

用 Kohonen 神经网络对高光谱分辨率 图像进行无监督分类的研究

郭一平

(中国科学院上海技术物理研究所, 上海, 200083)

B.C. Forster

(Centre for Remote Sensing & GIS, and school of surveying,
The University of New South Wales, Australia)

摘要 讨论了将 Kohonen 自组织神经网络用于成像光谱仪高光谱分辨率遥感图像无监督分类的结果。用于研究的是 $0.46\sim 0.76\ \mu\text{m}$ 15 个波段的高光谱分辨率的原始航空遥感图像。该图像复盖了澳大利亚达尔文市周围约 $200\ \text{km}^2$ 的试验区, 包括了海湾、岛屿、海滩、河流、城市与旷野等各种地物类型。神经网络分类的结果提供了试验区内地物分布符合实际的预测和估计, 它与传统的分类方法的结果相比较, 用神经网络所得到的结果更准确可信。

关键词 神经网络, 图像无监督分类, 高光谱分辨率遥感图像。

引言

自从第一台成像光谱仪问世以来, 遥感仪器所提供的信息量迅速增长。例如, 航空可见光/红外成像光谱仪 AVIRIS 具有 224 个波段, 而传统的多光谱扫描仪仅具有数个波段。但数据的最终使用者往往只对数据的某些具体的特征感兴趣, 而这些特征的“维数”远小于数据本身的“维数”。因此, 有效地从大量数据中抽取有限的特征是遥感应用中重要的课题。无监督分类采用簇分析抽取特征, 在对研究对象没有任何先验知识的情况下, 它可以提供对于待研究图像总体的、概况的描述。凡是与模式聚合与模式分类有关的问题, 均可以利用神经网络来进行研究。使用神经网络作研究的重要原因是它的结构提供了超越其它传统的方法诸如统计和最优化方法的独特性能。Kohonen 自组织神经网络能自动建立输入模式之间的联系, 根据模式之间的相似关系将其映射到输出端相应部分。一旦对神经网络完成了充分的训练, 模式之间的相互联系以及分类结果都可以在其输出端得到。因此它为自适应地建立拓扑图和复杂模式的识别提供了有效的方法。

1 成像光谱仪及图像数据

第一台成像光谱仪—航空成像光谱仪 (AIS) 由 JPL 实验室于 1982 年完成^[1]. AIS 在 $1.2\sim 2.4\ \mu\text{m}$ 范围内有 128 个光谱波段, 总视场为 3.7° . 1987 年, JPL 实验室完成了 AIS 的改进型, 称之为航空可见光/红外成像光谱仪 (AVIRIS)^[2]. 新的成像光谱仪能够以 10 nm 的采样间隔在 $0.4\sim 2.5\ \mu\text{m}$ 的光谱范围内获取连续的 224 个光谱波段的图像, 得到地物目标完整的反射光谱. AVIRIS 的总视场为 30° , 每个像元为 $20\times 20\ \text{m}^2$. 由于许多地物目标在反射光谱内具有 $20\sim 40\ \text{nm}$ 带宽的特征吸收谷, AVIRIS 采集完整的反射光谱的能力为分析研究地物目标提供了宝贵的手段. AVIRIS 的光谱分辨率已足以满足对上述特征吸收谷的分析要求, 进而可直接区分地物目标. 相比之下 LANDSAT 的扫描仪的通道带宽为 $100\sim 200\ \text{nm}$, 所以对区分和分析这些特征无能为力.

中国科学院上海技术物理研究所于 1990 年研制成组件式成像光谱仪 (MAIS)^[3]. 该仪器有 A, B, C 3 个分光计和 $0.44\sim 11.8\ \mu\text{m}$ 范围内的 71 个波段. 其中分光计 A 的 32 个相邻的光谱波段覆盖了 $0.44\sim 1.08\ \mu\text{m}$, 光谱采样间隔为 20 nm, 瞬时视场 (IFOV) 为 3 m rad. 分光计 B 设置 32 个连续的波段, 工作于 $1.5\sim 2.5\ \mu\text{m}$, 它的光谱采样间隔为 30 nm, 瞬时视场为 4.5 m rad. 分光计 C 的 7 个波段位于 $7.8\sim 11.8\ \mu\text{m}$, 光谱采样间隔为 $0.4/0.8\ \mu\text{m}$, 瞬时视场为 3 m rad. 成像光谱仪的总视场为 90° .

