

# 用于高光谱遥感图象分类的 一种高阶神经网络算法

熊 桢 童庆禧 郑兰芬

(中国科学院遥感信息科学开放研究实验室, 北京 100101)

**摘 要** BP神经网络近年来广泛地应用于遥感图象分类,但是它也有多层感知器神经网络的通病,即隐含层及其节点数问题、局部最小问题、训练速度问题等.为了从根本上解决这些问题,该文提出了一种高阶神经网络分类算法,这种高阶神经网络没有隐含层,从而也就没有了隐含层及其节点数的问题;它的模式划分界面是非线性的,从根本上解决了局部最小问题;同时它的训练速度更快,分类精度更高.该文详细介绍了这种高阶神经网络的构造、学习方法、模式分类方法和流程控制,并利用北京市沙河镇地区的高光谱数据进行了分类实验,取得了很好的结果,其训练样本和测试样本的分类精度都达到了100%,证明了这种高阶神经网络算法在结构、速度和精度方面相对其它神经网络算法的巨大优势.

**关键词** 高阶神经网络 分类精度 模式判别

中图分类号: TP751 文献标识码: A 文章编号: 1006-8961(2000)03-0196-06

## High-Rank Artificial Neural Network Algorithm for Classification of Hyperspectral Image Data

XIONG Zhen, TONG Qing-xi, ZHENG Lan-fen

(Laboratory of Remote Sensing Information Science, CAS, Beijing 100101)

**Abstract** The BP neural network is widely used for classification of remote sensing image data nowadays. But it has the usual shortcomings of multilayer sensor neural network too: the question about the number of crytic layer and the number of crytic layer node, the question about local minimum, the question about training speed, and so on. In order to solve the questions thoroughly, a sort of classification algorithm of high-rank neural network is developed in this research. This algorithm has not crytic layer. so it hasn't the question about the number of crytic layer and the number of crytic layer node. It's interface of model classification is nonlneear, so the question about local minimum is solved thoroughly. It's training speed is faster and the precision of model classification is greater than that of the BP neural network algorithm. In this article, the structure, flow chart and course control of this algorithm is introduced detailedly. Using the hyperspectral data in the destrict of Shahe town, Beijing city, an experiment is done and a excellent result is gained. The classification precision of training sample and the classification precision of test sample are all 100 percent. It is proved that the algorithm of high-rank neural network has great advantages than other algorithms of neural network in structure, speed and precision.

**Keywords** High-rank neural network, Classification precision, Pattern recognition

## 0 引 言

遥感图象的分类算法已经很多了.总的说来,目

前还没有一种算法是普适的和最优的,这是由遥感图象数据的复杂性决定的.因此人们针对某一具体的遥感数据,总在不断探索新的分类算法,以求达到更好的效果.遥感图象分类算法一般可以归纳为参

数分类器和非参数分类器两类。

人工神经网络算法属于非参数分类器,这种方法用于遥感图象分类始于 1988 年,此后,神经网络方法用于遥感图象分类得到了普遍的关注<sup>[1~7]</sup>,众多学者在这一领域已经取得了巨大的成功.人工神经网络中用得最为广泛的网络模型是多层感知器模型.1985 年 Rumelhart, McClelland 等人提出了前向多层网络的反向传播(Back Propagation)学习算法(简称 BP 算法).这种算法的基本思想是根据样本的希望输出与实际输出之间的平方误差,利用梯度下降法,从输出层开始,逐层修正权系数<sup>[8,9]</sup>.BP 算法一出现,便受到了广泛的欢迎,也被应用于遥感图象分类<sup>[7]</sup>.该算法采用分段线性判别函数,能较好地解决一般模式分类问题.但它也存在多层感知器神经网络的通病:首先,多层感知器神经网络在训练时很容易陷入局部最小,即使采用模拟退火算法或者遗传算法,仍不能完全摆脱局部最小问题的困扰;其次,中间隐含层数和隐含节点数无法科学地确定;再者,随着隐含层的增加,其反向传递的误差就越大<sup>[8]</sup>,而多层感知器的优势却正是因为它的隐含层数,所以这又是一个很难解决的矛盾.

