

基于混合双隐层径向基函数网络的高分辨率 SAR 图像地物分类算法研究

孙真真¹, 付 琨², 吴一戎²

(1. 北京系统工程研究所, 北京 100101; 2. 中国科学院电子学研究所, 北京 100080)

摘 要: 本文在高分辨率条件下对传统的合成孔径雷达 (SAR) 图像自动地物分类技术进行了扩展研究. 文章首先指出了经典的前馈神经网络模型在 SAR 图像地物分类中的不足, 然后基于径向基神经网络 (RBFN), 结合混合专家系统, 提出了一种变型的网络结构模型, 称之为混合双隐层径向基函数网络 (MDHRBFN), 并将其应用于高分辨率单视单极化的 SAR 图像地物分类. 实验结果表明, 基于该模型的分类型算法能够将 SAR 图像较好地地区分为人造目标类、自然目标类、背景和阴影, 具有比经典 RBFN 模型更好的分类效果, 不但可以应用于 SAR 图像辅助判读, 而且能够为目标识别过程提供潜在目标切片.

关键词: 合成孔径雷达图像; 神经网络; 地物分类

中图分类号: TN951

文献标识码: A

文章编号: 0372-2112 (2003) 12A-2040-05

The High-Resolution SAR Image Terrain Classification Algorithm Based on Mixed Double Hint Layers RBFN Model

SUN Zhen-zhen¹, FU Kun², WU Yi-rong²

(1. Beijing Institute of System Engineering, Beijing 100101, China;

2. Institute of Electronics, Chinese Academy of Sciences, Beijing 100080, China)

Abstract: The research on the high-resolution synthetic aperture radar (SAR) image automatic terrain classification (ATC) is made. Firstly, the shortage of the traditional feed-forward neural network model in SAR image classification is concluded. Then a new model named mixed double hint layers RBFN (MDHRBFN) is presented, which combines radial basis function network (RBFN) with mixed expert system. Finally, an algorithm based on this model for the high-resolution, single-look and single-polarization SAR images terrain classification is given and evaluated. The results show that this algorithm can readily cluster the SAR image into man-made targets, natural target, background and shadow, and has better performance than the one based on RBFN model. It can not only be applied to SAR image assistant interpretation, but also offer the potential target chips for target recognition process.

Key words: SAR image; neural network; terrain classification

1 引言

神经网络模式分类技术无需对统计分布模型进行明确的数学描述^[1], 同时兼有模式变换和特征提取的作用, 不但能够在模式空间里形成各种复杂的判决表面, 而且具有自适应能力. 此外, 在背景噪声的统计特性未知的情况下, 神经网络的抗噪优点尤为突出. 因此, 神经网络模式分类技术非常适合 SAR 图像的分类应用需求.

但是, 将前馈神经网络技术应用于 SAR 图像地物分类, 仍然面临诸多问题. 首先, 由于 SAR 图像严重的相干斑效应, 图像的测量值总是受到污染, 精确的训练样本集难以获取; 其次, 训练样本集的完备性难以保证, 通常无法获得覆盖各个目标的整个模式空间的足够训练样本; 再次, 图像中的目标往往

是动态的, 会随雷达姿态、时间的变化而发生偏移; 最后, 单频单极化 SAR 图像可利用的信息基本上依靠像素的 RCS, 而单视则进一步降低了特征的可靠性, 提高分类算法的精度非常困难.

径向基函数网络模型以多个“局部感受野”来拟合期望输出, 能够较好地解决 BP 网络收敛到局部极小值的问题, 因此被作为模式分类器得到广泛应用. 本文以 RBFN 作为原型, 结合混合专家系统, 提出了一种新的网络结构——混合双隐层 RBFN 模型 (MDHRBFN), 应用于 SAR 图像地物分类, 取得了较好的效果.

本文首先详细阐述 MDHRBFN 的模型拓扑结构及网络参数训练方法, 然后利用 MSTAR 实测数据对该网络模型应用于高分辨率单视单极化 SAR 图像进行验证和评估, 并给出结论.

