

文章编号: 1007-4619 (2001) 02-0122-08

人工神经网络遥感影像分类模型及其与知识集成方法研究

骆剑承¹, 周成虎¹, 杨 艳²

(1. 中国科学院 地理科学与资源研究所资源与环境信息系统国家重点实验室, 北京 100101;

2. 北京师范大学 环境科学研究所, 北京 100875)

摘 要: 以多层感知器(MLP)为例, 探讨了地学知识与 ANN 融合进行遥感影像分类的方法。首先对 MLP 网络结构、学习算法及其改进进行分析; 然后总结了 MLP 进行遥感影像分类的一般方法和存在的缺陷; 发展了基于知识的 MLP 神经网络遥感影像分类模型, 并具体利用基于规则的 MLP 方法进行了遥感土地覆盖分类的实验, 把获得的结果与传统统计方法和一般 ANN 方法进行了综合比较, 获得了有意义的结果。

关键词: 人工神经网络; 多层感知器; BP 学习算法; 遥感图像分类; 地学知识

中图分类号: TP751.1 文献标识码: A

1 引 言

随着人工智能技术和理论的发展, 当前遥感图像分类的研究也向更高层次的智能化方向发展, 主要热点包括空间结构信息提取和分类、基于知识的空间逻辑推理分类和信息提取、非线性并行处理人工神经网络分类方法等^[1]。人工神经网络(ANN)是由大量处理单元(神经元)相互连接的网络结构, 反映了人脑功能的基本特征, 是人脑的某种抽象、简化和模拟。ANN 信息处理是由神经元之间的相互作用来实现的, 知识和信息的存储表现为网络结构分布式的物理联系, 网络的学习和处理过程决定于神经元连接权值的动态变化。由于 ANN 通常采用非线性作用函数, 因此其动态运行构成了非线性动力学系统, 具有不可预测、不可逆、多吸引子等特点, 因此 ANN 可模拟大规模自适应的非线性复杂系统^[2,3]。

ANN 广泛应用于优化、模式识别、知识处理、信号处理等领域^[3], 其中很早就成功应用于模式识别领域, 80 年代末开始应用于遥感图像分类^[4]。遥感图像分类是反映人对图像的一种理解, 理解包括浅

层的视觉生理理解和深层的逻辑心理理解等两种层次^[5], 大多基于 ANN 方法的图像识别正是人的视觉生理现象的简单模拟^[3]。虽然当今系统结构计算机系统要模拟整个复杂人脑系统或视觉系统是不可能的, 但 ANN 是基于简单神经元结构单元的网络结构, 与传统统计方法相比, 具有并行处理、自适应、非线性动力机制等优势^[3,4,6-9]; 另外, 特征空间可自由分布, 类别在特征空间中可分布为多簇, 因此当特征空间很复杂时, 或者源数据具有不同的统计分布时, 也能获得理想的分类结果。

地学知识和地理信息的辅助决策可以大大提高遥感影像分类和信息提取的精度^[1,2,10]。ANN 除了以其神经计算能力进行低层次图像视觉识别外, 其非符号的连接主义的知识处理能力使地学知识、地理信息与遥感信息互相融合, 来完成深层影像理解及空间决策分析, 是遥感图像分析的研究方向之一。Benediktsson(1990)用 ANN 方法, 在 MSS 影像和 3 类地形数据(高程、坡度、方位)基础上对土地覆盖进行划分^[11]; JRC(1991)用 DTM 数据的高程数据和 2 个时相的 SPOT HRV 影像作为输入数据并应用多层感知器神经网络(MLP)进行土地覆盖分类^[1]。本文首先回顾多层感知器(MLP)模型和 BP 学习算法及其

收稿日期: 2000-05-29; 修订日期: 2000-07-25

基金项目: 中国科学院知识创新项目: KZCX1-Y-02

作者简介: 骆剑承(1970—), 男, 浙江杭州市人。1991 年毕业于浙江大学地球科学系遥感专业。1994 年开始在中国科学院地理科学与资源研究所资源与环境信息系统国家重点实验室攻读硕士、博士学位研究生, 于 1999 年获得博士学位。现为香港中文大学地理系博士后, 主要研究领域包括空间数据挖掘、遥感图像处理、神经计算和演化计算、多尺度空间数据分析和空间信息认知等。已发表学术论文十多篇。