相对 BP 神经网络,高阶神经网络具有如下特点:第一,高阶神经网络没有隐含层,不存在中间层节点数优化的困扰;第二,高阶神经网络采用非线性模式判别界面,可以最有效地划分各类模式,不存在 BP 神经网络中由于利用分段线性模式判别界面带来的局部最小问题,使得模式分类精度更高;第三,由于高阶神经网络没有隐含层,因此也就没有反向传递误差,使得网络的训练速度更快.

本文首先介绍了高阶神经网络的构造以及高阶神经网络的学习方法,然后用一组数据对高阶神经网络分类算法和 BP 神经网络分类算法进行了对比实验,并对实验结果进行了客观分析和评价,文章的最后给出了本文的结论.

## 1 高阶神经网络的构造

### 1.1 高阶神经网络的形式

高阶神经网络同多层感知器神经网络一样,也有输入层和输出层,不同的是它没有如多层感知器神经网络那样的中间隐含层(如图 1 所示),这样就省去了选择中间隐含层数和隐含层节点数的烦恼,同时由于网络结构的简化,避免了反向传递误差,使

网络的学习效率得到了根本的改善.从理论上讲,高阶神经网络的阶次越高,模式分类精度越高.但是由于高阶神经网络随着网络阶次的升高,网络的权系数呈几何级数增长,比如输入高阶神经网络的特征数为  $n$  个,则二阶神经网络的权系数个数为:  $(n+1)(n+2)/2$ ,而三阶神经网络的权系数个数则为:  $(n^3+17n+6)/6$ .所以,为了使网络结构不致于太复杂,高阶神经网络一般应以采用二阶或三阶为宜.采用太高的阶数不仅使网络结构复杂化,而且从用非线性模式判别界面的角度来看,三阶神经网络的模式判别界面已经足够复杂,已可以很精确地判别一般的模式类别,因此更高阶次的神经网络就显得没有必要了.基于此,本文采用了二阶神经网络作为研究高阶神经网络的对象.




图 1 高阶神经网络结构

### 1.2 高阶神经网络的模式判别界面

高阶神经网络采用的是非线性曲线判别函数,而多层感知器神经网络采用的是分段线性判别函数,从表 1 可以看出,高阶神经网络的非线性判别面明显优于多层感知器神经网络的分段线性判别面.

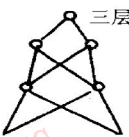
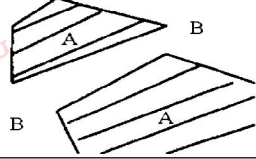
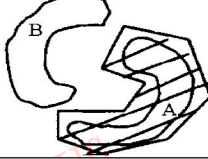
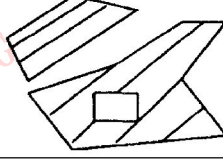

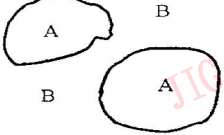

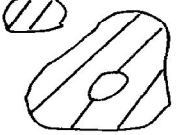
高阶神经网络虽然形式比较简单,但它的模式分类能力是强大的,因为它的模式判别界面是非线性的.从这一点来讲,高阶神经网络从理论上只要满足如下条件就可以无限提高模式的划分精度:第一,选用能够区分各模式类的有效特征;第二,选用有足够代表性的训练样本;第三,根据样本分布情况,能实时有效地调整权阵修正系数;第四,有足够的时间保证.这些条件往往是无法同时满足的,因此高阶神经网络的分类精度不是无限高的,它受到以上四个条件的限制.多层感知器网络尽管形式复杂,它的模式分类能力却赶不上高阶神经网络,因为它的模式判别界面是分段线性的,也正因为如此,多层感知器网络还存在局部最小的问题.

