

文章编号: 1000-5862(2015)04-0383-06

# 夜间静止卫星红外云图的 GHSOM 网络云分类模型

闫廷亚, 王 杉\*

(华东交通大学信息工程学院, 江西 南昌 330013)

**摘要:** 针对夜间云分类准确率低下的问题, 利用奇异值分解方法对 FY-2E 夜间红外云图进行特征提取和选择, 从中筛选出包括亮温和分裂窗差值在内的不同的纹理特征. 分别采用动态增长型分层自组织和自组织映射 2 种神经网络模型对夜间云图进行分类, 并将 2 种网络模型进行分类效果进行对比分析. 实验结果表明: GHSOM 网络模型在夜间云图分类方面效果较好, 平均准确率总体上高于 SOM, 通过分层的分类方法极大地提高了夜间云图的分类准确率.

**关键词:** 动态增长型分层自组织; 自组织映射; 夜间云图; 云分类

**中图分类号:** TP 183   **文献标志码:** A   **DOI:** 10.16357/j.cnki.issn1000-5862.2015.04.10

## 0 引言

气象卫星对监测天气变化具有重要的作用, 所提供的卫星云图具有丰富的气候信息<sup>[1]</sup>. 云图上呈现的各种云的类型和分布情况, 有助于提高天气预报的准确性和气候检测的有效性, 从而可以避免灾害现象的发生, 为人们的生活和出行提供了极大的便利<sup>[2]</sup>. 因此, 利用卫星云图的特征信息准确、自动识别云的种类是气象卫星业务的主要方向<sup>[3]</sup>, 具有重要的研究意义.

由于云的复杂多样性, 不同地区的云型差异较大, 因此应用卫星云图进行分类的方法也具有多样性<sup>[4]</sup>. 传统的云分类方法包括统计分类法<sup>[5]</sup>、聚类分析法<sup>[6-7]</sup>、最大似然估计法<sup>[8]</sup>、神经网络方法<sup>[9-11]</sup>等. 其中, 神经网络方法在训练精度和收敛概率方面要明显好于其他分类方法, 特别是 SOM 神经网络方法, 无论是模型结构还是模型精度, 均表现出较好的分类应用性<sup>[12-13]</sup>. B. Tian<sup>[14]</sup> 等利用 GOES-8 红外和可见光云图数据, 应用 SOM 网络进行分类, 分类准确率达到 74.8% 以上. 但是夜间由于可见光云图无法获取, C. Christodoulou 等<sup>[15]</sup> 利用 K-最近相邻法 (K-Nearest Neighbor, KNN) 和 SOM 方法相结合对 Meteosat-7 (Meteorological Satellite) 红外云图数据进行分类, 云图准确率只有 60.7%, 分类效果大大下降.

针对夜间云图分类(无可见光)准确率不够高的问题, 本文做了进一步改进. 采用一种在 SOM 基础上改进的 GHSOM 网络用于夜间静止卫星 FY-2E 红外云图分类<sup>[16-17]</sup>, 该方法通过网络层次的自增长及结点动态增长特性, 增强了网络结构拓展的灵活性, 极大地提高了夜间云图的分类准确率, 降低了夜间红外云图分类中的混分现象.

## 1 基于 SOM 网络模型的云图分类

### 1.1 SOM 的基本原理

SOM 网络模型具有分类识别能力, 能够在事先不知晓待分类样本特征的情况下, 通过无师自主学习, 在竞争层输出各样本的概率分布情况<sup>[18]</sup>. 具有仿造人的大脑系统去解决高维样本的识别能力. SOM 由输入层和输出层 2 层网络构成, 2 层之间通过权值向量相互连接, 其结构如图 1 所示. 该网络的输入层用来接收输入模式的特征向量, 输入节点数依据特征向量的维数而设定. 输出层的每个节点用来表征相似样本的个数. 目前, SOM 在聚类、矢量量化等领域都有较多的成功应用, 尤其在卫星云图分类领域, SOM 以非线性方式提取特征信息并进行降维等优点在该领域也得到越来越广泛的应用<sup>[19]</sup>.

SOM 网络算法采取的是胜者为王法则, 假设输入层结点数位  $i$ , 竞争层结点位  $j$ ,  $W_{ji}$  代表的是输出层到竞争层的权重, 将竞争层每个神经元的权值向

收稿日期: 2015-03-19

基金项目: 国家自然科学基金 (61261041) 资助项目.