试验区位于澳大利亚北部城市达尔文市及其周围地区, 位于东经 $130^\circ 48'\sim 130^\circ 58'$, 南纬 $12^\circ 26.5'\sim 12^\circ 30'$. 试验区内有城市、旷野、海湾、岛屿、海滩和河流等地物目标. 高光谱分辨率图像由 MAIS 于 1991 年 9 月 24 日当地时间上午 11:45 开始获取, 飞行高度为 4000 m. 两幅图像 (见图 1 和图 2) 均为 15 个波段 512×1024 像元的原始图



图 1 原始图像 A (镜向图像)
Fig. 1 Original image A



图 2 原始图像 B (镜向图像)

Fig. 2 Original image B

像. 像元的地面尺寸为 $12 \times 12 \text{ m}^2$, 故每幅图像均为 $8 \times 16 \text{ km}^2$. 成像光谱仪 MAIS 光谱波段的参数见表 1.

表 1 成像光谱仪 MAIS 光谱波段的参数
Table 1 The spectral bands of MAIS used in this work

波段号	波长 (μm)	波段号	波长 (μm)
2	0.46~0.48	10	0.62~0.64
3	0.48~0.50	11	0.64~0.66
4	0.50~0.52	12	0.66~0.68
5	0.52~0.54	13	0.68~0.70
6	0.54~0.56	14	0.70~0.72
7	0.56~0.58	15	0.72~0.74
8	0.58~0.60	16	0.74~0.76
9	0.60~0.62		

2 Kohonen 自组织神经网络

Kohonen 自组织神经网络是具有双层结构的神经网络, 它可以从随机的初始状态自动形成拓扑图^[4,5]. 拓扑图反映神经网络所接受的模式之间规律性的联系. 该神经网络 (见图 3) 由一层输入层和一层具有处理单元的竞争层组成, 并由无监督学习方法予以训练. 经过训练, 它能够“学会”找出输入模式之间的关系与规律. 神经网络的并行结构和 Kohonen 神经网络所特有的模式之间联系的图形表达优于传统的模式识别技术.

Kohonen 自组织神经网络的第 1 层是输入层, 第 2 层竞争层通常为二维的点阵结构. 所有的内部连接方向均从第 1 层到第 2 层, 两层之间为充分连接. 设输入给神经网络的模

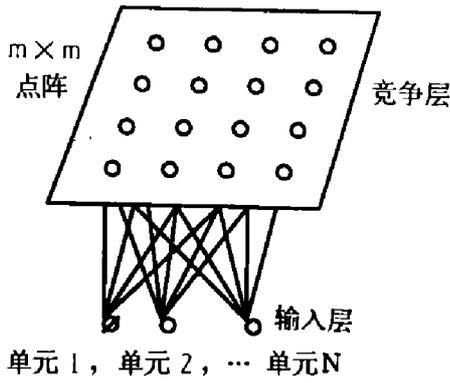


图 3 Kohonen 自组织神经网络的基本结构

Fig. 3 The basic structure of the Kohonen network

式为

$$P = [p_1, p_2, p_3, \dots, p_n], \quad (1)$$

输入层至竞争层第 i 单元的权重为

$$W_i = [w_{i1}, w_{i2}, w_{i3}, \dots, w_{in}], \quad (2)$$

Kohonen 神经网络工作的第一步是为竞争层上的每个单元计算匹配值 $|P - W_i|$ ，它实际上是矢量 P 和 W_i 之间的距离：

$$|P - W_i| = \sqrt{\sum_j (p_j - w_{ij})^2}, \quad (3)$$

具有最小匹配值的单元将在竞争中获胜。若单元 c 获

胜，则 c 满足条件

$$|P - W_c| = \min\{|P - W_i|\}, \quad (4)$$

式 (4) 对第 2 层上的所有单元 i 求最小值。若两个单元同时具有相同的匹配值，按惯例以序号 i 较小的单元获胜。

第二步是确定获胜单元的邻域。它由在竞争点阵中最靠近获胜单元的单元组成。邻域记为单元的集合 N_c 。集合 N_c 中的各单元的权重都予以更新。权重的更新遵照下式：

$$\left. \begin{aligned} \Delta w_{ij} &= \alpha (p_j - w_{ij}), && \text{(集合 } N_c \text{ 内的各单元)} \\ \Delta w_{ij} &= 0, && \text{(集合 } N_c \text{ 外的各单元)} \end{aligned} \right\} \quad (5)$$

