

遥感图像分类与后处理综合技术研究^{*}

——基于约束满足神经网络方法

李 强 王正志

(国防科技大学自动控制系 长沙 410073)

摘 要 遥感图像计算机分类的精度问题是阻碍计算机遥感信息处理系统实用化的一个关键问题。将分类后处理中的分类结果平滑过程模型化为约束优化问题,采用神经网络方法把分类结果平滑过程与遥感图像分类过程结合起来,提出了基于约束满足神经网络的遥感信息分类与后处理综合技术。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 遥感图像分类,分类后处理,神经网络

1 引 言

遥感信息的分类处理是遥感技术体系中十分重要的部分。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,有可能使遥感图像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。通常是利用地物类别的空间关系,即相邻地物的类别平滑处理这类噪声^[1]。

目前常用的分类结果平滑方法主要有2种:基于最小面积原则的分类平滑方法^[2]和择多滤波器方法^[3]。这2种方法的主要缺点是: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。提出的基于神经网络的遥感图像分类及后处理综合分析(Remote Sensing Image Classification and Post-classification Integrated Analysis,以下简称RSIC&PIA)方法将遥感图像分类过程与分类后处理中的平滑处理有机地结合在一起,并且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 基于神经网络的遥感图像分类与后处理综合思想的提出

神经网络的RSIC&PIA方法的思想是基于神经

网络的图像分割思想的启发下提出的。与遥感图像分类的原理相似,图像分割是一个将图像根据区域一致性,如灰度级或纹理,进行类别划分的过程,所以它的研究对遥感图像分类方法的研究具有一定的参考价值。

1985年,Poggio^[4]指出了早期视觉过程中的许多问题都可用能量函数形式表达,并通过求解最优化问题来解决。1990年,Shah^[5]分析了图像分割中的几个基本问题之后认为,图像分割中去除弱边界和小区域的问题可被阐述为最小能量模型。神经网络的渐近稳定状态对应了能量函数的局部极小,是求解最优化问题的一种有效方法。W.C.Lin和E.C.Kuo^[6]于1990年提出了一种约束满足神经网络(Constraint Satisfaction Neural Network,简称CSNN)用于解决人工智能领域中著名的Huffman-Clowes景物标记问题,其效果与传统方法最好的情况等效。1992年他们又把CSNN用于图像分割,也取得了十分满意的效果。M.Liang^[7]用松弛技术与CSNN结合,提出了一种低信噪比条件下图像分割的神经网络法,并与最佳鉴别准则门限分割法和保持门限分割法进行比较,证明它具有更好的效果。我们分析了遥感信息分类与平滑的3个基本过程,在Markov随机场理论的基础上定义了这3个过程相应事件发生的概率,将平滑过程与分类过程集成在一起,模型化为一个优化问题。然后运用约束满足神经网络求解该问题。下面就详细介绍这一方法。

^{*} 国家卫星应用重点项目支持,遥感和实测数据由林业部中需勘察设计院和云南省林业局提供,在此表示衷心感谢。 <http://www.cnki.net>

3 遥感图像的分类与后处理过程分析

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 维特征向量集 $G \subseteq \{g_s \in R^D, \forall s \in \Omega\}$ 表征。考虑遥感图像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 $L = \{0, 1, \dots, K-1\}$ 。把对应于位置 s 的像元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。

根据专业人员对遥感图像进行分类及后处理分析的过程, 将计算机遥感图像分类及后处理方法分为 3 个步骤。

3.1 初始分类过程

我们采用了传统的有导师统计模式识别方法进行初始分类, 并假设第 k 类的训练区域为 $\Omega_k \subseteq \Omega$ 。由模式识别理论可知, 传统的有导师统计模式识别方法实际上是通过每一个类别的样本数据进行统计分析, 建立其类别先验概率 $p(\vec{x} | \omega_i)$, 然后按照 Bayes 统计决策理论求出待分类模式的类别后验概率 $p(\omega_i | \vec{x})$, 并根据类别后验概率建立判别函数进行分类识别的过程^[8]。因此, 初始分类的一个关键问题就是类别先验概率的获取, 实际上也是各类特征向量的概率分布模型的建立问题。