通信作者: 王 杉 (1981-), 男, 江西南昌人, 副教授, 博士, 主要从事信号处理的研究.




图1 SOM神经网络的基本结构

量  $\hat{W}_j (j = 1, 2, \dots, m)$  与样本向量  $\hat{X}$  分别做一次点积,点积越小说明两者的相似性就越高,最相似的神经元获胜<sup>[20]</sup>.距离计算公式为

$$\begin{aligned} \|\hat{X} - \hat{W}_{j^*}\| &= \min_{j \in \{1, 2, \dots, m\}} (\|\hat{X} - \hat{W}_j\|) \Rightarrow \\ \|\hat{X} - \hat{W}_{j^*}\| &= \sqrt{(\hat{X} - \hat{W}_{j^*})(\hat{X} - \hat{W}_{j^*})^T} = \\ &= \sqrt{\hat{X}\hat{X}^T - 2\hat{W}_{j^*}\hat{X}^T + \hat{W}_{j^*}\hat{W}_{j^*}^T} \Rightarrow \\ \hat{W}_{j^*}\hat{X}^T &= \max_j(\hat{W}_j\hat{X}^T). \end{aligned} \quad (1)$$

根据胜者为王学习法则,最相似的神经元输出为“1”,剩下的神经元输出为0.即

$$y_j(t+1) = \begin{cases} 1 & j = j^* \\ 0 & j \neq j^* \end{cases}, \quad (2)$$

胜出的神经元重新调整其权值向量  $W_{j^*}$ ,其权值向量学习调整为

$$\begin{cases} W_{j^*}(t+1) = \hat{W}_{j^*}(t) + \Delta W_{j^*} = \hat{W}_{j^*}(t) + \alpha(\hat{X} - \hat{W}_{j^*}), \\ W_j(t+1) = \hat{W}_j(t) \quad j \neq j^* \end{cases}, \quad (3)$$

其中  $\alpha$  为训练时间以及获胜神经元附近邻域的函数,初始时  $\alpha$  被赋值于 0 到 1 之间的数值.该算法经过权值的不断调整来训练 SOM 网络,这个流程将继续直到网络到达指定的迭代次数或者误差可接受的水平为止.

### 1.2 静止卫星云图特征值提取

特征值的选取对网络的分类效果至关重要<sup>[21]</sup>.因此在云图特征值的提取过程中,应尽可能地选取最能体现不同云类差异的向量特征值,以达到区分云类的效果.目前最常用的云图特征包含亮温、可见光反照率和水汽含量等.其中亮温表征的是云的高度,云层的高度与亮温呈反比例关系,云层越高,亮温越小<sup>[22]</sup>.可见光云图特征纹理信息丰富,反照率越大说明云体越厚,可根据反照率的大小来识别云的类型,这也是大多数分类方法在处理云图分类上的依据.水汽含量的差异可用来区分冰晶云和液滴云等<sup>[23]</sup>.

本文的云图特征由静止业务卫星 FY-2E 提供. FY-2E 是我国自行研发的第 3 颗气象卫星,通过扫

描辐射计(Visible and Infrared Spin Scan Radiometer, VISSR)可获得红外和可见光云图.该卫星已于 2008 年在西昌卫星发射中心由长征三号甲运载火箭成功发射升空,目前定位于东经 105 度赤道上空.对所选取区域的卫星云图数据提取了包括红外(Infrared, IR)和可见光(Visual, VIS)通道的 7 种特征.其中 VIS 主要体现白天云厚度、高度以及云的成分. IR1、IR2 主要代表地表或云层特征, WV 主要体现高层的云特征, IR1-IR2 主要体现卷云和积雨云的特征, IR1-WV 和 IR2-WV 进一步体现不同大气层高度的云特征.各个云类特征的具体描述如表 1 所示.