和

$$w_{ij}^{\text{new}} = w_{ij}^{\text{old}} + \Delta w_{ij}. \quad (6)$$

式 (5) 中的 α 是学习率。其初始值是个相对较大的数，随着循环次数的增加而逐步衰减。通常定义为

$$\alpha_t = \alpha_0 (1 - t/T), \quad (7)$$

式 (7) 中 t 为当前训练的次数， T 是要求的总训练次数。 α_0 是 α 的初始值。邻域 N_c 的大小也随训练的次数改变，设 d 为获胜单元至邻域边界的距离，则 d 的变化为

$$d_t = d_0 (1 - t/T), \quad (8)$$

式 (8) 中 d_0 是 d 的初始值，在试验中取竞争层尺度的一半。

3 数据处理与结果

数据处理的所有软件均由 C 语言编写，包括 Kohonen 神经网络训练与测试的软件、

从图像文件中抽取数据形成训练数据集的软件、Kohonen 神经网络高速处理图像单字节文件的软件和将分类图转换成 RGB 图像作彩色硬拷贝的软件。

通常无监督分类训练数据的选取应尽量确保包括图像中所有的地物类别。由于训练神经网络的特殊性,即需要大量的循环使其收敛,故训练数据集的选取必须适中。在研究中,作者对每种类别的地物选取 8~10 个模式,每幅图像约为 100~200 个模式。研究中采用的 Kohonen 神经网络具有 15 个输入节点,分别对应 MAIS 的 15 个光谱波段。它的输出层有 16 个输出单元,组成 4×4 的点阵,将图像分成 16 种类别。

分类后的图像参见图 4 与图 5。分类的结果与 1:100,000 地图 (series R772, edition

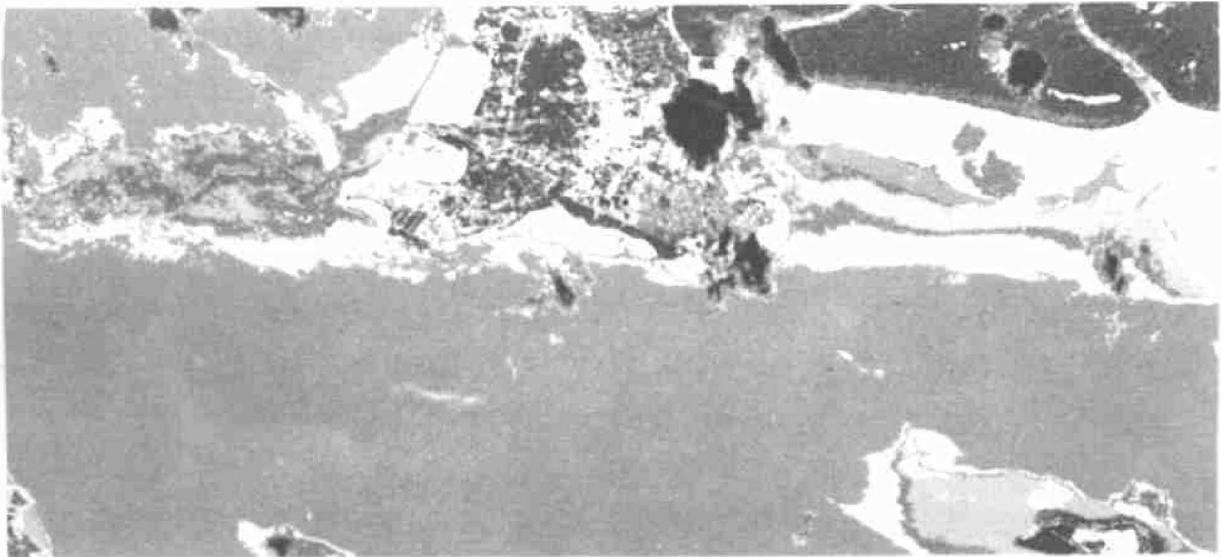


图 4 Kohonen 神经网络分类的图像 A
Fig. 4 Classified image A by the Kohonen network



图 5 Kohonen 神经网络分类的图像 B
Fig. 5 Classified image B by the Kohonen network

1-AAS), 1:50,000 地图以及与 MAIS 准同步获取的 1:60,000 和 1:30,000 航空摄影照片进行了比较和评价. 表 2 与表 3 是分类图与参考数据比较的结果.