一般地, 我们假设各类的特征向量服从 Gaussian 分布, 并且位置为 s 的像元属于第 k 类时 G_s 的条件概率服从 Markov 随机场模型, 即类别先验概率为

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

其中: 能量函数

$$E_1(G_s = g_s | L_s = k) = \|g_s - \theta_k\|^2 / (2\sigma_k^2) \quad (2)$$

归一化因子

$$Z_1(L_s = k) = \sqrt{(2\pi)^D \sigma_k^2} \quad (3)$$

而 θ_k 和 σ_k^2 是第 k 类模式特征的均值向量和方差, S_k 是集合 Ω_k 中所含元素个数。

$$\theta_k = \frac{1}{S_k} \sum_{s \in \Omega_k} g_s; \quad \sigma_k^2 = \frac{1}{S_k} \sum_{s \in \Omega_k} \|g_s - \theta_k\|^2 \quad (4)$$

则等式(1)可表示为:

$$p(G_s = g_s | L_s = k) = e^{-(\|g_s - \theta_k\|^2 / (2\sigma_k^2)) - (1/2) \ln[(2\pi)^D \sigma_k^2]} \quad (5)$$

3.2 基于邻域类别的调整分类过程

首先, 我们给出邻域的图示定义。图 1 给出了一个像元 s 的典型的 9 阶非因果对称邻域系统。令 N_L^s 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 $N_L^2 = \{(-1, -1), (-1, 0), (-1, 1), (0, -1), (0, 1), (1, -1), (1, 0), (1, 1)\}$ 。则在图 1 所示的非因果对称邻域系统中,

9	8	7	6	7	8	9
8	5	4	3	4	5	8
7	4	2	1	2	4	7
6	3	1	s	1	3	6
7	4	2	1	2	4	7
8	5	4	3	4	5	8
9	8	7	6	7	8	9

图 1 像元 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

N_L^s 具有下列性质:

$$r \in N_L^s \Rightarrow -r \in N_L^s; \quad N_L^{-1} \subset N_L^s$$

设像元 $s \in \Omega$ 的 p 阶邻域坐标为 $s+r, r \in N_L^s$, 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

$$p(L_s = k | L_{s+r}, \forall r \in N_L^s) = e^{-E_2(L_s = k | L_{s+r}, \forall r \in N_L^s)} / Z_2 \quad (6)$$

其中能量函数 E_2 定义如下:

$$E_2(L_s | L_{s+r}, \forall r \in N_L^s) = - \sum_{r \in N_L^s} \beta(r) \delta(L_s - L_{s+r}) \quad (7)$$

归一化因子

$$Z_2 = \sum_{L_s} e^{-E_2(L_s | L_{s+r}, \forall r \in N_L^s)} \quad (8)$$

$\beta(r) > 0$ 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。

3.3 类别调整的竞争过程

在确定(即非模糊)分类中, 每个像元只能属于一个类, 因此本过程的作用是已知像元 s 为某一类别时减小将其划分为其它类别的可能性。

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

$$p(L_s = k | L_s = n) = e^{-\alpha\bar{\delta}(k-n)} / Z_n \quad (9)$$

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

$$\bar{\delta}(l) = \begin{cases} 0, & \text{当 } l = 0 \text{ 时} \\ 1, & \text{当 } l \neq 0 \text{ 时} \end{cases} \quad (10)$$

$\alpha > 0$ 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。

3.4 后验概率的公式表达

令 $p(L_s = k | G_s, L_{s+r}, \forall r \in \mathbb{N}_L^0, L_s = n)$ 表示了已知像元 s 对应的特征向量、其邻域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

$$\begin{aligned} & p(L_s = k | G_s, L_{s+r}, r \in \mathbb{N}_L^0, L_s = n) \\ &= [p(G_s | L_s = k) p(L_{s+r} | L_s = k, \forall r \in \mathbb{N}_L^0) \cdot \\ & p(L_s = k | L_s = n)] / p(G_s) / p(L_s = k) \end{aligned} \quad (11)$$