2 MDHRBFN 模型及参数训练方法

基于 RBFN 和混合专家系统,本文提出了混合双隐层径向基函数网络(MDHRBFN)模型。该模型能够较好地提高 RBFN 模型的分类精确率(即对输入数据的敏感性),克服由于受相干斑的污染,使得 SAR 图像中背景类、自然目标类和一部分阴影数据的值比较接近的问题。其拓扑结构如图 1 所示。




图 1 MDHRBFN 拓扑结构

整个网络结构可分为两大部分,即样本集类别属性标定模块和双隐层 RBFN 网络。为了维护网络训练的流畅性,突出抗噪功能,本文结合学习矢量量化网络(LVQN)和模糊 C 均值的思路,提出了一种自适应模糊序贯聚类算法,以解决样本集类别标定问题。首先对所有样本集和聚类中心归一化,由

$$x_k - v_i = x_k - v_i + v_i - 2x_k \cdot v_i = 2 - 2x_k \cdot v_i \quad (1)$$

得,输入矢量与聚类中心之间的距离最小等价于输入矢量与聚类中心的点积最大。

算法流程如下:

(1) 初始化,定义警戒门限 $\tau_{\max}$,隶属度门限 $\mu_{\min}$,类别数目 $C=0$;

(2) 输入第一个样本,作为第一类的中心 v_1 ,类别数目 $C=1$;

(3) 输入下一个样本;

(4) 寻找 $v_i = \max_j \{x_k \cdot v_j\}$, $1 \leq j \leq C$;

(5) 计算 $\tau = \frac{x_k - v_i}{n_i}$, n_i 为当前类别 v_i 的个数,和隶属度函数 $\mu_{ik} = \frac{1}{\sum_{j=1}^C \left(\frac{x_k - v_k}{x_k - v_j} \right)^{\frac{1}{m-1}}}$, $m > 1$ 。若 $\tau <$

$\tau_{\max}$ and $\mu_{ik} > \mu_{\min}$,则更新聚类中心 $v_i = \sum_{k=1}^{n_i} \mu_{ik} x_k / \sum_{k=1}^{n_i} \mu_{ik}$,跳回步骤 3;

(6) 若 v_i 不满足 $\tau < \tau_{\max}$ and $\mu_{ik} > \mu_{\min}$,则对于剩下的聚类中心,跳回步骤 4;

(7) 若所有的聚类中心都不满足,生成新的聚类中心;

(8) 重复步骤 (3) ~ (7),直至所有的样本类别都标定完

毕。

自适应模糊序贯聚类算法无需迭代,若 $\tau_{\max}$ 和 $\mu_{\min}$ 选择合适,则聚类效果相当不错。并且只要存储当前的样本集中各样本的类别属性和聚类中心值,该算法具有“记忆”能力,可随时增加样本。

在类别数目已知的情况下,所有样本类别属性标定完成后,进行径向基函数数目、中心参数和尺度参数的学习。设径向基函数为高斯算子,则事实上其为尺度空间理论定义的经典尺度算子,因此,利用尺度空间理论,根据类别属性相同的样本来自然地选择径向基函数数目、中心参数和尺度参数,算法步骤如下:

(1) 在类别数目已知的约束下,按照自适应模糊序贯聚类算法对所有样本进行类别标定;

(2) 输入类别属性相同的样本子集;

(3) 初始设每一个样本自成一类,这样,样本值即为类别中心 $s_j(0)$,初始化尺度参数为一较小值 σ_0 ;

(4) 按照 $s_j(k+1) = s_j(k) + \eta \frac{x - s_j}{\sigma_j^2} \frac{(x - s_j)}{\sigma_j^2}$ 迭代各子

类的类别中心值;

(5) 根据预先设定门限,判断各类别中心值之间的距离,满足条件的进行类别合并;

(6) 如果合并后的类别数目大于 1,对尺度参数增加 $\nabla \sigma$,回到步骤 4;

(7) 输入类别属性相同的另一个样本集,回到步骤 3;

(8) 直到整个样本集训练完毕。

以上训练过程结束后,按照如下一种最直观的方法确定隐单元数目、中心参数和尺度参数:对于不同的类别属性相同的样本子集,选择随着 σ 的增加和中心参数的迭代,子类分类数目保持不变最长时的类别数目,为本类别属性相同的样本子集所确定的隐单元数目,类别中心值为各自的中心参数, σ 段的中值为尺度参数。

径向基函数数目、中心参数和尺度参数学习完毕后,接着进行第一隐层与第二隐层之间的权值训练。一般权值可取常数,如定义为 $1/M_i$,其中 M_i 为各自相同类别对应的径向基神经元数目;最后进行第二隐层与输出层之间的连接权值学习,这实质上是标准的前馈网络的学习算法,目前已较为成熟,因此不做深入探讨。大体上,若要求速度,可以采用无迭代的伪逆法或 LMSE 等,若要求精度,可采用 BP 学习算法或 RLS 学习算法等。