表 2 图像 A 分类的结果
Table 2 The classification results of image A

地物类别	色彩	地物类别	色彩
红树属植物	蓝色	水体 (中)	淡蓝色或天蓝色
云	黑色	水体 (深)	紫色
云的阴影	淡蓝色	人工建筑与道路	白色或黑色
沙滩	白色	草地与树冠	深灰色
水体 (浅)	淡红色或淡灰色		

表 3 图像 B 分类的结果
Table 3 The classification results of image B

地物类别	色彩	地物类别	色彩
云	褐色	中等密度的树林	红色
水面上及浅水中的沙滩	深灰色	低等密度的树林	品红或绿色
较深水下的沙丘	蓝色	红柳属植物	白色和淡灰色
河流	深蓝色或天蓝色	沼泽与红柳属植物	淡红色
海	紫色	过渡区域	黄色
人工建筑与道路	黑色		

分类结果表明:

(1) 分类图对沙类物质有很好的区分能力. 无论它们是在陆地上或是在水中, 均能可靠地予以区分. 图 4 中沙类物质覆盖的区域主要为白色, 例如 Mindil 海滩、Emery 角和 Ellet 角的沙滩, 特别是 Emery 角所面对的位于水下的沙丘. 若水深较深, 位于水下的沙类物质也有呈淡红色的. 在图 5 中, 沙类物质呈淡灰或蓝色. 前者代表位于陆地上的区域或位于浅水中的区域; 后者代表位于较深水下的区域. 值得指出的是大多数建筑物和道路都被划分到这一类之中, 这可能是因为它们都是混凝土或砖石结构, 本身包含沙类物质, 又具有沙类物质类似的光谱所致.

(2) 由于云具有很高的反射率, 故易于区分. 云在图 4 中为黑色, 而在图 5 中为褐色. 分类的结果表明神经网络对云的阴影不敏感, 即具备一定的抗干扰能力. 图 5 中无明显的阴影影响存在. 但若阴影十分严重, 像图 4 所示的那样, 它还是会对分类的结果产生影响.

(3) 水体在图 4 中占了 5 个类别, 呈淡灰、淡红、蓝、天蓝和紫色, 分别代表从浅至深不同深度的水体. 在图 5 中, 水体占了 4 个类别, 分别是天蓝、蓝、深蓝和紫色.

(4) 凡是生长红柳属植物的区域, 均能够清楚地与其它区域尤其是其它植物所覆盖的区域相区别. 生长红柳属植物的区域在图 4 中为深蓝色, 在图 5 中为白色或淡灰色. 这些区域与地图和航空照片比较时, 吻合极好.

(5) 红柳属之外的植物, 在图 4 中为深灰色, 而在图 5 中分成了 3 个类别, 呈红色、

品红和绿色. 在图 4 中, 草地和树冠均位于同一类别内, 而市区则表现为由沙类物质代表的建筑物点缀在植物类型的背景上.

(6) 作为比较, 用传统的最小距离法 (NNR) 所作的分类结果见图 6 与图 7. 比较的结果表明, 神经网络类的结果明显地优于 NNR 的结果.