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(11)式的分母对所有 s, k 是一个常量, 则它可被表示为 Gibbs 分布

$$\begin{aligned} & p(L_s = k | G_s, L_{s+r}, r \in \mathbb{N}_L^0, L_s = n) \\ &= \frac{e^{E(L_s = k | G_s, L_{s+r}, r \in \mathbb{N}_L^0, L_s = n)}}{Z} \end{aligned} \quad (12)$$

而能量函数

$$\begin{aligned} & E(L_s = k | G_s, L_{s+r}, r \in \mathbb{N}_L^0, L_s = n) \\ &= E_1(G_s | L_s = k) + \frac{1}{2} \ln[(2\pi)^M \sigma_k^2] \\ &+ E_2(L_{s+r} | L_s = k, \forall r \in \mathbb{N}_L^0) \\ &+ E_3(L_s = k | L_s = n) \end{aligned} \quad (13)$$

所以

$$E^{\text{Total}} = \sum_{s, k} E(L_s = k | G_s, L_{s+r}, r \in \mathbb{N}_L^0, L_s = n) \quad (14)$$

将(2)和(7)代入(14)式得

$$\begin{aligned} E^{\text{Total}} = \sum_{s, k} & \left[\frac{\|g_s - \theta_k\|^2}{2\sigma_k^2} + \frac{\ln[(2\pi)^M \sigma_k^2]}{2} \right. \\ & \left. - \sum_{r \in \mathbb{N}_L^0} \beta \delta(k - L_{s+r}) + \alpha \bar{\delta}(k - n) \right] \end{aligned} \quad (15)$$

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(15)式所示能量函数最小来实现。

下面讨论如何利用约束满足神经网络方法解决上述优化计算问题。

4 基于约束满足神经网络的 RSIC&PIA 技术

4.1 CSNN 网络模型概述

Hopfield 网络模型是最早用于优化计算的神经网络模型, W.C. Lin 和 E.C. Kuo 提出的 CSNN 网络模型实际上可看作一个三维的 Hopfield 网络。对于一帧大小为 $M \times N$ 个像元, 准备分为 K 类的遥感图像, CSNN 是一个 K 层, 每层 $M \times N$ 个神经元的神经网络, 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。




图2 CSNN 神经网络模型结构示意图

Fig. 2 The structure of CSNN

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^[9]

$$U_{i,j,k}(t) = \sum_{l,m,n} W_{i,j,k;l,m,n} O_{l,m,n}(t) + B_{i,j,k} \tag{16a}$$

$$O_{i,j,k}(t+1) = \begin{cases} 1, & \text{当 } U_{i,j,k}(t) > 0 \text{ 时} \\ 0, & \text{当 } U_{i,j,k}(t) < 0 \text{ 时} \\ O_{i,j,k}(t), & \text{当 } U_{i,j,k}(t) = 0 \text{ 时} \end{cases} \tag{16b}$$

$B_{i,j,k}$ 是神经元的阈值, 网络的能量函数形式为

$$E^{\text{Hopfield}} = -0.5 \sum_{i,j,k,l,m,n} W_{i,j,k;l,m,n} O_{i,j,k} O_{l,m,n} - \sum_{i,j,k} B_{i,j,k} O_{i,j,k} \tag{17}$$

可以证明, 当网络状态如(16)式变化时, 网络能量是单调递减的^[9]。

4.2 CSNN 网络模型在 RSIC&PIA 中的应用

将 CSNN 网络模型应用于 RSIC&PIA 的关键是确定网络的连接权和各神经元的阈值, 这就需要将第 3 节在分析人工遥感图像解译过程中定义的能量函数(15)式与 Hopfield 定义的能量函数(17)式联系起来。

