

应用神经网络模型分解 AVHRR 混合像元

王 喜 鹏

(南开大学环境科学系 天津 300071)

张 养 贞

(中国科学院长春地理研究所 长春 130021)

摘 要 在大面积农作物遥感估产中,应用气象卫星数据估算种植面积一直是一个难点。已有的混合像元分解法要么实际操作困难,要么不适用于 AVHRR 数据。该文在前人研究的基础上提出了一种新的方法——应用 AVHRR 混合像元神经网络分解模型估算种植面积。这种方法综合利用了 TM 数据与 NOAA 数据各自的优势,具有较好的科学性和经济可行性。

关键词 AVHRR 混合像元,神经网络

1 问题的提出

农作物的遥感估产主要包括 2 个部分:1)利用遥感资料估算农作物的种植面积;2)监测农作物的长势,估算单产。目前国内外对单产模式研究较多,有农学预报、气象统计、遥感气象综合模型等方法。这些方法均达到了一定精度,推动了遥感估产技术的发展。但对于难度较大的种植面积的估算,尤其是利用气象卫星数据进行大范围农作物种植面积提取,却研究甚少,还没有一种成熟而有效的方法^[1]。一般是利用陆地卫星进行农作物遥感图像分类,采用模式识别技术对其 CCT 数据进行监督或非监督分类;或者直接对其假彩色合成图像进行目视解译。由于 TM、SPOT 等图像的空间分辨率、光谱分辨率较高,因而无论是计算机自动分类还是目视解译,提取的种植面积精度都是可以接受的,对于小范围农作物遥感估产是可行的^[2]。但是,由于地球表面陆地上空常年有 65% 左右的区域被云覆盖,加之陆地卫星每 16 天才能覆盖地球 1 次,因此 TM 图像的时间分辨率较低。这一点对大面积遥感估产运行系统是很不利的,而且每景 CCT 磁带覆盖范围小,价格昂贵,更加制约了 TM 等信息源在大范围遥感估产中的应用。

用气象卫星 NOAA 进行作物估产只是近年来

的事。NOAA/AVHRR 第 1,2 通道是植被监测的主要通道,基本上能反映农作物的光谱反射特性。NOAA 的重复观测周期缩短到 0.5 天,在双星系统下,同一地点每天有 4 次过境资料,时间分辨率大为提高;另一方面,获取 AVHRR 数据资料的成本也大大降低。这两点都为建立一个大面积农作物遥感估产实用系统提供了良好基础。利用 AVHRR 数据计算面积的最大难点是其空间分辨率太低,星下点就达 1.1km。所以陆地范围内的 AVHRR 像元基本上均为混合像元。到目前为止,对遥感影像的经典处理方法均以像元为不可再分的基本单位。因此要利用气象卫星数据取得准确的面积,传统的图像处理方法已不适用于定量遥感的要求^[3],必须采用新的方法——混合像元分解法。

文献 [3] 利用 AVHRR 多时相的优点,以垂直植被指数 PVI 的线性可加性分解 AVHRR 混合像元,取得了较好结果。该法物理含义明确,理论上有很好的科学性,是一个突破;但在实际应用中各类地物 PVI 的动态变化矩阵的实测要求很难满足,不但要对各类地物的 PVI 进行测量,而且这种测量还得对应于 AVHRR 的各个时相同步进行。

文献 [4] 充分利用典型地物的灰度值及其线性可加性,从另一个角度提出了分解混合像元的方法。该法简单、实用, TM 图像的计算机分类精度提高了

25个百分点。不足之处是仅适用于空间分辨率较高的图像例如 TM 等。对于 AVHRR 数据,由于无法找到典型地物的光谱值,因而不适用。

上述方法均有一定的理论意义和实用价值。在大面积遥感估产实验中,受成本制约,信息源不应一味要求有较高的分辨率;同时也受精度制约,方法上不应一味只求简单、方便、价廉,二者之间应寻求某种适度的平衡,发挥各种信息源和方法的优势,扬长避短,找到一种最佳的组合方案估算种植面积。一种可行的方案是在小范围的典型样本区上,利用高分辨率的 TM 数据获得训练样本数据,然后以此对 AVHRR 混合像元神经网络分解模型进行训练,训练生成的分类器再对大范围的 NOAA / AVHRR 数据进行分解分类,最后对分解、分类的结果进行统计、输出。这个方案综合利用了 TM 数据和 AVHRR 数据各自的优势,具有较好的科学性和经济可行性。应用神经网络模型分解 AVHRR 混合像元是这一方案的难点和重点。其基本思路是:以训练样本区每个 AVHRR 混合像元的光谱值为输入,该像元所对应地表范围的 TM 图像分类结果为输出,应用神经网络模型求出二者的映射关系。