3 实验结果与算法评估

将 MDHRBFN 模型具体应用于 SAR 图像地物分类,可以建立适应性较强的分类算法。首先选择样本集,利用自适应模糊序贯聚类算法标定类别;然后,训练径向基函数数目、中心参数和尺度参数;进而定义第一隐层到第二隐层的权值参数,采用相同类别属性的样本集分别训练的方法,利用 RLS 算法训练第二隐层到输出层的权值;最后进行测试。

3.1 样本集的建立

本文采用的样本是 MSTAR 的 Redstone 实测杂波数据, X

波段、HH 极化,分辨率为 0.3m. 由于数据中人造目标太少,主要是为数不多的建筑物,因此,在杂波图中嵌入了一些强散射目标(与原图像最亮点在一个量级). 嵌入目标的另一个目的是可用来进行算法最感兴趣的人造目标类的分类准确性评估. 具体做法是先对 MSTAR 模板库中的 $T-72$ 模板进行分割,提出目标部分,然后随机嵌入杂波图中. 本文选取了 12 个不同姿态的模板,嵌入到图 $hb06182(1478 \times 1784)$ 中.




图 2 样本源 (a)MSTAR 杂波图 $hb06182$, (b)MSTAR $T-72$ 模板图

根据先验知识,选择合适的 $\tau_{\max}$ 和 $\mu_{\min}$, 保证聚类的类别数目为 4, 从 MSTAR 杂波图像中选择 5 块大小不等的图像区域, 分别作为样本集, 利用自适应模糊序贯聚类算法进行分类判定, 如表 1:

表 1 样本集参数选择

	样本集 1	样本集 2	样本集 3	样本集 4	样本集 5
$\tau_{\max}$	4.0	4.15	3.95	4.0	4.20
$\mu_{\min}$	0.05	0.05	0.05	0.05	0.05

3.2 参数训练过程

按照第二节的网络参数训练方法, 各样本集的参数训练结果如下: 表 2 是各样本集对应各子类的径向基函数数目; 各样本集对应子类的平均中心参数训练结果如表 3, 尺度参数训练结果如表 4(学习因子 $\eta = 0.002$); 第二隐含层到输出层的权值参数如表 5, 其中误差门限定为 0.1.

表 2 样本集各子类径向基函数数目

	样本集 1	样本集 2	样本集 3	样本集 4	样本集 5
人造目标类	2	2	2	2	2
自然杂波类	5	6	7	8	8
背 景	9	11	12	14	17
阴 影 类	2	3	4	4	4

表 3 样本集各子类平均中心参数

	样本集 1	样本集 2	样本集 3	样本集 4	样本集 5
人造目标类	0.4210	0.4212	0.4210	0.4216	0.4214
自然杂波类	0.1249	0.1406	0.1384	0.1348	0.1412
背 景	0.0062	0.0058	0.0072	0.0088	0.0076
阴 影 类	0.0006	0.0006	0.0006	0.0006	0.0006

表 4 各样本集尺度参数训练结果

	样本集 1	样本集 2	样本集 3	样本集 4	样本集 5
人造目标类	0.2478	0.2454	0.2482	0.2460	0.2462
自然杂波类	0.3810	0.4021	0.4316	0.4005	0.3728
背 景	0.6334	0.6120	0.6462	0.6613	0.6714
阴 影 类	0.2010	0.2048	0.2104	0.1987	0.1992

表 5 各样本集网络权值参数训练结果

(a) 阴影类对应权值

	样本集 1	样本集 2	样本集 3	样本集 4	样本集 5
W11	0.0848	0.0723	0.0766	0.0871	0.0774
W12	0.2267	0.2431	0.2186	0.2634	0.2582
W13	0.6369	0.6832	0.7143	0.6882	0.7056
W14	0.9011	0.8874	0.9144	0.9128	0.9046

(b) 背景类对应权值

	样本集 1	样本集 2	样本集 3	样本集 4	样本集 5
W21	0.0932	0.0834	0.0852	0.0872	0.0883
W22	0.3264	0.3530	0.3179	0.3593	0.3571
W23	0.8257	0.8933	0.8137	0.8872	0.8032
W24	0.6103	0.6851	0.7014	0.7112	0.7059

(c) 自然目标类对应权值

	样本集 1	样本集 2	样本集 3	样本集 4	样本集 5
W31	0.1772	0.1624	0.1721	0.1854	0.1763
W32	0.9174	0.9530	0.9087	0.9116	0.9194
W33	0.4246	0.4712	0.3964	0.3871	0.4033
W34	0.2412	0.2836	0.2135	0.2174	0.2042

(d) 人造目标类对应权值

	样本集 1	样本集 2	样本集 3	样本集 4	样本集 5
W41	0.9915	0.9847	0.9738	0.9860	0.9463
W42	0.2374	0.2460	0.2273	0.2531	0.2594
W43	0.0446	0.0437	0.0591	0.0672	0.0684
W44	0.0058	0.0064	0.0067	0.0043	0.0052

3.3 实验结果

利用上述样本集 2 的参数训练结果, 分别代入 MSTAR 的 redstone 杂波图 $hb06182$ 的左上角 (512×512) 部分, 直观的分类结果如图 3.