改进方法; 然后提出基于知识神经网络遥感图像分类的两种层次的集成框架; 最后以具体遥感土地覆盖分类为例, 对基于知识 ANN 分类方法进行比较分析。

2 多层感知器 (Multi Layer Perceptron)

2.1 基本概念

感知器 (Perceptron) 是 1957 年美国学者 Rosenblatt 提出的一种用于模式分类的神经网络模型。当时的感知器模型只包括单结点的一个层, 故称为单层感知器 (图 1)。结点的输出为:

$$y = f \left(\sum_{i=0}^{n-1} w_i x_i - \theta \right) \quad (1)$$

其中, w_i 为连接权重, x_i 为输入向量 x 的第 i 分量值, θ 为输出阈值, f 为激励函数, 一般为强制非线性输出函数。单层感知器只适用线性可分数据, 而对于非线性可分数据, 判别边界会产生振荡。




图 1 单层感知器

Fig. 1 Single layer perceptron

为解决非线性可分数据的多类别分解问题, Rumelhart 等人提出了多层感知器 (Multiple Layer Perceptron, MLP) 模型。这种网络模型的结构是由不同层次的结点集合组成, 每一层的结点通过与下一层互连输出到下一结点层, 其输出层通过连接权值而被放大、衰减或抑制。除了输入层, 每一结点的输入为前一层所有节输出值的加权和。每一结点的激励输出值由结点输入、激励函数及偏置量决定。

MLP 网络由感受层 (S)、联想层 (A)、响应层 (R) 构成 (图 2)。S, A, R 均是由同类神经元构成。感受层为网络结构的输入层, 用于特征向量的输入, 它相当于人工视网膜, 用于感知目标对象。联想层为网络中隐含层; 而响应层则为网络的输出层。S 层单元与 A 层单元通过联结关系构成对处理对象的联想矩阵, A 层单元与 R 层单元之间的联结构成对处理对象的决策矩阵。通过训练调整, 使网络形成有序的、具有复杂映射和决策能力的稳定结构。




图 2 多层感知器 (MLP) 网络

Fig. 2 Multi-layer perceptron

2.2 反向传播 (BP) 学习算法及改进

反向传播 (Back Propagation, BP) 学习算法是 MLP 模型中被最广泛应用的, 是最小均方误差 (LMS) 算法的一般化, 用梯度搜索技术, 使等于均方差的代价函数最小。网络开始训练时选用较小的随机互联权值与内部阈值, 通过反复加载训练样本并调整权值, 直到代价函数下降到可以接受的容限值。BP 算法正是将非线性多层感知器系统的判决能力与均方误差函数极小化的 LMS 算法相结合的产物。

如图 2 中, 在 j 层, 结点的输入值为:

$$net_j = \sum_j w_{ji} o_i \quad (2)$$

为满足非线性与连续可微的条件, 结点强制非线性输出函数, 又称激励函数 $f(x)$, 一般选用 Sigmoid 型函数。中间层 j 输出值为: $o_j = f(net_j)$, 同样在输出层 k 的输入为: $net_k = \sum w_{kj} o_j$, 输出值为: $o_k = f(net_k)$ 。

对于一输入样本 p , 其平方误差可定义为:

$$E_p = \frac{1}{2} \sum_k (t_{pk} - o_{pk})^2 \quad (3)$$

对于整个网络系统的总均方误差为: $E = 1/p \sum E_p$, 其中 p 为训练样本总数。

网络训练的目的在于找到一组权值, 使 E 极小化。LMS 算法用梯度下降法, 即权重的增量正比于误差的负导数^[3, 4, 6, 7], 使得过程收敛。

设 $w_{kj}(t)$ 是连接隐层结点与输出层结点在 t 时刻的联结权值, $w_{ji}(t)$ 是连接隐层结点与输入层结点在 t 时刻的联结权值; η 是一个正的常数项, 称为学习率, 反映权重的调整速率。 η 太小, 则学习的效率较低; 反之若 η 太大, 则可能引起振荡。为此, 可引入动量项 α , 使权重的变化与 $w(t) - w(t-1)$ 有关, 可以滤除权重空间中误差曲面的高频偏差, 使有效的权重间隔加大。一般情况下, 动量项在减小振

