

广义 LVQ 算法及其在遥感影像分类中的应用研究

刘伟^① 崔宝侠^②

^①(山东工商学院信息与电子工程学院 烟台 264005)

^②(沈阳工业大学系统工程研究所 沈阳 110023)

摘要 在比较了学习矢量量化 (LVQ)算法和广义学习矢量量化(GLVQ)算法的基础上,建立了基于 GLVQ 的遥感影像分类模型。以实际土地覆盖分类为例,通过与传统统计方法和 LVQ 分类器比较, GLVQ 分类器具有分类正确率高,收敛速度快,适应范围广等优点。

关键词 遥感影像分类, 学习矢量量化(LVQ), 广义学习矢量量化(GLVQ)

中图分类号: TP753

文献标识码: A

文章编号: 1009-5896(2006)07-1201-03

The Remote Sensing Image Classification Based on Generalized Learning Vector Quantization Algorithm

Liu Wei^① Cui Bao-xia^②

^①(Shandong Institute of Business and Technology, Yantai 264005, China)

^②(System Engineering Institute, Shenyang University of Technology, Shenyang 110023, China)

Abstract After comparing Learning Vector Quantization (LVQ) algorithm and Generalized Learning Vector Quantization (GLVQ) algorithm, this paper establishes a GLVQ-based classification model for remote sensing image. With the experimental applications of land-over classification with the presented model, the GLVQ classifier has higher recognition rate, faster convergence speed and wider adaption range than conventional classifier and LVQ classifier.

Key words Remote sensing image classification, Learning Vector Quantization(LVQ), Generalized Learning Vector Quantization (GLVQ)

1 引言

从本世纪 70 年代起, 遥感影像分类处理一直是遥感技术及相关领域学者所关注的问题。目前在遥感影像分类中, 主要采用的分类方法是统计模式识别法, 模糊数学分类法, 句法模式识别法等等。近年来, 人工神经网络(ANN)方法已经成为国际遥感数据分类的研究热点。神经网络方法在以下几个方面优于基于统计的传统分类方法: 不需要参数估计和假设数学模型, 抗噪声能力强, 可以学习多重复杂的模式等, 有利于解决遥感影像分类中的“同物异谱”、“同谱异物”现象。目前采用的神经网络主要有BP, Hopfield, ART, LVQ 及自组织特征映射模型等等^[1]。

学习矢量量化(Learning Vector Quantization, LVQ)算法是由Kohonen提出的^[2]。但是LVQ算法有两个缺点: (1)存在未被充分利用的神经元; (2)输入样本与竞争单元之间的信息被浪费^[3]。为解决上述问题, Pal等提出了一种广义的学习矢量量化(GLVQ)网络^[4]。本文首先回顾了LVQ和GLVQ算法, 然后在GLVQ算法的基础上, 提出了GLVQ非监督和监督遥感影像分类模型, 并以实际地区的土地覆盖分类为例, 对GLVQ分类器和传统统计分类器以及LVQ分类器进行了比较。

2 算法分析

2.1 LVQ 算法

学习矢量量化(LVQ)算法是 Kohonen 提出用于模式分类的一种有监督的学习算法。它允许对输入被分到哪一类进行指定。LVQ 网络结构由输入层和输出层组成。输入层接受输入样本, 输出层为竞争层, 它对输入样本进行聚类。这两层的神经元之间全互连连接。LVQ 算法基本步骤为:

(1)设输入矢量为 $\mathbf{X} = [x_1, x_2, \dots, x_p]^T$, 输出层神经元 j 的权值矢量为每次输入一个矢量 \mathbf{X} 后, 在输出阵列中寻找与 \mathbf{X} 有最近匹配的神经元, 用 i 表示;

(2)设 \mathbf{X} 所属类别已知为 r , 而在第一阶段学习中神经元 i 的类别为 C_i , 则

如果 $r = C_i$

$$\mathbf{W}_i(t+1) = \mathbf{W}_i(t) + \eta(t)[\mathbf{X} - \mathbf{W}_i(t)] \quad (1)$$

如果 $r \neq C_i$

$$\mathbf{W}_i(t+1) = \mathbf{W}_i(t) - \eta(t)[\mathbf{X} - \mathbf{W}_i(t)] \quad (2)$$

式中 $\eta(t)$ 为学习步长。

从上述 LVQ 算法可以看出, 对每个输入矢量, LVQ 算法仅对最优匹配单元进行权值的更新, 因而存在部分未被充分利用的神经元, 而且输入样本和部分竞争神经元的的信息被浪费了, 即每次迭代所计算的的距离信息部分被弃之不用, 相对增加了计算量。