图 4 为利用样本集 2 进行训练时的误差收敛趋势.

图 5 为利用样本集 2 将整幅 $hb06182$ 图像 (1478×1784) 进行分类的结果.

同样, 对图 3 和图 5 的分类结果, 结合文献 [11] 提出的树木类(典型自然杂波)、道路类(属于背景类)、建筑物类(属于人造目标)的初判算法, 对分类结果进行简单判读, 用以增强视觉可分辨率, 如图 6 所示.




图3 hb06182 分类结果 1(512 × 512) (a) 原始图
(b) 分类结果(对背景和阴影滤波后)




图4 训练误差收敛趋势图
(横坐标为样本个数,量纲为个;纵坐标为方差,无量纲)




图5 (a) 原始图 (b) 分类结果(未对背景和阴影滤波)




图6 类别粗判结果

3.4 算法评估

对分类算法进行比较细致的定量化评估,需要确定如何计算分类检测率(或错误率)、虚警率等。理论上,既然算法是基于像素(像素区域)级的,则似乎也应该通过对应的像素类别来计算检测率和虚警率。但是,对于 SAR 图像,利用像素计算分类检测率无法达到对算法分类性能的评估作用。原因在于:典型的可见光和红外遥感图像中的目标都是由灰度近似的具有与人眼成像方式相同的轮廓区域组成。而由于成像机理的原因,SAR 图像中目标一般都是由若干“散射中心”组成,直观地表现为亮暗不一的像素集,若不进行后处理,很难对一块区域(如对应某目标)中的所有像素进行一致性类别标定。此外,由于实际应用中非常忌讳“漏报”的问题,常常采用“宁可虚判,不可漏报”的原则,因此本文对分类算法的结果以分类(检测)率为主要指标。

表6 分类结果

	样本集 1	样本集 2	样本集 3	样本集 4	样本集 5
人造目标类	100 %	100 %	100 %	100 %	100 %
自然杂波类	80.3 %	81.0 %	81.7 %	82.2 %	82.6 %
背景	76.9 %	77.5 %	78.2 %	78.4 %	78.8 %
阴影类	88.1 %	88.7 %	89.2 %	89.3 %	89.6 %

综上所述,本文采用的评估准则为:样本集和分类过程仍然以像素(像素集)为单位,分类率则选择以“视觉可区分性”和基于像素直接计算分类率相结合的准则,进行算法性能评估。具体地说,图像中人造目标类、自然杂波类、一部分与目标相关的阴影,和不包含其它类别的背景块以视觉可分辨的“目标”个体为单位,进行算法性能评估,而其它的背景类和阴影则仍然计算基于像素的分类率,最终分类率为两种计算方法的均值。

利用以上 5 个样本集的数据,分别单独进行训练,代入 MSTAR 的 redstone 杂波图 hb06182 的数据,应用“视觉可分辨性判决”结合计算像素分类率的准则,分类结果如表 6 所示。

总体上,MDHRBFN 模型分类结果平滑了大部分小纹理,已经能够很清晰地区分预先定义的四种类别。结合实验结果,从图像分类结果图 3、5 和 6 来看,人造目标类在图像中比较明显,特别是在高分辨率情况下,目标都呈“块”状,按照视觉可分辨原则,不存在漏报问题,区分率可达 100%,嵌入的 12 个 T72 目标和其它视觉可分辨的人造目标,主要是建筑物,都被清晰地区分出来;自然目标类的区分率平均也达 81.8%,但是仔细分析,属于树冠和灌木的区域仍然保留的细节过多;背景类的平均区分率近 78%,特别地,背景区域比较平滑,可减轻大量的判读复杂度;阴影类的平均检测率近 89%;最明显的是图像中道路主体作为阴影区分得很好,可以将道路直接粗判出来。

从实际输出的三维分布图图 4(a)来看,人造目标类的实际输出与其它三类的实际输出区别较大,很容易进行区分;自然目标类实际输出也较明显,但部分强度较高的像素被误分类;背景和阴影的实际输出则比较接近。