对(15)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 $O_{i,j,k} = 1$ 时有效。

同理, $L_{s+r} = k, s+r = (l, m)$ 等价于 $O_{l,m,k} = 1$, 所以(15)式第三项等价于 $\sum_{r \in \mathbb{N}_L^p} \beta(r) \delta(L_s - L_{s+r})$

$$= \sum_{(i-l, j-m) \in \mathbb{N}_L^p} \beta(i-l, j-m) O_{i,j,k} O_{l,m,k}.$$

对于(15)式第四项, 其中 $\bar{\delta}(L_s - n)$ 仅在 $L_s \neq n$ 时取 1, 故可用下述等式表达

$$\bar{\delta}(k - n) = \begin{cases} O_{i,j,k} O_{i,j,n}, & \text{当 } k \neq 1 \text{ 时} \\ 0, & \text{其它} \end{cases} \tag{18}$$

$$\begin{aligned} \therefore E^{\text{Total}} &= \sum_{s,k} \left[\frac{\|g_s - \theta_k\|^2}{2\sigma_k^2} + \frac{1}{2} \ln[(2\pi)^D \sigma_k^2] \right] O_{s,k} \\ &\quad - \sum_{r \in \mathbb{N}_L^p} \beta(r) O_{s,k} O_{s+r,k} + \sum_{\forall n \neq k} \alpha O_{s,k} O_{s,n} \end{aligned} \tag{19}$$

比较(17)与(19)式可得

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

$$W_{i,j,k;l,m,n} = \begin{cases} 2\beta(i-l, j-m), & \text{当 } (i-l, j-m) \in \mathbb{N}_L^p, \\ & \text{并且 } k = n \text{ 时} \\ -2\alpha, & \text{当 } (l, m) = (i, j) \\ & \text{并且 } k \neq n \\ 0, & \text{其它} \end{cases} \tag{21}$$

式(21)表明, CSNN 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。

网络初始状态的设定是优化计算神经网络应用中的一个重要问题, 它一方面会直接影响网络的收敛性能, 另一方面也决定了网络最终的稳定状态, 即最终稳定于全局能量最小还是局部能量极小状态。一般神经网络在无任何先验知识的条件下, 其初始状态都是随机设定的。对于本文所述的问题, 遥感图像的初始分类过程提供了网络初始状态的先验信息, 可加以利用。具体地说, 就是令神经元 $C_{i,j,k}$ 的初始输出为

$$O_{i,j,k}(0) = \begin{cases} 1, & \text{当 } k = \max_n p(G_s = g_s | L_s = n) \\ 0, & \text{其它} \end{cases} \tag{22}$$

为了进一步说明问题, 我们对上述 2 种网络初始状态的设定方法进行了实验, 结果表明: 这种利用了先验知识的方法的收敛速度(3618s)高于随机设定方法(5124s), 且分类精度也略高于随机设定方法。

网络训练的终止条件可由能量函数确定, 当能量函数的变化很小时停止。网络的能量极小状态对应了(12)式后验概率的极大值, 因此网络最终输出对应了一种“局部”最优分类结果。还需要说明的一点是: 在网络运转过程中, 条件 $\sum_k O_{i,j,k} = 1$ 不能保证总是满足, 这反映了 2 种相似的类别之间的竞争。对于确定分类情况, 最终分类结果可取为 $L_s = \max_k U_{i,j,k}$ 。

5 实验结果及说明

采用上述基于神经网络的 RSIC&PIA 算法对 1997 年 1 月云南思茅地区的一帧 Landsat TM 第 7 波段遥感图像(433 * 444)进行了分类处理, 初始分类


与最终分类结果图如图 3, 分类结果精度见表 1。

表 1 分类结果精度表


Table 1 The Classification Precision

	林地	稻田	水域	居民地	未用地
初始分类结果/%	79.3	78.4	96.7	78.9	61.2
最终 网络随机初始化/%	93.3	91.6	98.6	89.1	78.3
结果 非随机初始化/%	93.6	92.3	98.6	89.3	78.9

表征邻域类别对当前类别调整影响的重要程度



(a)初始分类结果



(b)最终平滑结果

图 3 基于 CSNN 的遥感图像分类及平滑综合处理结果

Fig. 3 Results of Classification and Smoothing Based on CSNN

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

图 4 邻域重要因子取值

Fig. 4 The value of neighborhood important factor

6 结论与讨论

从上面的讨论过程中我们就可以想到, 基于约束满足神经网络的遥感图像分类与后处理综合方法不仅仅适用于确定性分类的情况, 还可以推广到模糊分类的情况。最明显的一点是在网络训练结束后得到最终分类结果时, 如果同一柱面有 2 个以上神经元的输入大于 0, 则可对该像元的类别进行模糊