### 1.3 高阶神经网络的学习方法

高阶神经网络的权值学习,通常采用误差反向传递的梯度下降法,其权值修正的一般公式为:

$$w_j(k+1) = w_j(k) + \eta(d_j - o_j)x^* \quad (1)$$

表1 三层前向网络与高阶神经网络对异或问题、一种模式分布所采用的决策域形状和决策域形式的一般形状的对比表

网络结构	异或问题	一种模式分布	决策域形式
 <p>三层</p>			
 <p>高阶</p>			

式中  $d_j$  为样本  $x^*$  的希望输出,  $o_j$  为样本  $x^*$  的实际输出,  $\eta$  为步长. 为了提高学习效率, 本次研究采用了单样本学习法, 其权值修正公式为:

$$w_j(k+1) = w_j(k) + \eta(d_j - o_j)(1 - o_j^2)x^* \quad (2)$$

式中, 计算节点输出  $o_i$  的公式为:

$$o_i = f \left| \sum_{j=1}^n w_{ij}x_j - \theta \right| \quad (3)$$

式中  $\theta$  为阈值,  $f$  为激励函数, 这里选取双极型函数作为激励函数, 双极型函数式为:

$$f(y) = \frac{2}{1 + \exp(-\lambda y)} - 1 \quad (4)$$

如图2所示, 当  $\lambda$  取不同的值时, 双极型函数向两极收敛的速度是不一样的. 取值太大和太小都不合适, 一般  $\lambda$  的值选为  $1^{[10]}$ .




图2 激励函数

为了提高学习速度, 同时还采用单样本扰动学习程序, 即每次训练时单个样本的类别是不一样的, 从各类样本中循环地抽取单个样本进行训练.

#### 1.4 高阶神经网络的学习过程控制

在高阶神经网络的学习过程中, 采取了如下控制手段:

(1) 为了提高训练速度, 单个训练样本的输出与其期望输出之间允许存在一定的误差, 但允许的误差随训练次数的增加逐渐减少, 在允许的误差范

围内, 权值不作修正.

(2) 允许存在一定的训练误差, 总误差阈值的设定必须依具体数据而定, 阈值过大, 影响分类精度; 阈值过小, 影响训练速度.

(3) 设定总误差变动速率和训练次数限值, 如果总误差下降的速率太小, 证明训练已超于收敛, 根据情况可以调整权值修正步长; 如果训练总次数超过阈值, 则结束训练, 以免训练陷入反复振荡之中.

#### 1.5 高阶神经网络的模式分类

高阶神经网络的模式分类采用的判别函数为:

$$d(x) = \sum_{j=1}^n w_{jj}x_j^2 + \sum_{j=1}^{n-1} \sum_{k=j+1}^n w_{jk}x_jx_k + \sum_{j=1}^n w_jx_j + w_{n+1} \quad (5)$$

显然, 高阶神经网络的模式划分界面是一个超曲面, 它是非线性的, 为此本文选择了一个  $x \rightarrow x^*$  的映射, 把非线性判别函数转化为  $x^*$  的线性函数.

$$d(x) = w^t x^* \quad (6)$$

这时,  $w^t x^*$  不是  $x$  的线性函数, 但却是  $x^*$  的线性函数.  $w^t x^* = 0$  在  $x^*$  空间确定了一个通过原点的超平面.

如图3所示, 设有 A, B, C, D 四个模式类, 当某一象元的特征使得 A 类的判别函数有极大值, 则该象元属于 A 类; 同理, 若该象元的特征使得 B 类的判别函数有极大值, 则该象元属于 B 类; 依次类推.




图3 非线性模式划分

## 2 高阶神经网络的运行实验与分析

### 2.1 样本抽取

这次实验选取了中科院上海技术物理所研制的成像光谱仪 MAIS(Model Airborne Imaging System) 于 1997 年 5 月飞行获取的北京市沙河镇可见光和近红外共 15 个波段的数据. 选择的训练样本有 7 个, 它们是水体、煤、树、草、石棉瓦、水泥地、裸土地(如图 4 所示). 这七个样本的光谱特征如图 5 所示.