表 1 云分类特征量介绍

云分类特征	描述
VIS	可见光通道的反照率
IR1	红外 1 通道的云顶温度
IR2	红外 2 通道的云顶温度
WV	水汽通道的云顶温度
IR1-IR2	红外 1 和红外 2 通道的分裂窗差
IR1-WV	红外 1 和水汽通道的亮温差
IR2-WV	红外 2 和水汽通道的亮温差


### 1.3 SOM 网络模型云分类结果及分析

本文采用的实验数据是由国家气象中心提供的 FY-2E 卫星的 HDF 格式产品,该产品包含了 5 km 分辨率的 IR1-IR3 通道数据和最高分辨率为 1.25 km 的 VIS 通道数据,以及云分类数据等.为了验证夜间和白天 SOM 网络模型云分类效果的不同,在其他网络参数不变的情况下,只在网络输入层上作了简单的调整.白天 SOM 网络云分类模型在输入层上多了 VIS 云分类特征.为了便于比较,从 2010 年 8 月 7 日 10:00 时和 00:00 时的卫星云图中各选取了 360 个输入样本进行检测.所选取的样本包含了目前气象中心划分的所有云的种类.其中每种云类的样本数量总体变化不大.图 2 所示的是 FY-2E 白天 10:00 拍摄的卫星云图,分别包括可见光云图和 IR1 通道红外云图.2 种云图工作的时间段是不同的,可见光云图的特点是只有白天有,夜间获取不到,而红外云图全天候都能获取.

云分类结果较大程度取决于网络结构,而网络结构与输入特征数、分类的类别数和优胜邻域等方面相关.在本分类实验中,首先利用 `newsom()` 函数来创建 SOM 网络,调用格式为 `net = newsom(PR, [d1 d2], hextop, linkdist)`.其中  $PR$  是  $R$  个输入特征值的最大值和最小值的设定值.  $d_i$  是第  $i$  层的维数,因为实验结果输出要求为 8 类,所以 SOM 网络的输出层设置为 [2 4] 形式.拓扑函数选择具有六角形结

构的 hextop, 当 SOM 网络创建好后, 该函数使各神经元之间呈六角形结构排列. 采用 linkdist 距离函数计算各神经元之间的相似性, linkdist 又称为连接距离函数, 在给定神经元的位置后, 该函数可用于计算神经元之间的距离. 网络中的剩余参数均取默认值. 在选取样本的过程中, 要包含气象中心划分的各个云类. 按照这个标准, 在本实验中, 从 2010 年的云图

样本库中抽取具有代表性的部分样本, 分别包含 8 种云类的训练样本, 用来训练构造 SOM 网络模型. 网络训练结束后, 把待检测的 360 个云图样本依次输入网络. 经过 Matlab 编程, SOM 网络模型的云分类结果如表 2 和表 3 所示, 其中表 2 所对应的是白天有可见光数据时的 SOM 云分类结果, 表 3 所对应的是夜间只有红外数据时的 SOM 云分类结果.



(a) IR1 通道红外云图 (b) 可见光云图.

图 2 2010 年 8 月 7 日 10:00 时的卫星云图

在当前样本下, 通过分析表 2 和表 3 中的分类结果可以看出, SOM 网络模型在夜间云图分类中容易错分. 由于夜间晴空陆地和海面温度比较接近, 导致所有陆地类别被误认为晴空海面类别. 在密卷云和积雨云的判别中, 由于这 2 种云在红外云图上的轮廓比较清晰, SOM 网络分类效果较好. 在卷层云方面, 表 3 中 SOM 网络对卷层云的识别率只有

57.1%, 而表 2 中的识别率却达到了 88.9%, 分类效果明显好于表 3. 表 2、表 3 中 SOM 网络对高层云的判别比较接近, 识别率较高, 更加符合原始卫星云图的分类结果. 在高积云的判别上, 表 2 中的高积云容易误判为混合像元, 识别率只有 56.4%. SOM 网络模型在白天和夜间云分类的平均准确率分别是 78.5% 和 64.6%.

表 2 白天 10:00 时 SOM 云分类结果

类别	海面	陆地	混合	高层云	卷层云	密卷云	积雨云	高积云	识别率/%
海面	30	0	0	0	0	0	0	0	100.0
陆地	17	19	0	0	0	0	0	0	52.3
混合	0	0	24	1	3	6	0	2	66.7
高层云	0	0	3	29	1	0	0	3	80.1
卷层云	0	0	1	3	56	3	0	0	88.9
密卷云	0	0	4	0	6	30	0	0	75.0
积雨云	0	0	0	0	0	6	58	0	90.6
高积云	0	0	5	5	4	0	0	41	74.5