荡的同时,使算法收敛速度更快。通过推导,误差调整增量可表示为:

$$\begin{aligned}\Delta w_{ji}(t) &= \eta \hat{\delta}_i + \alpha \Delta w_{ji}(t-1) \\ \Delta w_{kj}(t) &= \eta \hat{\delta}_j + \alpha \Delta w_{kj}(t-1)\end{aligned}\quad (4)$$

其中:

$$\begin{aligned}\hat{\delta} &= o_j(1-o_j) \sum_k \hat{\delta}_k w_{kj} \\ \hat{\delta}_k &= (t_k - o_k) o_k(1-o_k)\end{aligned}\quad (5)$$

式中, t_k 是输出层的期望输出, o_k 是输出层实际输出。

BP 算法的学习过程,由正向传播和反向传播组成。在正向传播过程中,输入信息从输入层经过隐层,再传向输出层,每一层的神经元的状态值只影响下一层的神经元的状态值;如果在输出层不能得到期望的输出值,则转入反向传播,将误差信号沿逆向通路返回,通过修正各层神经元的权值,使得网络的总误差值收敛到极小。BP 算法实质上是把一组样本的输入输出问题转化为非线性优化问题,采用梯度下降法,迭代运算修正网络联结权重,相应于学习记忆,而加入隐层结点是为了使优化问题的可调参数增加,获得更精确解。MLP 相当于从输入到输出通过对简单的非线性函数的组合,实现了复杂的非线性映射。

BP 算法也存在一些限制,如局部极小、学习效率低、网络结构难以确定等等,使其在实际应用中受到限制。在实际应用过程中,必须根据处理和分析对象的特点和预期目标,对算法和模型进行改进。针对大量基于 BP 神经网络(BPNN)的遥感影像分类应用中碰到的问题^[12-15],我们得出几点 BP 学习算法的改进方法:

(1) 输入向量的预处理(白化处理)。在对遥感影像分类之前,对样本值进行归一化处理,避免网络前后传播过程过饱和现象。

(2) 网络结构设置。隐层的数目和隐层的结点数难以确定,增加隐层数目和结点数,可以提高精度,且有效地较少局部极小的几率,但需要更长的学习时间。根据参考文献[13, 15],如果网络包含两个隐层,第一隐层的结点数至少是输入层结点的 2 到 3 倍,而根据本次工作的经验,甚至应该是 4 倍于输入层结点数;同样,第二层隐层的结点数应该至少为输出层结点数的 2 到 3 倍;如果网络只有一个隐层,则其结点数则至少为以上所述两层结点数的最大值;如果仍然不能达到足够精确的分类结果,则可以适当增加隐层结点的数目,直到获得预期的结果。

(3) 学习速率 η 的自适应性动态调整。学习率 η 的确定,虽然困难,但却是影响算法效率的关键。事实上最优的 BP 算法,其 η 应该是随时间的变化而作动态调整^[14]。 η 调整规则如下:(a) 网络中每个权值可具有不同 η ; (b) 每个 η 允许随时间变化; (c) 当网络中相对于某权值的误差偏量的符号连续保持不变时,即权值空间中误差曲面比较平稳,则该权值的 η 应适当增加; (d) 当网络中相对于某权值的误差偏量的符号发生振荡时,即权值空间中误差曲面起伏较大,该权值 η 应该适当减小; (e) η 值的增减有一定的限度。动态地修正 η 对于误差曲面比较平稳的网络可提高学习速度,而对于起伏较大的误差曲面,可防止发生振荡,加速寻找全局极小,因此同样也提高了收敛速度。

(4) 利用遗传算法(GA)进行网络权值和网络结构的优化。GA 是模拟生命进化机制的搜索优化方法,而 BP 学习算法正是使网络从无序到有序的优化过程,所以利用 GA 是实现网络优化的手段之一。

(5) 地理信息及知识的辅助决策。一般结构化地理信息的参与,只需增加特征向量的维数;而非结构性知识的辅助可通过建立知识库,根据实际分析对象来决定网络结构、学习参数、学习过程中的参数变化等。遥感信息和地理信息、地学知识相融合形成分布式的网络知识结构,提高了影像分类的精度,也保障了网络稳定性。