高阶神经网络随着阶数的增加, 权系数的数量将以几何幂速度增长, 陷入所谓“维数灾难”<sup>[9]</sup>. 因此必须选择对分类最有效的少数几个特征. 这个条件似乎限制了高阶神经网络的分类能力, 但实际上对于一个具体的分类数据, 有效的分类特征只需有限的几个便足以解决问题, 并非特征数越多越好, 在实际分类中常常发现, 特征超过一定限度会导致分类器的性能变坏而不是变好, 在最大似然分类器中表现出的哈夫斯(hughes)现象就说明了这一点\*. 为此, 在本次实验中选择了第 2, 6, 12 三个波段以及 NDVI 作为输入高阶神经网络的四个特征.




图 5 各类样本的光谱曲线

### 2.2 实验结果

高阶神经网络经过学习 245 次、713 次和 5574 次后的累积误差分别为 153.412、62.024 和 12.842. 其训练样本和测试样本的误差矩阵如表 2~ 表 7 所示.

表 2 网络学习 245 次后训练样本的误差矩阵

	A	B	C	D	E	F	G	总体精度
A	49	0	0	0	0	0	0	
B	0	300	0	0	0	0	0	
C	0	0	299	0	0	0	0	
D	0	0	0	0	0	0	0	
E	251	0	0	114	300	0	0	
F	0	0	1	0	0	300	0	
G	0	0	0	186	0	0	300	
样本精度	16.3%	100%	99.7%	0.0%	100%	100%	100%	73.7%

表 3 网络学习 245 次后测试样本的误差矩阵

	A	B	C	D	E	F	G	总体精度
A	145	0	0	0	0	0	0	
B	0	1459	0	0	0	0	0	
C	0	0	1368	0	0	0	0	
D	0	0	0	0	0	0	0	
E	463	0	0	812	368	0	0	
F	0	0	3	0	0	446	0	
G	0	0	0	1164	0	0	427	
样本精度	23.8%	100%	99.8%	0.0%	100%	100%	100%	63.3%



图 4 训练样本选取区域图象(338× 512 象元)

A—水; B—煤; C—树; D—旱地;  
E—石棉瓦; F—草; G—水泥地;

\* Xiuping Jia, Classification techniques for hyperspectral remote sensing image data, dissertation for degree of doctor of philosophy, The University of New South Wales.

表4 网络学习 713 次后训练样本的误差矩阵

	A	B	C	D	E	F	G	总体精度
A	300	0	0	0	0	0	0	
B	0	300	0	0	0	0	0	
C	0	0	300	0	0	0	0	
D	0	0	0	260	0	0	0	
E	0	0	0	35	300	0	0	
F	0	0	0	0	0	300	0	
G	0	0	0	5	0	0	300	
样本精度	100%	100%	100%	86.7%	100%	100%	100%	

表5 网络学习 713 次后测试样本的误差矩阵

	A	B	C	D	E	F	G	总体精度
A	608	0	0	0	0	0	0	
B	0	1459	0	0	0	0	0	
C	0	0	1371	0	0	0	0	
D	0	0	0	1588	0	0	0	
E	0	0	0	329	368	0	0	
F	0	0	0	0	0	446	0	
G	0	0	0	59	0	0	427	
样本精度	100%	100%	100%	80.4%	100%	100%	100%	

表6 网络学习 5574 次后训练样本的误差矩阵

	A	B	C	D	E	F	G	总体精度
A	300	0	0	0	0	0	0	
B	0	300	0	0	0	0	0	
C	0	0	300	0	0	0	0	
D	0	0	0	300	0	0	0	
E	0	0	0	0	300	0	0	
F	0	0	0	0	0	300	0	
G	0	0	0	0	0	0	300	
样本精度	100%	100%	100%	100%	100%	100%	100%	