2.2 GLVQ 算法

基于 LVQ 算法的上述缺点, Pal 等 1993 年提出了广义的 LVQ 算法(GLVQ)。GLVQ 算法的学习规则是从最优化一个目标函数导出的。对给定的输入矢量, GLVQ 算法更新竞争层所有神经元权值。设有一组 n 个样本, 特征空间为 p 维, 即 $\mathbf{X} = \{X_1, X_2, \dots, X_n\}$, 用 i 表示最优匹配神经元的标号, 定义如下损失函数 L_x :

$$L_x = L(\mathbf{X}; \mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_c) = \sum_{r=1}^c g_{ir} \|\mathbf{X} - \mathbf{W}_r\|^2 \quad (3)$$

$$\text{其中 } c \text{ 为类别数, } g_{ir} = \begin{cases} 1, & r = i \\ \frac{1}{\sum_{j=1}^c \|\mathbf{X} - \mathbf{W}_j\|^2}, & r \neq i \end{cases}$$

目的是找到 c 个聚类中心 \mathbf{W}_r , $\mathbf{W} = \{\mathbf{W}_r\}$ 使得损失函数 L_x 的期望值 $\Gamma(\mathbf{W})$ 达最小, 即使

$$\Gamma(\mathbf{W}) = \frac{\sum_{k=1}^n \sum_{r=1}^c g_{ir} \|\mathbf{X}_k - \mathbf{W}_r\|^2}{n} \quad (4)$$

达最小, 可用梯度下降法解决这一寻优问题。GLVQ 算法的步骤可归纳如下:

(1) 给定一组未标识的数据 $\mathbf{X} = \{X_1, X_2, \dots, X_n\} \in \mathbf{R}^p$, 类别数为 c 。迭代次数为 T , 允许误差 $\varepsilon > 0$ 。

(2) 初始化 $\mathbf{W}_0 = (W_{10}, W_{20}, \dots, W_{c0})$ 及初始学习步长 α_0 。

(3) 对于 $t=1, 2, \dots, T$, 计算 $\alpha_t = \alpha_0(1-t/T)$; 对于 $k=1, 2, \dots, n$, 找出 $\|\mathbf{X}_k - \mathbf{W}_i(t)\| = \min_{1 \leq j \leq c} \|\mathbf{X}_k - \mathbf{W}_j(t)\|$, 并按照下式修正所有 c 个权向量 $\{\mathbf{W}_r(t+1)\}$:

$$\mathbf{W}_i(t+1) = \mathbf{W}_i(t) + \alpha_t [\mathbf{X}_k - \mathbf{W}_i(t)] \cdot \frac{D^2 - D + \|\mathbf{X}_k - \mathbf{W}_i(t)\|^2}{D^2}, \quad r = i \quad (5)$$

否则

$$\mathbf{W}_r(t+1) = \mathbf{W}_r(t) + \alpha_t [\mathbf{X}_k - \mathbf{W}_r(t)] \frac{\|\mathbf{X}_k - \mathbf{W}_r(t)\|^2}{D^2} \quad (6)$$

这里 $D = \sum_{r=1}^c \|\mathbf{X}_k - \mathbf{W}_r(t)\|^2$ 。

(4) 计算

$$E_t = \|\mathbf{W}(t+1) - \mathbf{W}(t)\|_1 = \sum_{r=1}^c \|\mathbf{W}_r(t+1) - \mathbf{W}_r(t)\|_1 \\ = \sum_{k=1}^n \sum_{r=1}^c |w_{rk}(t+1) - w_{rk}(t)| \quad (7)$$

(5) 若 $E_t \leq \varepsilon$, 则停止, 否则对下一个 t , 重新计算。

(6) 计算最近标本下对 \mathbf{X} 的 c 的划分: $\mathbf{U} = [u_{ik}]_{c \times n}$, 其中

$$u_{ik} = \begin{cases} 1, & \|\mathbf{X}_k - \mathbf{W}_i\| \leq \|\mathbf{X}_k - \mathbf{W}_j\|, 1 \leq j \leq c, j \neq i \\ 0, & 1 \leq j \leq c, 1 \leq k \leq n, \text{ 其他} \end{cases} \quad (8)$$

