

基于 MRF 模型和人工神经网络的遥感图像分类综合方法研究*

李 强 王正志

(国防科技大学自动控制系 长沙 410073)

摘 要 本文总结了提高计算机遥感信息分类精度的四个有效途径, 据此提出了基于三维 Hopfield 人工神经网络模型的遥感信息分类及平滑处理综合技术。实验表明, 该方法可明显提高森林类型划分、土地利用调查等遥感应用专题的分类精度。

关键词 遥感信息分类, 分类后处理, 人工神经网络

分类号 TP391. 4

Research on NN-Based Remote Sensing Image Classification and Smoothing Integrated Technique

Li Qiang Wang Zhengzhi

(Depart. of Automatic control, NUDT, Changsha, 410073)

Abstract Summing up four ways to enhance the remote sensing computer classification precision, we put forward a remote sensing classification and smoothing integrated technique based on 3-D Hopfield network theory. The experiment results show that this method can improve the precision of classification saliently.

Key words Remote Sensing, Classification, Post-classification, Neural network

遥感信息分类本质上是一个模式识别过程, 因而目前计算机遥感信息分类主要采用传统的模式识别方法——统计决策方法和句法分析方法。但是, 由于从遥感图像上难以抽取结构基元, 并对它们进行描述, 目前结构模式识别方法在遥感信息分类中的应用尚不普遍。统计决策方法的实用条件是遥感数据准确地记录了各种地物的光谱特征。由于遥感数据还要受到地形、光照条件等多方面因素的影响, 这一点很难满足, 所以仅用遥感数据通过统计决策方法进行地物的识别准确率不高。

为了提高遥感信息分类精度, 前人作了大量研究, 主要从四个方面着手解决这一问题: ① 预处理, 即在进行分类之前根据传感器、电磁学和地形等方面的知识尽可能地剔除大气散射、地形和太阳光照等因素的影响, 通过降低源数据噪声提高分类精度; ② 多源多谱多形式信息的融合处理, 也就是对同一区域通过不同数据源得到的信息进行综合处理, 提取出波谱、空间和时间信息, 用空间、时间以及人的经验知识辅助分类以提高精度; ③ 新一代遥感信息分类方法的应用, 主要是将近年来发展起来的模糊理论、人工智能理论(主要是专家系统)、人工神经网络技术等应用于遥感信息分类, 从算法上改进分类精度; ④ 分类后处理, 通过对分类结果再进行处理提高分类精度, 主要是指分类结果的平滑处理。

本文将后两种技术与遥感信息分类结合起来, 提出了基于三维 Hopfield 网络的遥感分类综合方法。

1 传统分类结果平滑方法的不足及分类平滑综合思想的提出

在主要利用光谱信息进行遥感信息分类时, 由于环境因素的影响, 有可能使遥感图象的局部点数据出现偏差, 反映到分类结果上便会产生孤立点形式的分类噪声。通常总是利用地物类别的空间关系, 即相邻地物的类别来平滑处理这类噪声^[1]。

* 1998年9月9日收稿
国家卫星应用重点项目资助
第一作者: 李强, 男, 博士生, 1972年生

目前常用的分类结果平滑方法主要有基于最小面积原则的分类平滑方法^[2]，即由用户交互地给出最小分类区域的大小，然后将分类结果图像中面积小于指定值的同类地物区域的类别重新指定为其邻域的多数类别。这种方法的一个主要缺点是：平滑过程只使用了分类结果数据，不再使用原始遥感数据，因而效果不十分理想。我们在 Grossberg 的基于生理视觉的景象特征提取技术^[3]和 Lin 的基于约束满足神经网络的图象分割方法^[4]研究的启发下，将分类结果平滑处理模型化为一个约束优化问题，使其与遥感图像分类过程有机地结合起来，提出了基于三维 Hopfield 网络的遥感信息分类与分类结果平滑处理综合技术。该方法在平滑过程中考虑了原始遥感数据的影响，使分类精度有比较明显的提高。