3 基于知识的多层感知器遥感影像分类模型

3.1 ANN 遥感影像分类的应用研究

基于 BP 学习算法的多层感知器(MLP)模型的遥感影像分类方法已在土地覆盖分类、专题信息提取等方面得到应用^[1, 2],简单概括如下:

(1) 多源遥感影像数据的土地覆盖分类。数据输入的来源可包括多波段、多时相、多平台以及地理辅助数据等通过数据层的像素层、特征层的融合数据等。

(2) 专题信息提取。利用 BPNN 进行植被信息提取^[16, 17]并通过 BPNN 对雷达影像的降雪、降水信息进行提取等。

(3) 空间结构信息提取。主要通过 BPNN 在影像上以一定大小的区域(或窗口)为单元进行空间结构的识别和提取,如线状(如道路、河流)信息提取、纹理结构信息的识别和提取、城市单元结构提取、地

物形状信息识别(如军事目标识别)等。

(4) 模糊分类。应用 BPNN 对样本数据中混合像元所含的多种信息的含量及地物归属不确定性进行学习, 然后进行信息含量的提取或混合像元的分解^[2]。

3.2 地学知识与神经网络的融合

虽然这些分类应用的目标不尽相同, 但是都是建立在统一的神经计算模型之上, 即输入特征相量, 通过分布式神经元的学习记忆及前向推理, 输出结果(归属类别)。目前大多数基于 BPNN 的应用模型, 主要是通过对所选取的包含先验知识的样本数据进行学习, 然后利用 BPNN 高度复杂的映射计算能力来获得最后的分类结果, 因此其知识的决策成

分主要蕴涵于对样本数据的采集, 其中也包括了目视解译的经验知识成分。

这仅是低层次的视觉神经生理模拟的影像理解, 而遥感影像是具有地学属性的, 要揭示更深层的影像地学规律以获得更精确的影像分类和信息提取结果, 则需要汇集相关的地学信息和专家知识来模拟地学专家视觉活动和逻辑判断能力来获取对遥感影像的地学认知。另外, 由于遥感信息的复杂性和不确定性导致样本数据所包含的知识的决策信息是不完全的, 因此如果要进一步提高分类的精度, 需要融合其他辅助信息来加强网络的决策判别能力。一般通过两种方式进行地学辅助信息与神经网络分类模型的融合(图 3):

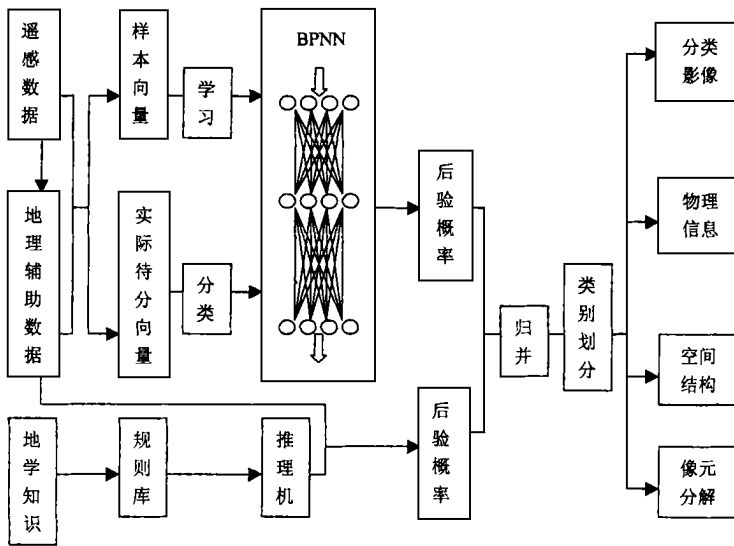


图 3 基于知识的 BPNN 遥感影像分类模型

Fig. 3 BPNN Based RS Classification Model

(1) 结构化地理信息数据作为 NN 输入向量的空间数据维之一与遥感数据并行参与 BPNN 的学习和分类过程。

(2) 非结构化地学知识与空间数据集成形成决策规则库, 通过推理机制, 形成对 BPNN 分类结果的后验验证知识库, 来对分类或信息提取的结果进行验证和修正, 以提高影像分类的合理性和保证精度的提高。