2 神经网络分解模型的基本原理

人工神经网络是指由大量类似于生物神经系统的神经细胞的人工神经元互联而成的、具有一定智能功能的网络。根据神经元在网络中联结方式、学习方式和信息传递方向的不同,可以把网络划分为若干类型例如线性联想记忆网络、离散自相关器网




图 1 一个具体的神经网络

Fig.1 An example of neural network

络等^[5],依所要解决的问题的特点和性质而定。AVHRR 混合像元神经网络分解模型采用的是误差逆传播前向网络(简称 BP 网络)。这种网络的拓扑

结构如图 1 所示:

这是一个 3 层网络,共含有 11 个神经元(该研究实际采用的网络含 35 个神经元)。一般情况下每个神经元都向与它连接的神经元提供一个可加性输入。各神经元是一个多输入单输出的非线性处理元件,都具有 2 个功能:收集前面一层神经元的激活值,确定自己输出的激活值。每对神经元之间的联结权重表示前一个神经元输入到后一个神经元的激活值之连接强度。根据网络结构和功能的不同,神经元也具有不同的运算模型。该文所采用的是 Rosenblatt 提出的感知机的阈值逻辑单元^[6],其显著特点是神经元之间的连接权值是可变的,从而保证了网络具有学习能力。

神经网络的信息处理功能由神经元的激活特性、网络的拓扑结构、连接权的大小和神经元的阈值所决定。在拓扑结构固定时,神经网络的学习归结为联结权的变化。根据学习规则的不同,学习可以分为 4 类:误差修正型学习、随机型学习、赫布型学习和竞争型学习^[5]。该研究的 AVHRR 混合像元神经网络分解模型采用的是误差修正型学习。

BP 网络是神经网络中最大的家族。该网络通过权值实现样本数据的正向映射。所谓样本数据是指由输入模式与期望输出模式对组成的训练数据和校验数据。训练的目的在于希望得到的权值能产生较小的误差和最大的精度。误差判据(又称代价函数、误差测度函数)可以有多种形式,例如熵代价函数、线性误差函数等。该研究采用常见的均方误差准则,即对训练样本中的所有输入模式上输出单元希望的输出与实际输出误差平方和^[7]:

$$SSE = \frac{1}{2} \sum_p \sum_k (a_{pk} - t_{pk})^2$$

式中 p 代表全部输入模式与希望输出模式对, k 代表第 k 个输出单元, a_{pk} 代表当输入模式为 p 时第 k 个输出单元的输出, t_{pk} 是对应的希望输出模式。

3 试验环境和数据特点

根据是否具备 AVHRR 和 TM 的晴空资料、典型地物的代表性、能否找到适当数量的控制点、时相是否适用于玉米遥感估产等因素,选择了位于吉林省、内蒙古自治区和辽宁省 3 省交界处的区域作为研究区, E123°00'—124°30', N42°15'—43°45', 包括吉林省的四平地区、内蒙古的科尔沁左翼后旗、辽宁省的铁岭地区共计 12 个县。

在研究区范围内,根据地面覆盖类型在全区范围内的典型性又划分了 3 块试验子样区。1 号样区为二龙山水库样区,2 号样区为清河水库样区,3 号样区为花胡硕哈嘎样区。其中的 2 号样区生成校验样本数据,其余 2 个样区生成训练样本数据。

TM 数据 2, 4, 7 波段的假彩色合成像片,中心经度 E123°48', 纬度 N43°11', 日期为 1991 年 8 月 24 日,无云; AVHRR 数据从国家气象局气象卫星中心购取,共 1 幅 2 个波段(可见光波段和近红外波段),幅面大小为 576 × 768 像元,纬度范围 N41.5°—48°,日期为 1991 年 8 月 23 日,部分地区有云。