表 3 夜间 00:00 时 SOM 云分类结果

类别	海面	陆地	混合	高层云	卷层云	密卷云	积雨云	高积云	识别率/%
海面	30	0	0	0	0	0	0	0	100.0
陆地	36	0	0	0	0	0	0	0	0
混合	0	0	21	5	3	1	0	6	58.3
高层云	0	0	5	29	0	0	0	2	80.5
卷层云	0	0	13	0	36	7	0	7	57.1
密卷云	0	0	1	0	0	32	7	0	80.0
积雨云	0	0	0	0	0	10	54	0	84.4
高积云	0	0	5	2	7	0	0	31	56.4

通过对实验结果的对比分析, 证明利用 SOM 网

络方法对白天有可见光云分类特征进行聚类分析是

可行有效的.但是 SOM 网络模型在应用于夜间云图识别上,效果并不明显.尤其在本实验 SOM 网络各项参数设置和构建的基础上,云图识别准确率低下,甚至出现了陆地和海面的混分现象.因此,针对夜间可见光云图无法获取,SOM 网络在夜间云图(无可见光)分类方面混分及整体准确率并不是很高的问题,在对其原因作了具体分析之后,提出了将 GH-SOM 神经网络应用于夜间云图分类.GHSOM 是基于 SOM 基础上发展出来的,相比于传统的 SOM,GHSOM 采用多层网络结构,在处理夜间云图方面,通过多层数据细分达到提高云图分类准确率的效果.

## 2 基于 GHSOM 网络模型的夜间云分类

### 2.1 GHSOM 网络的基本原理

GHSOM 是在 SOM 基础上发展演变而来的一种神经网络模型,比较适合高维输入样本的聚类问题.该模型不同于传统的 SOM,它具有灵活性、网络结构不固定性等特点<sup>[24]</sup>.在聚类过程中,GHSOM 事先不指定聚类的类别数,而是通过输入样本的内部特征动态地划分成若干类别,最终网络的结构依据输入样本的特征而作具体的变化.GHSOM 网络具有多层结构,每层结构都由部分 SOM 网络组成,如图 3 所示.最开始的第 0 层只有一个神经元,又称为虚拟的第 0 层.而真正网络运算的起点是第 1 层,该层网络由简单的  $2 \times 2$  单元 SOM 组成.在网络的拓展过程中,依然采用 SOM 网络学习算法.初始的网络模型依据输入样本的主要特征进行聚类,其次该网络将进一步挖掘输入样本的次要特征,再做进一步的细分,直至产生最终的 GHSOM 网络模型,能够把输入样本的概率分布彻底变现实出来<sup>[25]</sup>.目前 GH-SOM 网络在图像处理、分割和聚类等领域都有一定的应用.

### 2.2 GHSOM 网络的训练过程

在 GHSOM 网络的运行机制中,SOM 是整个网络的基础,需要考虑 3 个主要环节,分别是竞争、协同和突出自适应环节.由于 GHSOM 网络由多层 SOM 组成,所以 GHSOM 的学习算法与 SOM 相同.在训练过程中,GHSOM 网络分别按照横向和纵向这 2 种拓展方式,动态地改变网络的结构.在 GH-SOM 算法中,对增长的全局控制有平均量化误差(mean quantization error,  $mqe$ )和量化误差(quantization error,  $qe$ ) 2 个参数.其中平均量化误差是决定




图 3 GHSOM 网络结构图

GHSOM 网络能否纵向发展的分层终止条件.当每层网络训练结束后,该网络算法将对竞争层的每个神经元做一次检查,判断其是否满足全局终止条件为

$$qe_i < \tau_2 \times qe_0, \tag{4}$$

其中  $\tau_2$  为控制网络规模的系统参数.

而量化误差是判断 GHSOM 网络能否横向发展的增长终止条件,神经元分裂方式需满足增长终止条件.增长型神经元可通过自适应增长,扩充神经元的规模,如图 4 所示.对于单个网络  $m$ ,增长终止条件为

$$mqe_m < \tau_1 \times qe_u, \tag{5}$$

其中  $qe_u$  为该网络所对应上层神经元  $u$  的量化误差,参数  $\tau_1$  决定了整个网络的深度.