2 遥感图像的分类及平滑处理过程分析

首先给出后续部分讨论中要用到的一些符号的含义。令 $\Omega = \{ (i, j), 0 \leq i < M, 0 \leq j < N \}$ 表示一给定的多波段遥感图像 T_Ω 中的像素点坐标集， $g_s, s \in \Omega$ 代表对应于遥感图像中位置 s 处的模式特征，则图像 T_Ω 可由一个 D 维特性向量集 $G \subseteq \{g_s, R^D, \forall s \in \Omega\}$ 表征。考虑遥感图像的模式特征的统计表示形式，可以把每个像元点的模式特征 g_s 看成是 M 维随机过程 G_s 的一个实现，其先验概率记为 $P(G_s)$ 。在遥感图像分类过程中，一般最后结果的类别数都是预先给出的，故图像的每个像素点可被标记为一个类别号。不失一般性，设所有类别的集合为 $L = \{0, 1, \dots, k-1\}$ 。把对应个位置 s 的像元的类别归属看作一个随机事件，用 L_s 表示，其先验概率由 $P(L_s)$ 描述。下面从统计学角度对遥感图像分类及平滑过程进行分析。

2.1 初始分类过程

本文采用了传统的统计模式识别方法进行初始分类。假设各类的特征向量服从 Gaussian 分布，在已知像元类别的情况下像元特征向量的条件概率服从 Markov 随机场 (MRF) 模型，则位置为 s 的像元属于第 k 类时其特征向量 G_s 的条件概率，即类别先验概率为：

$$p(G_s = g_s, L_s = k) = e^{-E_1(G_s = g_s, L_s = k)} / Z_1 \tag{1}$$

其中：能量函数 $E_1(G_s = g_s, L_s = k) = \sum_{s \in \Omega_k} \|g_s - \theta_k\|^2 / (2\alpha^2)$ (2)

归一化因子 $Z_1(L_s = k) = \sum_{G_s} e^{-E_1(G_s = g_s, L_s = k)} / (2\pi)^D \sigma_k^2$ (3)

S_k 是集合 Ω_k 中所含元素个数， θ_k 和 σ_k^2 是第 k 类模式特征的均值向量和方差。在监督分类情况下可通过直接对样本区进行统计获得，而在非监督分类情况下则需要在初始分类之后统计获得：

$$\theta_k = \frac{1}{S_{k, \Omega_k}} \sum_{s \in \Omega_k} g_s; \quad \sigma_k^2 = \frac{1}{S_{k, \Omega_k}} \sum_{s \in \Omega_k} \|g_s - \theta_k\|^2 \tag{4}$$

2.2 基于邻域类别的调整分类过程

首先给出邻域的图示定义。图 1 给出了一个像元 S 的典型九阶非因果对称邻域系统。令 N_s^L 是一个像元的 p 阶邻域偏移矢量，例如一个像元的二阶邻域偏移矢量为 $N_s^2 = \{(-1, -1), (-1, 0), (-1, 1), (0, -1), (0, 1), (1, -1), (1, 0), (1, 1)\}$ 。从而在图 1 所示的非因果对称邻域系统中， N_s^L 具有下列性质。

$$(1) r \in N_s^L \Rightarrow -r \in N_s^L; \quad (2) N_s^{L-1} \subset N_s^L$$

设像元 $s \in \Omega$ 的 p 阶邻域坐标为 $s + r, r \in N_s^L$ ，设邻域类别调整过程服从 Markov 随机场模型，则在已知邻域 $s + r$ 的类别的情况下重新分配像元 s 的类别为 k 的概率为

$$p(L_s = k | L_{s+r}, \forall r \in N_s^L) = e^{-E_2(L_s = k | L_{s+r}, \forall r \in N_s^L)} / Z_2 \tag{5}$$

其中能量函数 E_2 定义如下：

$$E_2(L_s = k | L_{s+r}, \forall r \in N_s^L) = - \sum_{r \in N_s^L} \beta(r) \delta(L_s - L_{s+r}) \tag{6}$$

| | | | | | | |
|---|---|---|---|---|---|---|
| 9 | 8 | 7 | 6 | 5 | 4 | 3 |
| 8 | 5 | 4 | 3 | 2 | 1 | 0 |
| 7 | 4 | 2 | 1 | 0 | 1 | 2 |
| 6 | 3 | 1 | S | 1 | 3 | 6 |
| 5 | 2 | 1 | 0 | 1 | 2 | 5 |
| 4 | 1 | 0 | 1 | 2 | 3 | 4 |
| 3 | 0 | 1 | 2 | 3 | 4 | 3 |
| 2 | 1 | 2 | 3 | 4 | 5 | 2 |
| 1 | 0 | 1 | 2 | 3 | 4 | 1 |
| 0 | 1 | 2 | 3 | 4 | 5 | 0 |

图 1 象元 S 的邻域系统，框中数字表示邻域的阶数
Fig. 1 The neighborhood of pixel S , the number in pane is the order of the neighborhood