3.3 基于规则的 BPNN 分类模型

地学知识的表示与地学知识库的构造要结合具体地学问题的研究特点^[18]。规则是地学知识的主要表示方法, 能反映地学客观事物的基本规律性。但是由于在实际问题中, 所掌握的规则大多是经验

性、常识性的知识, 其含义是不精确的, 因此所反映的规则也是不确定的, 规则的不确定性可用可信度 CF (Certainty Factor, CF) 来表示。采用产生式的模糊规则形式来表达知识, 其基本形式为:

IF (条件), THEN(结论), CF(可信度因子)

其中, CF 的取值为[0, 1], 反映结论的可能性程度, 当 CF=0 时, 则完全排除结论的可能性; 而当 CF=1 时, 表示结论完全可靠。本次试验工作所采用的部分规则如下:

If ((dem> 0.0) or (slope> 0.0)) then id is c1
 CF is close-to 0.01
 If (dem>= 1.0) then id is c4
 CF is very-close-to 0.06...

符号逻辑的知识处理过程与神经网络的计算协

同作用是对整个视觉图像理解过程的简单模拟,即首先通过神经网络的复杂映射计算获得对图像目标发自本能的基本认识,然后用所具备的后天获得的知识来进一步推断、确认和验证,使所感知的对象具有一定的专业属性。基于地学知识的土地覆盖分类过程是以光谱数据为基础的 BPNN 神经网络分类器所获得的结果作为初始数据,然后使用地形辅助数据和知识库中的规则,进行不确定推理,最后确定出像素单元的所归属的类别。

规则与 BP 神经网络继承的基本处理过程如下:

(1) 通过 BPNN 对训练样本进行学习;

(2) 输入遥感影像的未知模式向量 A , 用 BPNN 计算获得输出向量 y_1 , 作为当前模式 A 属于各类别的后验概率, 即属于各类别的可信度的初始值;

(3) 输入所对应的辅助数据向量 C , 对规则库通过规则匹配进行推理, 计算获得该模式的后验可信度向量 y_2 , 如果无匹配规则, 则获得一预先设定的各类别可信度一致的常向量 o ;

(4) 根据 D-S 证据理论确定模式属于各类别的最终可信度, 最后取最大可信度分量作为该模式的最后类别。

设由 BPNN 计算获得的模式 A 后验可信度向量为: $m_1 = \{0.2, 0.3, 0.3, 0.1, 0.1\}$, 由不确定推理获得的模式 A 的可信度向量为: $m_2 = \{0.1, 0.3, 0.4, 0.0, 0.1\}$, 则最后总的可信度 m 为:

$$m(G) = m_1 \oplus m_2(G) = \frac{\sum_{x \cap y} m_1(x) \circ m_2(y)}{1 - \sum_{x \cap y = \phi} m_1(x) \circ m_2(y)}$$

式中, G 为其中的一个子集, 这里表示所属的类别, ϕ 是空集, $m(G)$ 表示总可信度一部分分给 G 的数据。通过计算得到 $y = \{0.14, 0.35, 0.43, 0.04, 0.04\}$, 所以最后的类别为第 3 类。

4 应用试验

4.1 基于 BPNN 土地覆盖分类

土地覆盖分类是指通过对遥感影像上各种地物光谱信息的分析, 将像元划分为不同类型的土地覆盖单位, 因此地物的光谱属性是土地覆盖分类的主要判别依据。本文以香港元朗地区为实验区, 进行了 BPNN 分类模型支持下的遥感影像分类的应用, 对分类结果与典型的统计方法——最大似然法分类器(MLC)进行了综合比较分析。

BPNN 输入层结点数等于参与分类的数据的特征空间的维数, 辅助数据是通过结构化形式参与分类, 相当于增加了输入向量的维数; BPNN 的输出层等于欲分类的土地类型的数目。选用 TM 的 4 个波段为 BPNN 的输入向量: $A = (PCA1, CH4, CH5, CH7)$ 。其中 PCA1 是 CH1(蓝色波段)、CH2(绿色波段)、CH3(红色波段)这 3 个相关程度比较大的可见光波段经过主成分(PCA)变换后所选取的第 1 主成分, 其中基本包含了 R、G、B 这 3 个波段的总体信息含量, 通过 PCA 变换可以降低特征的维数, 提高学习和分类效率; 另外, CH4 为近红外波段, CH5 和 CH7 为中红外波段(分别是 $1.55-1.75\mu\text{m}$ 和 $2.08-2.35\mu\text{m}$)。