图 4 GHSOM 网络横向拓展结构图

下面是 GHSOM 网络具体的训练过程:(i) 分别为  $\tau_1$  和  $\tau_2$  赋初始值,且取值在 0 到 1 之间.在初始化 GHSOM 网络模型的过程中,每层 SOM 的其他参数不作改变,并设定每层 SOM 的最大迭代次数  $\lambda$ .(ii) 将云图输入样本送入 GHSOM 网络,按照 SOM 学习算法,进行迭代,直到达到总迭代次数  $\lambda$  结束.(iii) 检查每层 SOM 网络竞争层是否满足横向拓展条件  $MQE_m < \tau_1 \times qe_u$ ,将不满足条件的每个神经元继续进行横向拓展,直到所有神经元均符合横向拓


展判定条件为止。(iv) 判断 GHSOM 网络模型中每层 SOM 网络竞争层每个神经元是否满足纵向拓展条件  $qe_i < \tau_2 \times qe_0$ 。将不满足条件的每个神经元进行纵向拓展,产生新的层次,继续进行再分,直至每个神经元都符合全局结束条件才结束。(v) 检查所有竞争层是否都训练完毕,如果不是的话,则继续等待,直至所有的网络训练都结束。

### 2.3 GHSOM 云分类结果及分析

为了便于比较夜间 2 种网络模型的分类效果,



(a)



(b)

(a) IR1 通道红外云图 (b) 水汽云图。

图5 2010年8月7日00:00时的卫星云图

在本分类实验过程中,可以根据云图样本的主要特征进行横向拓展,在某一竞争层上将其聚为一个样本子集,然后再根据样本子集内部的次要特征,在下一个竞争层对某些样本子集做进一步的划分<sup>[26]</sup>。由于混合像元、高层云/雨层云、卷层云和层积云/高积云在轮廓上比较相似,晴空陆地和晴空海面在温度上比较接近,根据这 2 个主要特征,GHSOM 网络在初始分类时分别将其划分成一类,这样经过第 1 层的粗糙分类后,360 个云类样本被划分成 4 大类,分别是积雨云、密卷云、晴空陆地和海面,混合像元、高层云/雨层云、卷层云和层积云/高积云。

由于待检测分类样本具有 6 个特征值向量,样本维度比较高、特征复杂。GHSOM 采用自适应纵向拓展,在接下来的第 2 层继续对数据进行细分。首先对经过横向拓展分类后的各个神经元进行判断,看其是否符合全局结束条件  $qe_i < \tau_2 \times qe_0$ 。将不满足全局结束条件的样本抽选出来,组成一个新的样本,重新构建 SOM 网络(即 GHSOM 网络的第 2 层),进行再次分类。经过纵向拓展分类后,GHSOM 在网络的

待分类检测样本与夜间 SOM 型相同。实验数据是从 2010 年 8 月 7 日 00:00 时的 FY-2E 红外云图中提取出来的,共计对 360 个云分类样本进行测试。初始化 GHSOM 网络的各项参数,取  $\tau_1 = 0.5$ ,  $\tau_2 = 0.01$ ,每个竞争层最大迭代次数  $\lambda$  等于 50。将 360 个云类样本输入 GHSOM 中,直到迭代 50 次为止。图 5 所示是夜间 FY-2E 拍摄的 IR1 通道红外云图。

第 2 层将混合像元、高层云/雨层云、卷层云和层积云/高积云成功地被分成 5 类,晴空陆地和海面成功地被分成 2 类。经过 2 层的样本粗分和细分后,GHSOM 网络模型将夜间云图分成 8 个种类。

夜间 GHSOM 网络模型云图识别效果如表 4 所示,将其与 SOM 网络模型夜间和白天云图分类结果进行比较。表 4 中,在网络的第 2 层进一步挖掘晴空陆地和海面的纹理特征信息,两者被成功地区分开来,晴空陆地的识别率达到了 75%,比表 2 高出了 22.7%。在密卷云和积雨云的识别上,由于两者的特征信息比较明显,在 GHSOM 网络的第 1 层就已经成功地识别出来,分类准确率分别达到了 90% 和 100%。表 4 中,卷层云和混和像元混分的现象明显降低,63 个卷层云样本中,只有 4 个样本被错误地划分成混合像元,比表 3 中少了 9 个样本,卷层云的识别程度提高到 93.7%,分类效果大大改进。在当前样本下,表 4 中高积云的识别率达到了 100%。其他类型云的识别率也都相应地得到了提高,云图整体识别率达到了 93.5%,比表 3 中 SOM 分类准确率高出了 28.9%,分类结果明显优于 SOM。