归一化因子为:

$$Z_2 = \sum_{\forall L_s} e^{-E_2(L_s, L_{s+r}, r, N_L^l)} \quad (7)$$

$\beta(r) > 0$ 是衡量邻域类别对当前像元类别影响的重要程度的因子, $\beta(r)$ 越大则该邻域像元的类别对当前像元的类别影响越大。因此, 邻域阶数越小, β 值应越大, 而对于同阶邻域, β 值应相等。

2.3 类别调整的竞争过程

基于邻域类别的调整过程结束之后, 各像元以不同的概率被分到各个类别, 而在确定 (即非模糊) 分类中, 每个像元只能属于一个类, 因此存在同一像元处不同类别的竞争。

假定当前时刻像元 s 属于第 n 类, 为其分配一个新类别号 k 的概率为

$$p(L_s = k | L_s = n) = e^{-\alpha \bar{\delta}(k-n)} / Z_n \quad (8)$$

其中 Z_n 是归一化因子, $\bar{\delta}$ 为 Kronecker 的 δ 函数的对偶函数:

$$\bar{\delta}(l) = \begin{cases} 0, & l = 0 \\ 1, & \text{其他} \end{cases} \quad (9)$$

$\alpha > 0$ 是衡量改变类别可能性大小的因子, α 越大则改变为不同类别的可能性越小。

2.4 后验概率的公式表达

令 $p(L_s = k | G_s, L_{s+r}, \forall r, N_L^l, L_s = n)$ 表示在已知像元 s 对应的特征向量、其邻域的类别以及当前时刻其本身所属类别的条件下, 下一时刻将其分为第 k 类的后验概率, 则有^[5]

$$p(L_s = k | G_s, L_{s+r}, \forall r, N_L^l, L_s = n) = \frac{p(G_s | L_s = k) p(L_s = k | L_{s+r}, \forall r, N_L^l) p(L_s = k | L_s = n)}{p(G_s) p(L_s = k)} \quad (10)$$

因为任意像元的特征向量是 R^D 空间一个已知的固定点, 所以 $p(G_s)$ 是一个常量。在分类前假定 $p(L_s = k) = 1/K$ (K 为类别总数), 也是一个常量, 所以 (10) 式的分母对所有 s, k 是一个常量, 则它可被表示为 Gibbs 分布

$$p(L_s = k | G_s, L_{s+r}, r, N_L^l, L_s = n) = \frac{e^{E(L_s = k | G_s, L_{s+r}, r, N_L^l, L_s = n)}}{Z} \quad (11)$$

而能量函数

$$E(L_s = k | G_s, L_{s+r}, r, N_L^l, L_s = n) = E_1(G_s | L_s = k) + \frac{1}{2} \ln [2\pi]^M \sigma_k^2 + E_2(L_s = k | L_{s+r}, \forall r, N_L^l) + E_3(L_s = k | L_s = n) \quad (12)$$

所以 $E^{\text{Total}} = \sum_{s,k} E(L_s = k | G_s, L_{s+r}, r, N_L^l, L_s = n) \quad (13)$

将 (2) 和 (6) 代入 (13) 式得

$$E^{\text{Total}} = \sum_{s,k} \left[\frac{g_s - \theta_k}{2\sigma_k^2} + \frac{\ln [(2\pi)^D \sigma_k^2]}{2} - \sum_{r, N_L^l} \beta \delta(k - L_{s+r}) + \alpha \bar{\delta}(k - n) \right] \quad (14)$$

这样, 遥感图像分类实际上是通过配置 L_s 使得 (11) 式所示概率最大, 等效地, 使得 (14) 式所示能量函数最小来实现。下面讨论如何利用三维 Hopfield 网络方法解决上述优化计算问题。

3 基于人工神经网络的遥感信息分类及平滑综合技术的实现

Hopfield 网络模型是最早用于优化计算的神经网络模型。对于一帧大小为 $M \times N$ 个象元, 准备分为 K 类的遥感图像, 我们构造一个 K 层, 每层 $M \times N$ 个神经元的三维 Hopfield 网络, 网络中的每个神经元表示为 $C_{i,j,k}$, $0 \leq i < M, 0 \leq j < N, 0 \leq k < K$, 其基本结构如图 2 所示。