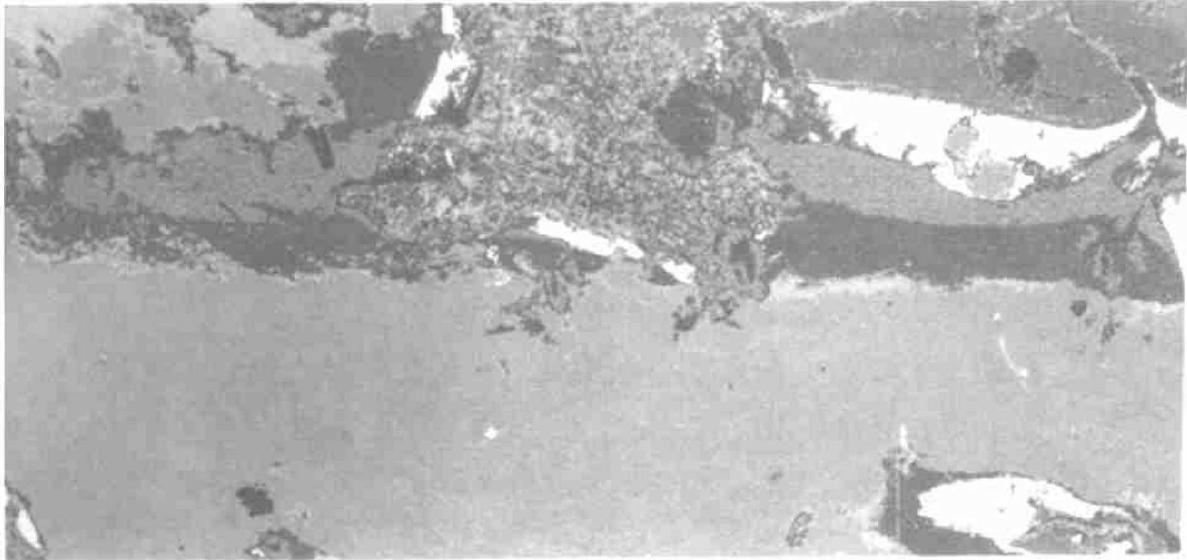


图 6 最小距离法 NNR 分类的图像 A
Fig. 6 Classified image A by the NNR

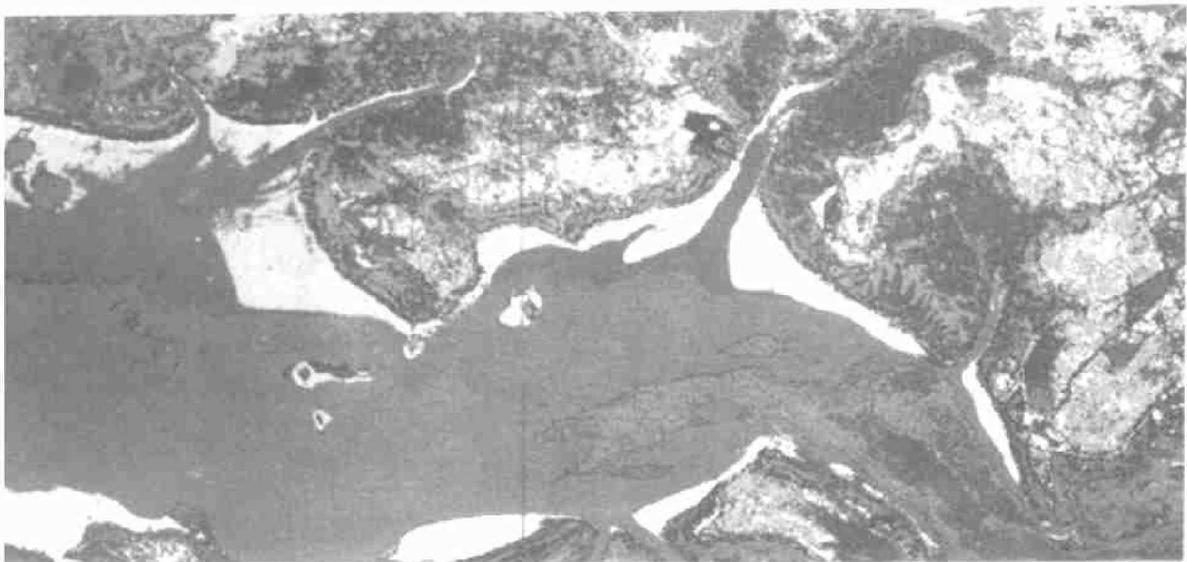


图 7 最小距离法 NNR 分类的图像 B
Fig. 7 Classified image B by the NNR

(7) 由于 Kohonen 神经网络的特点, 它的输出单元通常为正方形的点阵, 故输出的类别往往多于图像中实际的物质种类. 分类图中在主要的类别之间存在小的、离散的过渡区域.

为全面研究 Kohonen 神经网络分类的特性, 专门考察了神经网络受到破坏后的性能. 首先是破坏训练后的神经网络的权重矢量, 给每个权重都加上个小的随机量. 该随机数为均匀分布的, 幅度为 0.002~0.3 的随机变量. 权重改变后, 神经网络分类的正确率下降, 这是因为 Kohonen 神经网络分类的基础就是将输入的模式与权重相比较和匹配. 图 8 是训练后的 Kohonen 神经网络分类特性随权重被破坏的函数关系. 随着破坏程度增加, 神经网络的分类特性下降加剧. 当破坏的幅度小于 0.2 时, 该函数关系可近似被看作为分段的对数关系, 在 0~0.01、0.01~0.1 和 0.1~0.2 三段中分别有各自的基数. 由此可见, 训练时的权重应保证具有优于 0.0001 的精度. 其次是破坏了 Kohonen 神经网络输入层中的输入节点. 图 9 所示的是训练后的神经网络分类特性随输入节点被破坏的函数关系. 试验时, 将等间隔的输入节点破坏, 即等间隔地将光谱波段输入短路. 图 9 表明破坏输入节点对神经网络分类特性所造成的影响比破坏权重的影响要小. 即使破坏将近一半的输入节点, 分类的正确率仍接近 90%, 等效于对权重破坏程度仅为 0.01. 分析表明, 这是由于成像光谱仪相邻的波段之间具有相当高的相关性, 而且其波段数越多, 相应的相关性也越高. 神经网络的这一特性在实际应用中十分宝贵. 它意味着即使在数据采集过程中由于某些原因造成个别通道工作不正常时, 只要将该通道知路, 对分类结果的影响将是微不足道的.