选用的遥感资料为 Landsat-TM5 数据(1996 年 3 月 3 日)。影像大小为 600 行 \times 600 列, 覆盖大约 3200km^2 。通过对实际区域情况的了解和对影像进行目视解译, 把该区域大致分为以下 10 个大类的地物类型:

C_1 —水体(海洋); C_2 —河流、水塘(淡水); C_3 —沼泽; C_4 —红树林; C_5 —城镇区; C_6 —道路; C_7 —裸地; C_8 —绿地; C_9 —林地; C_{10} —高山草地。

其中水体(C_1 、 C_2)、建筑物(C_5 、 C_6)、植被(C_8 、 C_9 和 C_{10})等由于其光谱特征的相近性, 在样本的特征空间分布中互相混杂, 很难分清。对照土地利用图, 分别准备了包含 1700 个训练样本的数据集和包含 800 个测试样本的数据集。首先在这些样本数据集的基础上用传统的统计方法——最大似然分类器(MLC)进行了分类实验, 获得对测试样本的误差矩阵(表 1), 结果表明 MLC 方法所获得的总体测试精度为 83.22%, 其中学习过程大致所需的时间为 5s; 然后, 对同样的训练样本数据集进行 BPNN 神经网络的训练, 然后输入测试样本分别获得分类类别, 并通过与目标类别相比较, 得出 BPNN 分类器的测试样本的误差矩阵(表 2), 网络结构分别为 4, 20, 10 个结点, 大致需要通过 25 min 左右、约 120 000 次循环学习后, 网络达到基本收敛, 最后测试精度为 87.90%, 总体精度比 MLC 提高 4.68%。

4.2 地学知识支持下的 BPNN 土地覆盖分类

大量应用实例表明, 土地覆盖/土地利用对地形因子有明显的依赖关系。在本次实验工作中, 通过融合高程及其派生数据-坡度等因子对类别划分进行控制, 一定程度上提高了分类的精度。根据实际情况与地学基本知识, 初步得出几方面地形与土地

覆盖的关系,如在高程大于 0 的区域不可能有海洋;红树林一般分布在海拔 0—2m 之间;道路、城镇一般分布在海拔 5m 以上、100m 以下、坡度平缓的区域;山地草甸一般分布在海拔 100m 以上的山顶;平原园林、作物等绿地则只能分布在坡度平缓的平原地带;陆地水体的坡度只可能是 0°左右;等等。

同样用相同的 1700 个训练样本作为 BPNN 的训练样本集,另外又选择了加入地形因子后的测试

样本数据集,其中包含 1000 个样本,每一类各包括 100 个样本。用这些测试样本数据进行测试分析表明(表 3),如果没有地形因子辅助,只用 BPNN 所获得的测试样本的总体精度为 87.90%,而在上述规则支持下融合地形因子后,总体测试精度显著提高 91.70%。结果表明,在相关地理数据和地学知识辅助下,能进一步提高神经网络分类的效率和精度。

表 1 MLC 分类方法误差矩阵

Table 1 Error Matrix of MLC Classifier

训练样本 实际分类	C ₁	C ₂	C ₃	C ₄	C ₅	C ₆	C ₇	C ₈	C ₉	C ₁₀	总体
C ₁	93	8	0	0	1	0	0	0	0	0	102
C ₂	4	41	1	0	1	0	0	0	0	0	47
C ₃	0	1	77	4	1	4	0	0	0	0	87
C ₄	0	0	0	91	0	0	0	0	0	0	91
C ₅	3	45	18	0	90	14	0	0	0	0	170
C ₆	0	0	4	0	4	77	2	6	0	4	97
C ₇	0	0	0	0	3	3	98	1	0	0	105
C ₈	0	0	0	3	0	0	0	80	7	0	90
C ₉	0	0	0	2	0	0	0	12	93	0	107
C ₁₀	0	5	0	0	0	2	0	0	0	96	103
总体	100	100	100	100	100	100	100	100	100	100	1000