实验的硬件环境: AST486 主机, 时钟 33e, 4MB 内存, 硬盘(E)可用空间 20MB, PINWRITER P6300i 宽行彩色打印机。

实验的软件环境: MS-DOS6.0 版, PC ARC / INFO 3.4D 版(1990 年)。自行开发的程序均由 TURBO C2.0 编成。

AVHRR 数据量化级高,达到 10byte 1024 个量化级,而陆地卫星的 TM 仅为 8 byte 256 个量化级。因此 AVHRR 数据经过定标可较精确地描述地面覆盖类型的光谱特性;它还具有热红外通道,易于进行大气校正,并且对水体、植被、地热等反映敏感;数据覆盖范围广,接收设备简单,易于推广应用^[8]。

AVHRR 的扫描角为 55°,扫描时的步进为 0.000937°,每个时刻采样的瞬时视场角为 0.0013°,因而像元之间在扫描方向和步进方向均有重叠。像元大小的变化也随扫描角的增大而增大。星下点的 AVHRR 像元是一个圆,扫描线两端则是纵横向均有重叠的变了形的椭圆^[9]。受地球曲率的影响,不同轨道、不同时相的同名 AVHRR 像元的位置和形状均变化较大,但在高斯-克吕格投影体系下,像元的形状是不规则的四边形^[10]。因此,代表同一地物的某个 AVHRR 混合像元,在不同的 AVHRR 数字图像上其地理位置、形状、大小、光谱信息均有着很大变化,而同一数字图像上不同像元的形状大小也在发生变化,这给分解 AVHRR 混合像元造成了很大困难。为此,该研究在尽量合理的情况下对 AVHRR 混合像元作了简化性假设。例如在样区范围很小的情况(例如 20 × 20 像元)下,可以假定像元大小和形状是不变的。由于 1) 经过预处理后提供给用户的 AVHRR 数据的像元灰度值是经过重采样后得到的,所以每个像元的灰度值并不是严格对应于地面上圆或椭圆范围内地物光谱信息的平均值,每个像元所对应的地面范围可以说是未知的或者说是变动的;

2) 混合像元分解的结果形式是各类地物在混合像元中所占面积的百分比,对于混合像元的形状没有严格要求;3) 在高斯-克吕格投影下混合像元的形状是四边形;4) AVHRR 数据与 TM 数据配准时, AVHRR 栅格数据转化为矢量形式后,每个像元的几何形状为平行四边形。所以根据以上 4 条理由,该文还假定样区内的 AVHRR 混合像元的形状是平行四边形。

在 NOAA 遥感应用研究中,载有地物信息的电磁波在被 AVHRR 接收之前,其能量强度、波谱特征及其空间分布都会受大气影响而产生辐射畸变和几何畸变。为有效建立地面覆盖类型和 AVHRR 光谱数据之间的映射关系,必须进行预处理,做辐射校正和几何校正。这一工作均由北京大学遥感应用研究所的气象卫星校正软件完成。

4 训练及校验样本数据的获取

BP 网络属于有监督学习网络的一种^[11],它需要一定量的训练样本数据。同时为了检验模型运行结果的精度,我们还需要一组校验样本数据。这 2 类数据的获取过程基本类似,也是该研究的难点之一。

4.1 AVHRR 数据的前期处理

经过预处理后的 AVHRR 数据为 10bit 1024 个量化级,每 2 个字节存放 1 个像元的灰度值。为了满足 VGA 显示适配器分辨率为 200 × 320 × 256 显示方式的要求,首先把 AVHRR 10bit 的栅格数据转化为 8bit 格式,即把每个像元的灰度值右移 2 位。此后就可开窗口选定子区了。

8bit 数据生成的植被指数图像主要用于与 TM 目视解译图配准叠加。在这个过程中有两个问题要解决:一是必须能在植被指数图上找到足够数量的(大于 4)、分布均匀的、与 TM 解译图上的控制点相对应的控制点;二是生成的植被指数图中,各像元的植被指数值出现的频率应尽量呈均匀分布,这样在由栅格形式转换为矢量形式后,代表每个像元的平行四边形将尽可能以非连通的形式出现,从而有利于计算单个像元中各类地物的面积。我们根据像元植被指数值的频率直方图和对照 TM 图像确认控制点的比较,选用了垂直植被指数(PVI)图像,认为该类图像控制点特征突出,像元值分布比较均匀。