记各神经元的输入为 $U_{i,j,k}$, 输出为 $O_{i,j,k} \in \{0, 1\}$ ($O_{i,j,k} = 1$ 表示 (i, j) 处的像元属于第 k 类, 对于确定性无拒绝分类情况, 显然应满足条件 $\sum_k O_{i,j,k} = 1$)。记神经元 $C_{i,j,k}$ 到 $C_{l,m,n}$ 的连接权为 $W_{i,j,k;l,m,n}$, 且假设 $W_{i,j,k;l,m,n} = W_{l,m,n;i,j,k}$, 则网络的运转方程为^[6]

$$U_{i,j,k}(t) = \sum_{l,m,n} W_{i,j,k;l,m,n} O_{l,m,n}(t) + B_{i,j,k} \quad (15-a)$$

$$O_{i,j,k}(t + 1) = \begin{cases} 1, & \text{if } U_{i,j,k}(t) > 0 \\ 0, & \text{if } U_{i,j,k}(t) < 0 \\ O_{i,j,k}(t), & \text{if } U_{i,j,k}(t) = 0 \end{cases} \quad (15-b)$$

$B_{i,j,k}$ 是神经元的阈值，网络的能量函数形式为

$$E^{\text{Hopfield}} = - 0.5 \sum_{i,j,k,l,m,n} W_{i,j,k;l,m,n} O_{i,j,k} O_{l,m,n} - \sum_{i,j,k} B_{i,j,k} O_{i,j,k} \quad (16)$$

可以证明，当网络状态如 (15) 式变化时，网络能量是单调递减的^[7]。

对 (14) 式进行分析，其第一、二两项代表了初始分类过程对能量函数的贡献，且仅当 $L_s = k$, $s = (i, j)$ ，即 $O_{i,m,k} = 1$ 时有效。同理， $L_{s+r} = k, s + r = (l, m)$ 等价于 $O_{i,j,k} = 1$ ，所以 (14) 式第三项等价于 $\sum_{r \in N_L^p} \beta(r) \delta(L_s - L_{s+r}) = \sum_{(i-l, j-m) \in N_L^p} \beta(i-l, j-m) O_{i,j,k} O_{l,m,k}$ 。对于 (14) 式第四项，其中 $\bar{\delta}(L_s - n)$ 仅在 $L_s = n$ 时取 1，故可用下述等式表达

$$\bar{\delta}(k - n) = \begin{cases} O_{i,j,k} O_{i,j,n}, & \text{if } k = n \\ 0, & \text{else} \end{cases} \quad (18)$$

$$E^{\text{Total}} = \sum_{s,k} \left[\frac{g_s - \theta_k}{2\sigma_k^2} - \frac{1}{2} \ln[(2\pi)^D \sigma_k^2] \right] O_{s,k} - \sum_{r \in N_L^p} \beta(r) O_{s,k} O_{s+r,k} + \sum_{\forall n \in k} \alpha O_{s,k} O_{s,n} \quad (19)$$

比较 (17) 与 (19) 式可得

$$B_{i,j,k} = - \frac{g_s - \theta_k}{2\sigma_k^2} - \frac{1}{2} \ln[(2\pi)^D \sigma_k^2] \quad (20)$$

$$W_{i,j,k;l,m,n} = \begin{cases} 2\beta(i-l, j-m), & \text{if } (i-l, j-m) \in N_L^p \text{ and } k = n \\ -2\alpha, & \text{if } (l, m) = (i, j) \text{ and } k = n \\ 0, & \text{else} \end{cases} \quad (21)$$

式 (21) 表明，该网络实际上并非全连接的。任一神经元 $C_{i,j,k}$ 只与同一层 p 阶邻域内的神经元 $C_{l,m,k}$ 及不同层但同一柱面神经元 $C_{i,j,n}$, ($n \neq k$) 连接，这可大大减少计算量。

优化计算的一个经典问题是如何避免局部极值而获得全局最优解。目前常见的解决办法有模拟退火算法和遗传算法。我们在网络运转过程中采用模拟退火算法来达到网络的全局能量最小状态。

4 实验结果及说明

我们采用上述基于人工神经网络的遥感信息分类及平滑综合算法对 1996 年 11 月云南思茅地区的一帧 Landsat TM 七波段遥感图像进行了分类处理，初始分类、不采用模型退火技术的神经网络综合结果 (Neural Network) 和采用模拟退火技术进行全局寻优的最终综合结果 (Neural Network+ SA) 如图 3 所示。分类结果精度见表 1。

表征邻域类别对当前类别调整影响重要程度的参数 β 和当前像素类竞争因子 α ，对于分类结果影响较大。经过对多帧遥感图像的试验，我们认为 α 的取值应在 0.1 ~ 1.0 之间，而 β 的一阶值(最大)应在 0.3 ~ 0.5 之间。对图 3 采用的 $\alpha = 0.8$ ，邻域影响重要性因子 β 的取值如表 2(只给出了部分值，其它可由邻域系统的对称性获得)。