总体测试精度为 83.22%, Kappa=0.814

表 2 BP 神经网络分类方法误差矩阵

Table 2 Error Matrix of BPNN Classifier

训练样本 实际分类	C ₁	C ₂	C ₃	C ₄	C ₅	C ₆	C ₇	C ₈	C ₉	C ₁₀	总体
C ₁	95	12	0	0	0	0	0	0	0	0	107
C ₂	4	74	4	0	8	0	0	0	0	0	90
C ₃	0	4	84	2	5	8	1	2	1	2	109
C ₄	0	0	0	98	0	0	0	8	0	0	106
C ₅	1	10	12	0	80	12	1	0	0	0	116
C ₆	0	0	0	0	7	78	3	5	0	0	93
C ₇	0	0	0	0	0	0	91	0	0	0	91
C ₈	0	0	0	1	0	0	0	84	2	0	86
C ₉	0	0	0	0	0	0	0	1	97	0	98
C ₁₀	0	0	0	0	0	2	4	0	0	98	104
总体	100	100	100	100	100	100	100	100	100	100	1000

测试时间为 150s, 总体测试精度为 87.90%, Kappa=0.866

表 3 一定地学规则支持下的 BPNN 分类方法的误差矩阵

Table 3 Error Matrix of Rule Based BPNN Classifier

分类 实际	C ₁	C ₂	C ₃	C ₄	C ₅	C ₆	C ₇	C ₈	C ₉	C ₁₀	总体
C ₁	99	4	0	0	0	0	0	0	0	0	103
C ₂	0	74	2	0	0	0	0	0	0	0	76
C ₃	0	5	91	2	1	3	0	0	0	2	104
C ₄	0	0	0	98	0	0	0	2	0	0	100
C ₅	1	11	6	0	91	12	1	0	0	0	122
C ₆	0	0	1	0	8	82	4	6	0	0	101
C ₇	0	0	0	0	0	1	93	1	0	0	95
C ₈	0	0	0	0	0	0	0	91	0	0	91
C ₉	0	0	0	0	0	0	0	0	100	0	100
C ₁₀	0	6	0	0	0	2	2	0	0	98	108
总体	100	100	100	100	100	100	100	100	100	100	1000

测试精度为 91.70%, Kappa=0.914

5 结论与展望

BP-MLP 是由神经元以层次结构相互连接的多层前向网络结构,一定程度上模拟了人的视觉感知系统。MLP 信息处理是由神经元之间的相互作用来实现的,知识和信息的存储表现为网络结构分布式的物理联系,网络的学习和识别过程决定于各神经元连接权值的动态变化过程。MLP 构成了一个非线性动力学系统,具有不可预测性、不可逆性、多吸引子等特点,与传统统计方法相比,具有并行处理、自适应、非线性动力机制等优势;另外,数据特征空间可自由分布,各模式在特征空间中可分布为多簇,因此当特征空间分布很复杂时,或者源数据各维具有不同的统计分布和尺度时,也能获得理想的分类结果。

通过实例分析,由 BPNN-MLP 神经网络方法获得的分类结果,由于数据对特征空间分布预先不一定需要假设某种参数化密度分布,使其在总体精度上要优于传统的参数化统计分类方法;用 BPNN 方法对于相似程度比较接近的类别的区分程度要比一般的分类方法好,这一点反映了 BPNN 具有复杂的映射能力,如对城镇和道路的区分、海水和陆地水的区分等。地理信息和地学知识可以通过结构化和非结构化的融合方式参与影像分类,在这些辅助信息的支持下,能有效提高 BPNN 分类和识别的精度。

参 考 文 献 (References)