随后显示 PVI 图像和添加控制点。至此生成的 AVHRR 数据文件还必须转换成 ARC / INFO 系统所能接收 ASCII 码形式。转换生成的数据文件以栅

格形式进入 ARC / INFO 系统。

4.2 TM 样区基准图的获取

作为研究与 AVHRR 数据相比较的“真实”数据, TM_{2, 4, 7} 三个波段假彩色合成图像具有空间分辨率高、几何及辐射畸变小、影像层次丰富、地物界线清晰、色彩及其饱和度变化多样的特点。鉴于精度、可靠性、转换方式等因素的考虑, 该文没有采用计算机自动分类, 而是采用比较成熟的目视解译的办法得到基准图。为实现 AVHRR 数据与 TM 数据的叠加, 利用 ARC / INFO 将 TM 解译图数字化。数字化时为将类型编码直接加入属性数据文件以便将来查询面积时用, 又将用户标识符改造为类型编码。至此完成了 TM 方面的数据准备工作。

4.3 样本数据文件的获取

首先将 AVHRR 栅格数据矢量化, 再利用 ARC / INFO 的空间操作功能, 实现 TM 基准图与 AVHRR 数据的叠加, 得到查询底图。TM 数据与 AVHRR 数据的叠加精度完全取决于控制点的匹配是否准确。TM 图像的控制点容易确定, 但因空间分辨率相差很大, 一个 AVHRR 混合像元至少包含 $1100^2 / 30^2 \approx 1344$ 个 TM 像元, 这给在 AVHRR 图像上确认同名控制点造成很大困难。为此我们放大显示 AVHRR 的 PVI 图像, 在单个 AVHRR 像元范围内通过目测估计 TM 图像控制点的相对位置来添加控制点。由于 1) 选取的 PVI 图像控制点特征突出; 2) 整个样区内控制点数目不少于 4 个且分布均匀; 3) 同名控制点是在放大的单个 AVHRR 像元内添加的, 所以这种方法的叠加精度虽然不高, 但总体上的偏差也不会很大, 这从叠加后的查询底图上地物之间的对应关系也可看出。当然如何利用 GIS 技术实现 TM 与 AVHRR 2 类遥感信息的高精度复合, 是课题今后有待解决的难点之一。

利用 ARC / INFO 的空间属性数据查询功能, 逐幅、逐行、逐个地查询非连通单个像元的类型代码和面积数值, 并记录下来。对于与相邻像元连通的像元, 可将叠加图放大打印输出, 将连通的像元划线分割, 然后用方格面积量算法求出每个像元内各多边形的面积。将记录的原始样本数据逐行输入计算机, 形成 ASC II 码形式的原始样本数据文件。

原始样本数据文件有两点不能满足要求: 1) 为 ASC II 码形式, 存取速度慢, 精度有限; 2) 面积的数值为绝对面积值, 根据分解混合像元的要求应一律

转化为相对值。据此开发程序, 逐行读入像元编号、类型代码和面积数据, 求出每一像元各类地物的相对比值, 再以二进制形式按类型代码的顺序依次存入, 最后形成样本数据文件。

至此生成的样本数据文件仅满足了模型输出端的要求, 即给出的是像元中各类地物的百分比值。还有一类样本数据文件应满足模型输入端的要求, 即给出产生这样地物分配比例的信息, 是什么原因促成了这样的地物分配比例。具体到有哪些因素起作用, 涉及到模型的结构设计。这里只给出结果: 输入端 6 个神经元, 其输入值依次是第 1 通道值、第 2 通道值、垂直植被指数、差值植被指数、归一化植被指数和比值植被指数。各个数值均要规范化到 0—1 之间, 依序以二进制形式存放。

这样, 各样区的训练及校验样本数据均已获得。

5 模型结构与算法设计

神经网络在信息处理中最典型、最有希望的领域就是模式识别, 与传统的模式识别系统相比有以下几个明显优点^[5]: 1) 能够识别带有噪声或变形的输入模式; 2) 具有很强的自适应学习能力, 通过对样本的学习, 掌握模式变换的内在规律; 3) 能够把识别处理与若干预处理融合在一起进行。

