谱仪数据进行了分类, 区分出了高邮 503, 9204, 4185 及早熟品种等 4 种小麦的种植田块, 如图 6 和图 7。

本文选取中国科学院栾城农业实验站的实验田块(分类结果如图 7)进行了精度验证。根据农业站田块工程设计图和实地丈量结果, 得出每种小麦的面积(单位平方米, 见表 2), 再从分类结果图中计算出每种小麦分对和分错的面积, 从而计算出实际分类精度, 见表 2, 结果表明, 小麦品种分类精度, 除 4185 外均达到 90% 以上, 总的小麦分类精度超过 90%。

表 2 四种小麦的分类精度

Table 2 The classification accuracy of four wheat types

	503 小麦	9204 小麦	4185 小麦	早熟小麦	其他地物	合计	分类精度 / %
503 小麦	12996	459	0	162	383	14000	92.8
9204 小麦	117	10953	468	72	390	12000	91.3
4185 小麦	0	621	6849	378	152	8000	85.6
早熟	0	0	315	4536	149	5000	90.7
合计	13111	12033	7632	5148	1074	39000	90.6




图6 栾城成像光谱数据分类结果

Fig.6 The classification of Luancheng imaging spectrometer data




图7 实验点成像光谱数据分类结果

Fig.7 The classification of the test area

4 结 论

高光谱数据提供了丰富而又冗余的信息,本文以国产成像光谱仪数据为例,对高光谱数据的特点进行了分析,引用遗传算法结合小麦生物物理特性筛选出了参与分类的波段。利用 Fuzzy ARTMAP 分类器进行了地物分类,识别了不同的小麦品种。本文认为利用 GA 算法结合小麦生物特性进行的特征选择从理论上是可靠的,从实践上是可行的,是一种针对作物品种分类的有效特征选择方法;对不同小麦品种识别的精度超过 90%,说明利用高光谱数据结合合理的特征及分类器的选择,能够实现不同小

麦品种的识别。

参 考 文 献 (References)

- [1] Lakshmana Rao K M. Remote Sensing for Land-Use Planning [J]. International Journal of Remote Sensing, 1995, 16(1): 53- 60
- [2] Tucker C J, Townshend J R G, Goff T E. African Land-Cover Classification Using Satellite Data [J]. Science, 1985, 227: 369- 375.
- [3] Defries R S, Townshend J R G. NDVI-Derived Land Cover Classification at Global Scales [J]. International Journal of Remote Sensing, 1994, 15: 3567- 3586.
- [4] Staenz K, Deguise J C, Chen J, et al. The Use of Hyperspectral Data for Precision Farming [A]. ISPRS Commission VII Symposium [C]. Budapest Hungary, September 1- 4, 1998.
- [5] Staenz K. Classification of a Hyperspectral Agricultural Data Set Using Band Moments [J]. Canadian Journal of Remote Sensing, 1996, 22(3): 248- 257.
- [6] Deguise J C, McGovern M, McNaim H, et al. Spatial High Resolution Crop Measurements with Airborne Hyperspectral Remote Sensing [A]. 4th International Conference on Precision Agriculture [C]. Saint Paul Minnesota, 19- 22 July, 1998.
- [7] Tong Q X, Zheng L F, Wang J N, et al. Imaging Spectrometry Remote Sensing Study for Wet Land Vegetation [J]. Journal of Remote Sensing, 1997, 1(1): 50- 57. [童庆禧, 郑兰芬, 王晋年等. 湿地植被高光谱遥感 [J]. 遥感学报, 1997, 1(1): 50- 57.]
- [8] Gong P, Pu R L, Yu B. Hyperspectral Data Identify and Analysis for Different Temporal Conifer Breeds [J]. Journal of Remote Sensing, 1998, 2(3): 211- 217. [宫鹏, 浦瑞良, 郁彬. 不同时相针叶树种的高光谱数据识别和分析 [J]. 遥感学报, 1998, 2(3): 211- 217.]
- [9] Forutan I, Sklansky J. Feature Selection for Automatic Classification of Non-Gaussian Data [J]. IEEE Transactions on Systems Man and Cybernetics, 1987, 17: 187- 198.
- [10] Fukunaga K. Introduction to Statistical Pattern Recognition [M]. Academic Press, New York, 1990.
- [11] Richards J A. Remote Sensing Digital Image Analysis: an Introduction [M]. Springer-Verlag, Berlin Heidelberg, Second Edition, 1993.
- [12] Bruce L M, Koger C L, Li J. Dimensionality Reduction of Hyperspectral Data Using Discrete Wavelet Transform Feature Extraction [J]. IEEE Transaction on Geoscience and Remote Sensing, 2002, 40(10): 2331- 2338.
- [13] Lee C, Landgrebe D A. Feature Extraction Based on Decision Boundaries [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1993, 15: 388- 400.
- [14] Yang J G. Artificial Neural Network Applied Tutorial [M]. Hangzhou: Zhejiang University Press, 2001. [杨建刚. 人工神经网络实用教程 [M]. 杭州: 浙江大学出版社, 2001.]
- [15] Zhou Z H, Chen Z Q, Chen S F. Self-Adaptive Resonance Theory Review [J]. Computer Science, 1999, 26(4): 54- 56. [周志华, 陈兆乾, 陈世福. 自适应谐振理论综述 [J]. 计算机科学, 1999, 26(4): 54- 56.]