表4 夜间00:00时 GHSOM 云分类结果

类别	海面	陆地	混合	高层云	卷层云	密卷云	积雨云	高积云	识别率/%
海面	30	0	0	0	0	0	0	0	100.0
陆地	9	27	0	5	0	0	0	0	75.0
混合	0	0	30	0	3	1	0	3	83.3
高层云	0	0	0	31	0	0	0	0	86.1
卷层云	0	0	4	1	59	3	0	7	93.7
密卷云	0	0	0	0	0	36	0	0	90.0
积雨云	0	0	0	0	0	0	64	0	100.0
高积云	0	0	0	3	1	0	0	56	100.0

### 3 结束语

本文针对夜间云图分类准确率不够高的问题,做了进一步的探索和研究,并从理论和分类效果两个方面对 GHSOM 网络和 SOM 网络的云图识别情况进行对比分析.从上述实验可以看出,采用 GHSOM 这种分层次的分类方法,大大地提高了夜间静止卫星云图分类的准确率.综合比较得出,GHSOM 网络模型无论从结构上,还是分类效果上,均明显优于传统的 SOM 网络模型,可以推广应用于夜间云图分类当中.

致谢:感谢国家气象中心免费提供 FY-2E 卫星云图数据,感谢国家自然科学基金的支持和帮助.

### 4 参考文献

- [1] 吴咏明,张韧,蒋国荣,等.多光谱卫星图像的一种模糊聚类方法[J].热带气象学报,2004,20(6):689-696.
- [2] 张韧,王海俊,孙照渤,等.双光谱卫星云图的模糊推理云分类[J].防灾减灾工程学报,2004,24(3):257-263.
- [3] 陈晓颖,宋爱国,李建清,等.地基云图云状识别技术及其研究进展[J].自动化技术与应用,2014,33(9):1-6.
- [4] 尹跃. FY-2C 资料对西北太平洋海域云分类的研究[D].北京:北京大学,2008:1-5.
- [5] Desbois M, Seze G, Szejwach G. Automatic classification of clouds on METEOSAT imagery [J]. Journal of Applied Meteorology, 1981, 21(21):401-412.
- [6] Ameer Z, Ameer S, Adane E A, et al. Cloud classification using the textural features of Meteosat images [J]. Remote Sensing, 2004, 25(4):4491-4503.
- [7] Berendes T, Mecikalski J, Mackenzie W, et al. Convective cloud identification and classification in daytime satellite imagery using standard deviation limited adaptive cluster-

ring [J]. Journal of Geophysical Research, 2008, 113(20):1-9.

- [8] Berendes T A, Kuo K S, Logar A, et al. A comparison of paired histogram, maximum likelihood, class elimination, and neural network approaches for daylight global cloud classification using AVHRR imagery [J]. Journal of Geophysical Research, 1999, 104(D6):6199-6213.
- [9] 黄招娣,应宛月,余立琴,等.基于 PSO 的神经网络优化证券投资组合方法研究[J].华东交通大学学报,2013,30(2):42-46.
- [10] Bankert R. Cloud classification of AVHRR imagery in maritime regions using a probabilistic neural network [J]. Journal of Applied Meteorology, 1994, 33(8):909-918.
- [11] Ahmed T. A system based on ratio images and quick probabilistic neural network for continuous cloud classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(12):1196-1203.
- [12] 石小云.基于神经网络方法的卫星图像云分类[D].青岛:中国海洋大学,2012:50-52.
- [13] Liu Yu, Xia Jun, Shi Chunxiang, et al. An improved cloud classification algorithm for China FY-2C multi-channel images using artificial neural network [J]. Sensors, 2009, 9(7):5558-5579.
- [14] Tian B, Shaikh M, Azimi-Sadjadi M, et al. A study of cloud classification with neural networks using spectral and textural features [J]. IEEE Transactions on Neural Networks, 1999, 10(1):138-151.
- [15] Christodoulou C, Silas C, Constantinou S, et al. Multifeature texture analysis for the classification of clouds in satellite imagery [J]. IEEE Transactions on Geosciences and Remote Sensing, 2003, 41(11):2662-2668.
- [16] 王振,李朝锋,吴小俊. GHSOM 在遥感图像分割中的应用[J].计算机工程与应用,2010,46(16):188-190.
- [17] 阳时来,杨雅辉,沈晴霓,等.一种基于半监督 GHSOM 的入侵检测方法[J].计算机研究与发展,2013,50(11):2375-2382.
- [18] 顾一鸣.基于自组织映射的故障诊断方法[D].杭州:浙江大学,2006:24-28.
- [19] 段文影,朱敏.基于粗糙集和自组织神经网络的聚类方