5.1 模型拓扑结构设计

网络为多重前向网络 根据分解模型识别区域为无界的凸区域这一特点, 只有多重网络能够识别结点数确定的任意更复杂区域。为减少计算量, 确定模型为 3 层网络。

输入层神经元结构 模型输入层决定网络分解混合像元的根据是什么。显然, AVHRR 混合像元的分解只能依赖于 AVHRR 光谱信息和时相信息。该研究只初步对光谱数据的利用作了探讨, 在 AVHRR 5 个波段的光谱数据中只使用了比较广泛应用的可见光波段 (0.58—0.68 μm) 和近红外波段 (0.725—1.1 μm)。因包含在单一光谱波段的信息常不足以描述植被状态, 故而结合这 2 个波段形成植被指数。4 个植被指数加上第 1, 2 两个波段值构成模型的输入层, 神经元为白化结构, 即植被指数和二通道值经归一化处理后进入分解模型的下一层(隐层)。

输出层神经元结构 每给一组 (6 个) AVHRR 混合像元的光谱数据, 经过神经网络分解模型的处理, 输出该像元所对应的 9 类地面覆盖类型所

占比值。所以输出层共含有 9 个神经元。每个神经元的输入值为隐层各神经元输出值的加权和,输出值为该神经元所代表地物在混合像元中所占比值,与样本数据文件的格式相对应。

隐层神经元结构 隐层神经元个数与输入、输出层的个数尚无简单的联系,据文献[6]取输入层与输出层的平均数为宜。但经实际上机运行检验,隐层神经元取 7 或 8 均不理想,这与映射变换的复杂性有关。经实验取 20 效果较好。

分解模型的结构除了层数、每层神经元个数、每个神经元结构等要求外,还应考虑神经元之间的联结方式即权重的确定。该研究模型的原始权重是随机给定的,通过一组训练样本数据的训练,学习获得最佳模型权重空间,从而确定了模型的最终结构。再以此模型对所给 AVHRR 混合像元进行分解。

5.2 模型算法设计

AVHRR 混合像元分解模型通过多层误差修正梯度下降法离线学习,按离散时间方式运行。学习通过一个使代价函数最小化过程完成输入到输出的映射。

该文采用 BP 算法,每给网络提供一套输入输出模式对,即 $20 \times 20 = 400$ 个 AVHRR 混合像元的 6 种光谱数据及每个像元所对应的 9 类地物所占占比值,首先进行前向传播并计算出各单元的一般化误差,然后逆向往输入层传播,求出各单元的参考误差。此后进行连接权和各单元阈值的调整,这样便完成一次迭代。对下一模式对,重复上述过程,当 400 个模式对各自的迭代都完成以后,又重复对第一模式对的迭代,这样循环下去,直到输出层单元的误差满足要求为止。

算法设计中重要的一环是学习率的确定,其大小对学习训练时间的长短有重要影响,也有文献称之为学习增益系数,表示沿误差曲面上的最速下降方向移动的步长^[6]。过大有可能跨过深窄的极小点,过小有可能滞留于局部极小点。该研究采用动态调整学习率的办法,即在模型训练过程中适时改变其大小,加快学习速度。为保证收敛性的要求,该研究学习率的值控制在 0.0001—0.1。

6 运行结果与讨论

在人工逐个像元查询获得 3 个样区共计约 5000 个数据的基础上,编制了 AVHRR 混合像元分解模

型的训练学习程序,在 486 微机上连续运行 42h,得到分解模型的权重空间。利用训练成功的模型对校验样本区(第 2 样区)进行分类。分类的实验结果表明,水体与居民地容易混淆,旱地、水田、林地也不易区分。这取决于训练样本数据及校验样本数据的质量,同时还与模型的拓扑结构和算法设计有关。总精度由均方误差和为 59.126 可粗略估算为

$$1 - \sqrt{59.126 / 400} = 62\%$$

这个精度离实用要求还差很远,有待于今后作更细致的研究。该文仅就与模型的结构和算法有关的问题作一初步探讨。

1)神经网络模型的仿真运行有一条很重要的性质,即 expensive^[7],也就是说输入层提供的信息越多(即增加输入端的维数),则收敛速度成数量级提高,精度也会有很大改善。AVHRR 数据共有 5 个波段的光谱数据,如果把 3 个热红外波段(分别为 3.55—3.92 μm , 10.5—11.5 μm 和 11.5—12.5 μm)加入到网络的输入层,AVHRR 混合像元分解模型的运行速度和精度将会有很大提高。