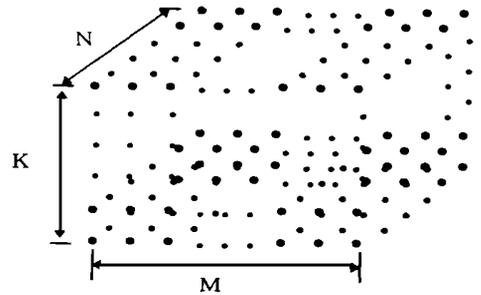


图 2 3D Hopfield 神经网络模型结构示意图

Fig. 2 The structure of 3D Hopfield NN

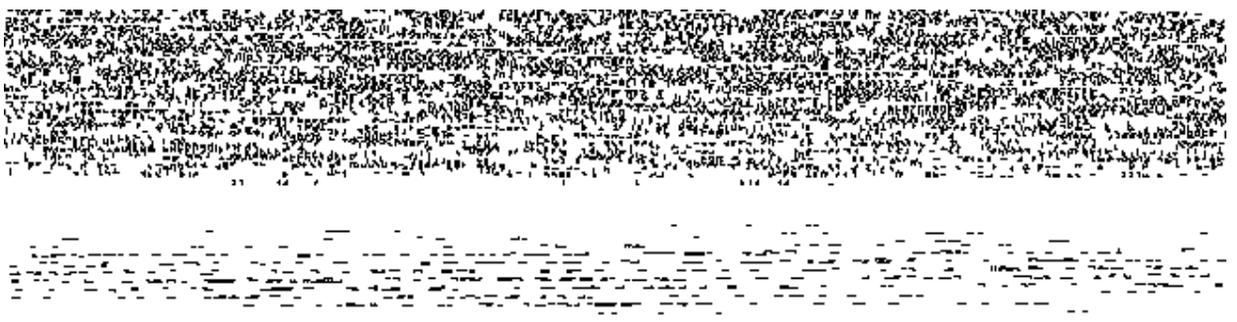


图3 基于人工神经网络的遥感信息分类及平滑综合处理结果

Fig. 3 Results of Classification and Smoothing Based on NN

表1 分类结果精度表

Table 1 The table of classification precision

| | 水域 | 灌木林 | 乔木林 | 稻田 | 未用地 |
|--------|---------|---------|---------|---------|---------|
| 初始分类结果 | 77. 66% | 76. 70% | 85. 12% | 78. 80% | 78. 04% |
| NN | 90. 31% | 90. 88% | 93. 95% | 87. 69% | 86. 52% |
| NN+ SA | 91. 67% | 90. 9% | 93. 74% | 89. 10% | 87. 64% |

表2 邻域重要因子取值

Table 2 The value of neighborhood factor

| | | | |
|-------|-------|-------|-------|
| 0. 03 | 0. 07 | 0. 11 | 0. 15 |
| 0. 07 | 0. 19 | 0. 23 | 0. 27 |
| 0. 11 | 0. 23 | 0. 31 | 0. 35 |
| 0. 15 | 0. 27 | 0. 35 | S |

5 结束语

本文给出的基于三维 Hopfield 人工神经网络方法将遥感信息分类过程与分类后处理中的平滑过程有机地机合在一起, 显著提高了遥感信息分类精度。

参考文献

- 1 万发贵, 遥感图像数字处理, 武汉: 华中理工大学出版社, 1991
- 2 Davis A W, Peet P G. A Method of Smoothing Digital Thematic Maps, Remote Sensing of Environment, 1977 6(1): 45 ~ 49
- 3 Grossberg S, et al. Neural dynamics of surface perception: Boundary webs, Illuminants and Shape-from-shading, CVGIP, 1987, 37: 116 ~ 165
- 4 Lin W C, et al. Constraint satisfaction neural networks, Pattern Recognition, 1992, 25 (7): 667 ~ 678
- 5 李强, 遥感信息处理方法研究, 国防科技大学 [博士学位论文], 1998
- 6 Hopfield J J. Neural networks and physical systems with emergent collective computational abilities, in Proc. Nat. Acad. Sci. Apr. 1982, 79: 2554 ~ 2558
- 7 Kung S Y. Digital Neural Networks, Englewood Cliffs, NJ: Prentice-Hall, 1993