- [1] Wilkinson G G. A review of current issues in the integration of GIS and remote sensing data [J]. *Int. J. Geographical Information Systems*, 1996, **10**(1): 85—101.
- [2] Atkinson P M, Tatnall A R L. Neural networks in remote sensing [J]. *Int. J. Remote Sensing*, 1997, **18**(4): 699—709.
- [3] Hu Shouren, Yu Shaobo, Dai Kui. The Principles of Neural Networks [M]. Changsha: The National Defence Science and Technology University Press, 1993. [胡守仁,余少波,戴葵.神经网络导论[M].长沙:国防科技大学出版社,1993.]
- [4] Shen Qing, Tang Lin. The Principles of Pattern Recognition [M]. Changsha: The National Defence Science and Technology University Press, 1991. [沈清,汤霖.模式识别导论[M].长沙:国防科技大学出版社,1991.]
- [5] Wang Runsheng. Image Understanding [M]. Changsha: The National Defence Science and Technology University Press, 1995. [王润生.图像理解[M].长沙:国防科技大学出版社,1995.]
- [6] Fu, Limin. Neural Networks in Computer Intelligence [M]. McGraw-Hill, Inc. 1994.
- [7] Gallant, Stephen I. Neural Network Learning and Expert Systems [M]. The MIT Press, 1993.
- [8] Atkinson P M, Cutler M E J, Lewis H. Mapping sub-pixel proportional land cover with AVHRR imagery [J]. *INT. J. Remote Sensing*, 1997, **18**(4): 917—935.
- [9] Gong P. Integrated Analysis of Spatial Data from Multiple Sources: Using Evidential Reasoning and Artificial Neural Network Techniques for Geological Mapping [J]. *Photogrammetric Engineering & Remote Sensing*, 1996, **62**(5): 513—523.
- [10] Mural H, OMATU S. Remote sensing image analysis using a neural network and knowledge based processing [J]. *INT. J. Remote Sensing*, 1997, **18**(4): 811—828.
- [11] Benediktsson J A, Swain P H, Ersoy O K. Neural network approaches versus statistical methods in classification of multi-source remote sensing data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1990, **28**(4): 540—552.
- [12] Zhou J, Daniel L. Civco. Using Genetic Learning Neural Networks

- for Spatial Decision Making in GIS, Photogrammetric Engineering & Remote Sensing [J]. 1996, **62**(1): 1287—1295.
- [13] Lippmann R P. An Introduction to computing with neural nets [J]. *IEEE. ASSP Magazine*, 1987, 2: 4—22.
- [14] Bhattacharya U, Panji S K. An improved back propagation neural network for detection of road-like features in satellite imagery [J]. *INT. J. Remote Sensing*, 1997, **18**(16): 3379—3394.
- [15] Kanellopoulos I, Wilkinson G G. Strategies and best practice for neural network image classification [J]. *INT. J. Remote Sensing*, 1997, **18**(4): 711—725.
- [16] Kimes D S, Nelson R F. Attributes of Neural Networks for Extracting Continuous vegetation Variables from Optical and Radar Measurements [J]. *INT. J. Remote Sensing*, 1998, **19**(14): 2639—2663.
- [17] Foschi P G, Deborah K. Smith. Detecting Subpixel Woody Vegetation in Digital Imagery Using Two Artificial Intelligence Approaches [J]. *Photogrammetric Engineering & Remote Sensing*, 1997, **63**(5): 493—500.
- [18] Leung, Yee. Artificial Intelligence, Spatial Analysis and Spatial decision [J]. *Acta Geographica Sinica*, 1997, **52** (Supplement): 104—113. [梁怡. 人工智能、空间分析与空间决策 [J]. 地理学报, 1997, **52** (增刊): 104—113.]

ANN Remote Sensing Classification Model and Its Integration Approach with Geo knowledge

LUO Jian cheng¹, ZHOU Cheng hu¹, YANG Yan²

(1. Institute of Geographic Sciences and Natural Resources Research LREIS, Chinese Academy of Sciences, Beijing 100101, China;

2. Institute of Environmental Science, Beijing Normal University, Beijing 100875, China)

Abstract: The Classification of remotely sensed data is the main theme of Remote Sensing Image Understanding and Analysis, while the artificial neural networks (ANN) is one of the latest and most important techniques developed recently in the area of connective artificial intelligence. In this paper, after we made a through study on the structure of the multi layer perceptron (MLP) and deeply analyzed it's back propagation (BP) training algorithm, the framework of how to integrate Geo knowledge with ANN and apply to RS classification is put forward. Firstly, the suggestions of improving the efficiency of BP algorithm, including network architecture selection, use of optimization on learning rate, and assistance with additional data and expert knowledge etc., are presented. Then, after the general approach of ANN based RS image classification is reviewed, the model of integrating Geo knowledge with ANN for RS image classification is developed with specific experiment of RULE based MLP. Experimental result shows significant improvement in comparison with statistical and traditional ANN classifiers.

Key words: artificial neural networks (ANN); multi layer perceptron (MLP); BP algorithm; RS image classification; geo knowledge