从收敛速度图 4(b) 来看,人造目标类收敛速度快,一般经过 70 次左右迭代,误差可小于 0.1;阴影类次之,一般迭代次数在 120 次左右;而自然目标类和背景类则迭代过程需要的时间较长,分别达 300 次和超过 400 次,才能满足误差要求。

将标准 RBFN 模型和本文提出的 MDHRBFN 模型分类算法进行比较,图 7 为两种算法对 hb06182 左上角(512 × 512)数据的分类结果对比。可以看出,标准 RBFN 更多地起到了对原始图像“增强”的效果,并未真正将图像分成预先定义的四类目标,而是分成三类,其中自然目标的中心区域被分为人造目标类,边缘区域别分为背景,背景和阴影分布比较杂乱。而 MDHRBFN 模型分类结果则将自然目标类和人造目标类较好地进行了区分,并且包含了一定的“智能”处理,人造目标和自然目标的轮廓更清晰,背景和阴影区更加集中、细致。当然,由于标准 RBFN 是单层网络,训练速度更快是其较 MDHRBFN 模型而言的优点。




图 7 分类对比结果 (a) 原始图, (b) RBFN 分类结果, (c) MDHRBFN 分类结果

4 结论

本文研究了直接利用样本集进行非参数估计的 SAR 图像地物分类技术,以径向基函数网络作为研究原型,结合混合专家系统,提出了一种新的变型结构,称之为混合双隐层径向基函数网络模型。该模型能够大量减少隐含层单元的数目,需要调控的经验参数少,训练速度较快,比较适合于函数逼近和模式分类应用。试验结果表明,基于该模型分类算法在 SAR

图像地物分类的实际应用中,较经典的标准网络模型而言,具有更高的分类精度和分类率,表现出更好的分类效果。

参考文献:

- [1] 边肇祺,张学工,等. 模式识别(第二版)[M]. 北京:清华大学出版社,1999. 7 - 8.
- [2] Yoshihisa Hara, Robert G Atkins, et al. Application of neural networks to radar image classification[J]. IEEE Trans on Geoscience and Remote Sensing, 1994, 32(1): 100 - 109.
- [3] 王士同, 於东军. 径向基神经网络的构造理论[J]. 华东船舶工业学院学报, 1999, 13(2): 41 - 45.
- [4] 王长琼, 孙国正. 一种组合径向基函数网络结构的分类方法[J]. 武汉交通科技大学学报, 1998, 22(1): 23 - 28.
- [5] Poggio T, F Gossi. Networks for approximation and learning[J]. Proceedings of the IEEE, 1998, 78(9): 1481 - 1497.
- [6] HWANG Y S, BANG S Y. An efficient method to construct a radial basis function neural network classifier[J]. Neural Networks, 1997, 10(8): 1495 - 1503.
- [7] Grosi F. Some extensions of radial basis functions and their applications in artificial intelligence[J]. Computers Math, 1992, 24(12): 61 - 80.
- [8] Rinivasa V C, Joydeep Ghosh. Scale-based Clustering using the Radial Basis Function Network[EB/OL]. <http://pegasus.ece.utexas.edu/journals.html>.
- [9] B Fritzke. Incremental neuro-fuzzy systems[A]. Proc SPIE's Optical Science, Engineering and Instrumentation '97: Applications of Fuzzy Logic Technology IV[C]. San Diego, CA: SPIE Press, 1997. 2 - 10.
- [10] B Fritzke. Fast Learning with Incremental RBF Networks[J]. Neural Processing Letters, 1994, 1(1): 2 - 5.
- [11] 付琨, 匡纲要, 郁文贤. 高分辨率 SAR 图像地物分类算法研究[J]. 电子学报, 2001, (12A): 1280 - 1283.

作者简介:

孙真真 女, 1972 年 12 月生于湖南省长沙市, 2001 年获国防科技大学电子科学与技术学院信息与通信工程博士学位, 主要从事信号处理、SAR 图像解译与目标识别等方面的研究工作。

付琨 男, 1974 年 6 月生于湖北省天门市, 2002 年获国防科技大学电子科学与技术学院信息与通信工程博士学位, 目前在中科院电子所从事博士后研究工作, 主要研究领域包括 SAR 图像理解、雷达目标自动识别技术、数字视频、图像数据库等。

吴一戎 男, 1963 年 7 月生于北京, 1998 年获中科院电子学研究所信号与信息处理博士学位, 博导, 研究员, 中科院电子所副所长, 主要从事卫星地面信息处理、SAR 信号处理、SAR 图像解译与目标识别等方面的研究工作。