的参数 β 和当前像素类别竞争因子 α 对于分类结果影响较大。由于不同地区、不同遥感应用专题这些参数是完全不同的, 因此依靠系统本身去自适应获取这些参数是不现实的, 一般应由用户根据先验知识交互地给出。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 之间, 而 β 的一阶值(最大)应在 0.3-0.5 之间。对图 3 采用的 $\alpha=0.2$, 邻域影响重要性因子 β 的取值如图 4(只给出了部分值, 其它可由邻域系统的对称性获得)。

化。不过, 进行模糊分类仅考虑这一点是不够的。更合理的思路是对整个遥感图像分类与后处理过程重新考虑, 在 3 个子过程中全面考虑模糊分类思想的引入。因此将神经网络与模糊理论相结合进行遥感信息分类及后处理是我们下一步工作的一项重要内容。

另外, 在上述讨论中, 我们只考虑了 β 与空间位置 r 的关系, 而实际上它与邻域像元的类别也是关系密切的。例如, 水稻田这种类别出现在水域附近的概率显然大于其出现在城区街道附近的概率。显然, 这时我们需要利用关于不同类别空间关系的知识。专家系统是解决这一问题的有效途径, 因此将神经网络与专家系统相结合进行遥感信息分类及后处理是我们下一步工作的另一项重要内容。

参 考 文 献 (References)

- 1 Wan Faguan. Digital remote sensing image processing. Wuhan: Huazhong University of Science and Technology Press, 1991. (In Chinese)

- [万发贵. 遥感图像数字处理. 武汉: 华中理工大学出版社, 1991.]
- 2 A. W. Davis, F. G. Peet. A Method of Smoothing Digital Thematic Maps. *Remote Sensing of Environment*, 1977, **6**(1): 45—49.
 - 3 R. A. Schowengerdt. Techniques for Image Processing and Classification in Remote Sensing. New York: Academic Press, 1983.
 - 4 T. Poggio, *et al.* Computational vision and regularization theory. *Nature*, 1985, **317**: 314—319.
 - 5 J. Shah. Parameter estimation, multiscale representation and algorithms for energy-minimizing segmentation. *Proc. Int. Conf. Pattern Recognition*, 1990, 815—819.
 - 6 LIN Weichung, *et al.* Constraint satisfaction neural networks. *Pattern Recognition*, 1992, **25**(7): 667—678.
 - 7 M. Liang, Z. K. Sun. A neural network model for image segmentation. *ICAI & NN '92*, Switzerland, 1992.
 - 8 Fu. K. S Editor, Cheng Ming-de Translator. Application of pattern recognition. Peking University Press, 1990. (In Chinese). [傅京孙著, 程明德译. 模式识别应用. 北京大学出版社, 1990.]
 - 9 J. J. Hopfield. Neural networks and physical systems with emergent collective computational abilities. in *Proc. Nat. Acad. Sci.*, 1982, **79**: 2554—2558.

作 者 简 介

李强,男,1972年10月生,1993年在中国人民解放军国防科技大学自动化系获学士学位,现为国防科技大学自动化系博士研究生,主要从事模式识别、遥感信息处理和地理信息系统方面的研究,已发表论文8篇。

Research on Remote Sensing Image Classification and Post-Classification Integrated Techniques

LI Qiang WANG Zheng-Zhi

(National University of Defense Technology Changsha 410073)

Abstract The precision of computer classification is the main obstacle to the wide application of computer remote sensing information processing system. We model the smoothing classification results process as a constraint optimization problem, and integrate it with the classification process through neural network method, then present a remote sensing image classification and post-classification integrated technique based on constraint satisfaction neural network. This paper analyses The judging process of careerman, and discusses the theoretic model of neural network classification method in detail. The experimental results show that this method can improve the precision of classification saliently.

Key words Classification, Post-classification, Neural network