表7 网络学习 5574 次后测试样本的误差矩阵

	A	B	C	D	E	F	G	总体精度
A	608	0	0	0	0	0	0	
B	0	1459	0	0	0	0	0	
C	0	0	1371	0	0	0	0	
D	0	0	0	1976	0	0	0	
E	0	0	0	0	368	0	0	
F	0	0	0	0	0	446	0	
G	0	0	0	0	0	0	427	
样本精度	100%	100%	100%	100%	100%	100%	100%	

由于三层 BP 网络存在隐含层,因此也带来了隐含层节点数问题.这里采用 7~23 个隐含层节点进行了实验,其分类结果如表 8 所示.

表8 三层 BP 网络分类实验结果

隐含层节点数	训练次数	训练样本精度(%)	测试样本精度(%)
7	4928	95.583	89.151
8	5834	95.083	88.766
9	8869	95.083	90.967
10	3384	95.167	88.285
11	3445	95.167	88.348
12	2738	95.167	88.093
13	2889	95.333	88.493
14	3202	95.500	88.282
15	4655	95.083	88.864
16	3135	95.167	88.137
17	3594	95.000	87.979
18	2586	95.000	86.978
19	3888	95.250	87.595
20	8476	95.917	85.306
21	2929	95.333	88.681
22	6119	95.083	89.746
23	3122	95.083	87.230

### 2.3 结果分析

(1) 从表 2 至表 8 可以看到,高阶神经网络训练 5574 次后,训练样本和测试样本的各类样本分类精度和总湾分类精度均达到了 100%,而三层 BP 网络的最高训练精度为 95.917%,最高测试精度为 90.967%,这证明高阶神经网络的非线性模式判别界面具有极高的精度,同时也证明了高阶神经网络相对多层感知器网络具有明显的精度优势.

(2) 从三个训练样本误差矩阵可以看出,高阶神经网络的学习速度比 BP 神经网络快.三层 BP 网络至少需要 2586 次学习,才能使训练精度达到 95.000%,测试精度达到 86.978%,而高阶神经网络仅经过 713 次学习,训练样本的总体分类精度就达到了 98.1%,测试样本的分类精度也达到 94.20%.高阶神经网络经过 245 次学习,7 个样本中就已经有 4 个样本的分类精度达到了 100%,还有一个训练样本的分类精度达到 99.7%,训练样本的总体分类精度达到了 73.7%.高阶神经网络经过 713 次学习,7 个样本中就已经有 6 个样本的分类精度达到了 100%,另外一个训练样本的分类精度也达到 86.7%,训练样本的总体分类精度则达到 98.1%.而高阶神经网络经过 5574 次学习,各类样本的分类精度均达到了 100%.

(3) 这次试验选用的图象数据均采集于北京市北郊清河镇,这一地区属于城乡结合部,土地覆盖类别十分复杂.在这种地区选用的训练数据不同于遥感实验场的数据,由于这种地区的数据更加复杂,因

此它对网络的分类能力更具挑战性. 从上面的误差矩阵可以看出, 高阶神经网络对这种复杂数据的分类精度非常高, 这证明高阶神经网络对复杂数据具有很好的适应能力.

(4) 从网络的训练过程可以看出, 高阶神经网络不会陷入局部最小, 能够很快收敛于全局最小. 只要网络的结构设计合理, 选用的特征合适, 在有限的训练次数内就可以完全划分各模式类样本.

(5) 从误差矩阵可以看到, 高阶神经网络经过 245 次学习, 训练样本的总体分类精度为 73.7%, 测试样本的总体分类精度为 63.3%. 该网络经过 713 次学习, 训练样本的总体分类精度为 98.1%, 测试样本的总体分类精度为 94.2%. 两次实验均显示测试样本的总体分类精度比训练样本的分类精度下降了. 而第三次经过 5574 次学习, 测试样本和训练样本的分类精度都达到了 100%, 这说明这次选用的训练样本的代表性不容怀疑. 只要增加训练次数, 测试样本可以达到与训练样本一样的分类精度. 同时也说明, 训练样本选择的重要性. 如果训练样本选择不合适, 测试样本的分类精度必然要比训练样本的分类精度低.