(下转第 410 页)

- [J]. *Int J Hydrogen Energy* 2011 36(12): 7051-7065.
- [32] Du Yeshuang, Cao Nan, Yang Lan, et al. One-step synthesis of magnetically recyclable rGO supported Cu@Co core-shell nanoparticles: highly efficient catalysts for hydrolytic dehydrogenation of ammonia borane and methylamine borane [J]. *New J Chem* 2013 37(10): 3035-3042.
- [33] Patel N, Fernandes R, Gupta S, et al. Co-B catalyst supported over mesoporous silica for hydrogen production by catalytic hydrolysis of Ammonia Borane: A study on influence of pore structure [J]. *Appl Catal B-Environ* 2013 140/141: 125-132.
- [34] Lu Zhanghui, Li Jinping, Zhu Aili, et al. Catalytic hydrolysis of ammonia borane via magnetically recyclable copper iron nanoparticles for chemical hydrogen storage [J]. *Int J Hydrogen Energy* 2013 38(13): 5330-5337.

## 沸石咪唑酯骨架结构材料 Co-ZIF-9 催化氨硼烷水解制氢

黄 维 胡 娜 桂 田\* 张 飞 陈祥树\*

(江西师范大学化学化工学院 江西省无机膜材料工程技术研究中心 江西 南昌 330022)

**摘要:** 采用溶剂热方法合成了沸石咪唑酯骨架结构材料 Co-ZIF-9, 并将其用于非均相催化氨硼烷水解放氢实验. 结果表明: 配位的 Co-ZIF-9 在室温下能够有效地催化氨硼烷放出氢气, 且其催化活性远高于 Co 纳米粒子. Co-ZIF-9 的多孔结构在催化中起了很大的作用. 另外, Co-ZIF-9 催化水解氨硼烷的活化能约为  $40.8 \text{ kJ mol}^{-1}$ , 低于多数用于该催化实验的其他催化剂, 表明所合成的沸石咪唑酯骨架结构材料 Co-ZIF-9 具有优越的催化性能.

**关键词:** 氨硼烷; 沸石咪唑酯骨架; 溶剂热法; 水解; 制氢

(责任编辑: 刘显亮)

(上接第 388 页)

- 法 [J]. *江西科学* 2009 27(4): 569-571.
- [20] 李颖. 基于神经网络的军事目标识别方法研究 [D]. 沈阳: 沈阳理工大学 2005: 10-25.
- [21] 张利华, 马均钊, 勒国庆, 等. 基于 BP 神经网络的仓储烟草霉变预测 [J]. *华东交通大学学报* 2013 30(3): 71-75.
- [22] 刘扬. 基于静止气象卫星云图的分类研究 [D]. 青岛: 中国海洋大学 2011: 15-17.
- [23] 郭胜, 徐智勇. 基于数字地球的 3 维云图实现技术 [J]. *首都师范大学学报: 自然科学版* 2013 34(2): 70-73.
- [24] 欧阳怡彪. 空间数据挖掘的聚类方法与应用 [D]. 成都: 电子科技大学 2006: 59-76.
- [25] 廖广兰, 史铁林, 刘世元, 等. 基于 GHSOM 网络的故障识别 [J]. *华中科技大学学报: 自然科学版* 2008 36(7): 105-107.
- [26] 刘强. 人工神经网络方法在人脸检测和数据挖掘中的应用 [D]. 成都: 电子科技大学 2005: 55-65.

## The GHSOM Network Cloud Classification Model of Stationary Satellite Infrared Cloud Images at Night

YAN Tingya, WANG Shan\*

(School of Information Engineering, East China Jiaotong University, Nanchang Jiangxi 330013, China)

**Abstract:** Aiming at the low accuracy of cloud classification at night, the features of FY-2E cloud images which include bright temperatures and split window values were extracted and selected based on the method of singular value decomposition. The neural network models of growing hierarchical self-organizing map (GHSOM) and self-organizing map (SOM) were built separately to classify cloud images at night, meanwhile, contrasting the classified effect of the two network models. The experiments results showed that GHSOM network can improve the distinguishing effect of cloud images at night greatly through hierarchical classified method, and the average accuracy of cloud classification results is higher than SOM.

**Key words:** growing hierarchical self-organizing map; self-organizing feature map; night cloud image; cloud classification

(责任编辑: 冉小晓)