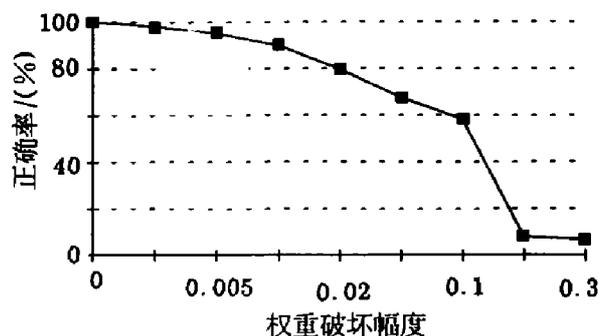


图 8 训练后的 Kohonen 神经网络分类特性随权重被破坏的函数关系

Fig. 8 Performance of the trained Kohonen network as a function of the amount of damage done to the weights

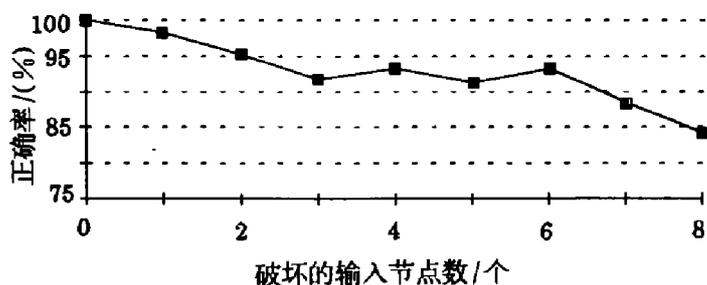


图 9 训练后的 Kohonen 神经网络分类特性随输入节点被破坏的函数关系

Fig. 9 Performance of the trained Kohonen network as a function of the amount of damage done to the input node

4 结语

Kohonen 神经网络为 MAIS 的高光谱分辨率图像无监督分类提供了一种方法. 试验表明, 利用 0.46~0.76 μm 15 个光谱波段的原始图像数据, 在对试验区域无任何先验知识的情况下, Kohonen 神经网络是对复杂模式进行识别的有效方法. 由于缺乏现场的实测数据, 还无法对分类的结果作充分和精确的评价; 但仅就目视判别而言, Kohonen 自组织神经网络分类的效果已明显优于传统的 NNR 方法.

参考文献

- 1 Goetz *et al.* *Science*, 1985,(228):1147~1153
- 2 Macenka S A, Chrisp. *JPL Publish*, 1987,87(38):89~97
- 3 Xue Y Q *et al.* *Proceedings of the 11th Asian Conference on Remote Sensing*, Guangzhou, China, 1990, P-32
- 4 Judish E Dayhoff. *Neural Network Architectures: An Intruduction*, New York: Van Nostrand Reinhold, 1990, 163~191
- 5 Matthew Zeidenberg. *Neural Network Models in Artificial Intelligence*, England: Ellis Horwood, 1990, 82~86

UNSUPERVISED CLASSIFICATION OF HIGH SPECTRAL RESOLUTION IMAGES USING THE KOHONEN SELF-ORGANIZATION NEURAL NETWORK

Guo Yiping

(*Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Shanghai 200083, China*)

B.C. Forster

(*Centre for Remote Sensing and GIS, and School of Surveying,
The University of New South Wales, Australia*)

Abstract This study applies the Kohonen self-organization neural network to the task of unsupervised classification. The data source is the raw data in 15 bands of high spectral resolution images ranging between 0.46 and 0.76 μm . This dataset covers a 200 square-km region centred near the city of Darwin, in northern Australia. The study area consists of bays, islands, beaches, rivers, as well as urban and rural areas.

Key words neural network, unsupervised classification of image, high spectral resolution remotely sensed images.