### 3 结 论

(1) 高阶神经网络结构简单, 没有隐含层, 训练速度快, 分类精度高.

(2) 高阶神经网络可以有效地避免局部最小问题, 能够很快收敛于全局最小.

(3) 高阶神经网络对复杂训练数据具有很好的适应能力.

(4) 只要网络结构设置合理, 训练样本选择恰当, 输入特征有效, 高阶神经网络具有很高的分类精度.

(5) 虽然输入高阶神经网络的特征数不可能太多, 但是只要特征选择适当, 也能克服这一弱点, 获得很好的结果.

### 参 考 文 献

- 1 Andrea Baraldi and Flavio Parmiggiani. A neural network for unsupervised categorization of multivalued input patterns: An application to satellite image clustering. IEEE. Transactions on Geoscience and Remote Sensing. 1995, 33(2).
- 2 Changyi Sun, Christopher M U Neale, Jeffrey J. McDonnell, Heng-Da Cheng. Monitoring land-surface snow conditions from SSM/I data using an artificial neural network classifier. IEEE.

Transactions on Geoscience and Remote Sensing, 1997, 35(4).

- 3 H Bischof, W Schneider, A J Pinz. Multispectral classification of Landsat-image using neural networks. IEEE. Transactions on Geoscience and Remote Sensing, 1992, 30: 482~ 489.
- 4 Jon A Benediktsson, Philip H Swain, Okan K Ersoy. Neural network approaches versus statistical methods in classification of multisource remote sensing data. IEEE. Transactions on Geoscience and Remote Sensing, 1990, 28(4).
- 5 Justin D Paola, Robert A Schowengerdt. A detailed comparison of backpropagation neural network and maximum-likelihood classifiers for urban land use classification. IEEE. Transactions on Geoscience and Remote Sensing, 1995, 33(4).
- 6 L Bruzzone, C Conese, F Maselli and F Roli. Multisource classification of complex rural areas by statistical and neural-network approaches. Photogrammetric & Remote Sensing, 1997, 63(5): 523~ 533.
- 7 Tomoji Yoshida and Sigeru Omatu. Neural network approach to land cover mapping. IEEE. Transactions on Geoscience and Remote Sensing, 1994, 32(5).
- 8 章孝灿, 黄智才, 赵元洪. 遥感数字图象处理. 杭州: 浙江大学出版社, 1997, 185~ 248.
- 9 黄凤岗, 宋克欧. 模式识别. 哈尔滨: 哈尔滨工程大学出版社, 1998, 30~ 80.
- 10 赵振宇, 徐用懋. 模糊理论和神经网络的基础与应用. 北京: 清华大学出版社, 广西科学技术出版社, 1996, 80~ 114.



熊 桢 1966 年生, 讲师. 1986 年毕业于武汉测绘科技大学航测系, 1993 年获工测系硕士学位. 现在中科院遥感所遥感信息科学开放研究实验室攻读博士学位, 主要从事遥感图象处理、模式识别和遥感图象分类技术的研究.



童庆禧 1935 年生, 研究员, 中国科学院院士. 1961 年毕业于苏联敖德萨水文气象学院农业气象系. 现任国家遥感中心专家委员会主任、中国遥感协会秘书长等职. 主要从事高光谱遥感及其应用的研究, 已发表学术论文 70 余篇, 出版专著 3 部.



郑兰芬 1941 年生, 研究员, 博士生导师. 1964 年毕业于南京大学地理系. 现任中国科学院遥感信息科学开放研究实验室副主任. 主要从事高光谱遥感及其应用研究, 主持多项国家攻关、自然科学基金、863 国际合作等重大项目的研究, 多次获得国家级和省部级科技成果奖.