2)模型的性能不但依赖于输入层信息的数量,还取决于信息的质量。例如设计更能反映绿色植被光合作用特点的植被指数^[11],象土壤调节植被指数(SAVT)把红波段、近红外波段形成的 SVT 土壤亮度影响最小化;除最小化背景的影响,还可用大气顶层(TOA)光谱辐射值校正大气影响以恢复植被信息。开发光谱模型和指数以改善受大气、土壤影响的植被敏感度。这样神经网络模型所接收的信息质量更高,分解混合像元的精度也就更高。

3)该文在模型结构的细节设计上还有许多工作要做。例如该文采用的是应用较广泛的 BP 网络。实际上也可采用其它结构的网络例如盒中脑(BSB)网络^[5]。BSB 网络的误差修正学习同样实现了整个模式训练集上希望输出与实际输出均方误差的梯度下降,且收敛到均方误差函数的唯一最小点,而不是 BP 网络的满意极小点。又如逻辑活动函数的参数该文只是人为地规定了它们的取值,实际上应该根据分解模型的运行结果与校验数据进行比较,通过实验来确定。

4)AVHRR 混合像元分解模型通过 2 个训练样区进行学习,建立了模型的权重和阈值空间。虽然学习时间较长,但这对于遥感估产任务来说不是主要问题。因为模型一旦通过学习建立,对 AVHRR 大范围数据进行分解分类是快速的(一般需要 10—30min)^[12],在实用估产系统中也是可以容忍的。所

以建立实用化分解模型的关键在于样本数据的准确性。如何开发出一套规范的、基于高精度的 GIS 技术的样本数据获取过程和方法,是以后工作中有待解决的难点和重点。

参 考 文 献

- [1] 王喜鹏. 大范围遥感估产中面积提取技术的理论与方法. 中国科学院长春净月潭遥感实验站年报. 吉林科技出版社, 1995.
- [2] 王乃斌等. 应用 TM 图像采用模式识别技术自动提取冬小麦播种面积的研究. 小麦、玉米和水稻遥感估产技术试验研究文集. 北京: 中国科学技术出版社, 1993.
- [3] 徐希孺等. 混合像元的因子分解方法及其在大面积冬小麦种植面积估算中的应用. 科学通报, 1990, 35(4): 317—320.
- [4] 刘永怀. 混合像元分解的理论与方法. 遥感技术与应用, 1992, 7(1).
- [5] 靳蕃等. 神经网络与神经计算机. 西南交通大学出版社, 1991.
- [6] 何明一. 神经计算原理、语言、设计、应用. 西安电子科技大学出版社, 1992.
- [7] H. Bischof, *et al.* Multispectral Classification of Landsat-images Using Neural Networks. *IEEE Transaction on Geoscience and Remote Sensing*, 1992, 30(3).
- [8] 陈述彭等. 遥感地学分析. 北京: 测绘出版社, 1990.
- [9] J. Cihlar, *et al.* AVHRR Bidirectional Reflectance Effects and Compositing. *Remote Sensing of Environment*, 1994, 48(1): 77—88
- [10] 吴炳方. NOAA AVHRR 1B 数据的几何精纠正. 环境遥感, 1994, 9(4).
- [11] 史忠植. 神经计算. 电子工业出版社, 1993.
- [12] Philip D. heerman *et al.* Classification of Multi-spectral Remote Sensing Data Using a Back-Propagation Neural Network. *IEEE Transaction Geoscience and Remote Sensing*. Vol. 30 No. 1 January 1992.

作 者 简 介

王喜鹏, 男, 南开大学讲师, 1963 年 8 月生, 1995 年硕士毕业于中国科学院长春地理研究所地图学与遥感专业, 现从事遥感应用与地理信息系统方面的科研与教学工作, 已发表论文 4 篇。

The Study on Decomposing AVHRR Mixed Pixels by Means of Neural Network Model

Wang Xipeng

(Environmental Science Department in Nankai University, Tianjin 300071)

Zhang Yangzhen

(Changchun Institute of Geography, Chinese Academy of Sciences, Changchun 130021)

Abstract In large area crops yield estimation from remote sensing data, crops planting area estimation with NOAA data remains to be resolved difficultly. Those mixed pixed decomposition methods given before are impractiable, or not suitable for AVHRR data. In view of points above, a new method, more scientific and economic than before, is put forward, that is to estimate crops planting area by means of AVHRR mixed pixel neural network decomposition model, which comprehensively makes use of the advantages of both TM data and NOAA data.

Key words AVHRR mixed pixel, Neural network