Pal 等运用 GLVQ 算法在著名的 IRIS 数据上采用不同的

初始化方法做了仿真。实验结果表明, GLVQ 算法对初值不敏感, 独立于学习因子, 不同的条件下均能给出合理的结果, 而 LVQ 算法则不然。

3 基于 GLVQ 算法的遥感影像分类模型

本文将 GLVQ 算法运用于遥感影像分类, 并建立了基于 GLVQ 分类器的遥感影像分类模型。GLVQ 算法实质上是一种高效的非监督聚类算法, 对于未知类别的数据样本 X , GLVQ 算法的结果只是把数据样本 X 聚类成 c 个类别。为了用于识别, 可以对这 c 个聚类中心加以监督学习, 就可以把该中心所代表的所有数据都归入中心所属类别。GLVQ 分类器分类流程如下:

(1) 数据准备: 在给定训练样区提取数据集作为 GLVQ 分类器的训练样本, 并把这个数据集随机等分成两个数据集 A 和 B 。数据集 A 和 B 形式都为: $\{(X_1, C_1), (X_2, C_2), \dots, (X_n, C_n)\}$, n 为训练样本数, C_n 为 X_n 代表类别。

(2) GLVQ 网络结构初始化: 设定神经网络输入层神经元数目(即 X 的维数), 输出神经元数目(即类别数), 最大迭代次数 T , 允许误差 ε , 初始聚类中心 \mathbf{W}_0 (可从训练样本集中随机选取), 初始学习步长 $\alpha_0 \in (0, 1)$ 。

(3) 非监督学习过程: 利用数据集样本 A , 按照 2.2 节所述 GLVQ 聚类算法进行非监督学习类别样本, 最后形成 c 个聚类中心。

(4) 监督学习并标识神经网络输出层过程: 将已知类别的数据样本集 B 送入已经非监督学习好的神经网络中, 对 c 个权值向量作进一步的精细调整, 同时根据文献[4]提出的标识算法(Relabeling algorithm)对网络输出层进行标识。

(5) 分类识别过程: 经过非监督的聚类和 supervised 的学习之后, 最终形成的分类器网络就可以拿来对整个数据进行分类和识别了。给定一个未知类别的样本, 网络的竞争输出就代表它的归属类别。

4 实例及结果分析

本文选取了武汉市区的 7 波段的 TM 遥感影像作为试验图像, 选取的研究区域为 2048×2048 的像元子区, 地面分辨率为 30m。该地区的地形比较复杂, 土地利用类别主要是水域、城镇区、道路、农田及裸地。为减少数据量, 将 TM1, TM2, TM3 3 个波段作主成分分析, 取第 1、第 2 主成分和 TM4, TM5, TM7 波段作为网络输入数据。

通过目视解译, 利用实地考察结果并辅以当地的实际土地利用图以及 543 假彩色合成影像, 把该地区初步分为 6 大地类: C1(河流), C2(湖泊), C3(城镇区), C4(道路), C5(农田), C6(裸地)。其中类别(C1, C2), (C3, C4) 的光谱特征较为相近。并在 TM 卫星数据上选取了训练和测试样本集。表 1 是试验用训练和测试样本点数据集的构成描述。

表1 训练数据集和测试样本集描述
Tab.1 The description of training datasets and testing datasets

| 类别号 | 1 | 2 | 3 | 4 | 5 | 6 | 总计 |
|-------|------|------|------|------|------|------|-------|
| 土地类型 | 河流 | 湖泊 | 城镇区 | 道路 | 农田 | 裸地 | |
| 训练数据集 | 2400 | 3210 | 3300 | 4500 | 2000 | 2500 | 17910 |
| 测试数据集 | 620 | 850 | 720 | 960 | 560 | 580 | 4290 |

GLVQ 分类器的主要参数可设置为: 网络为两层结构, 输入层 5 个神经元, 输出层 6 个神经元; 最大迭代次数 5000 次, 允许误差 ε 为 0.001, 学习步长 $\alpha_0=0.5$ 。为了比较, 利用同样网络结构的 LVQ 分类器和传统的最大似然分类器 (Maximum Likelihood Classifier, MLC) 对相同的数据进行分类, 并对分类结果进行了比较。表 2 是各分类方法在相同测试数据集下的 Kappa 系数、总精度的比较结果。表 3 为各方法的分类正确率。

从表 2 中的比较结果可以看出, 在相同的测试条件下, GLVQ 分类器总的性能要明显高于 MLC 和 LVQ 分类器。而从表 3 的分类正确率比较中分析, GLVQ 分类器在各类别上的分类正确率要全面优于 MLC 和 LVQ 分类器。

表 2 各分类器比较结果
Tab.2 Comparison of three classifiers performance

| | Kappa 系数 | 总体精度(%) |
|------|----------|---------|
| MLC | 0.852 | 86.80 |
| LVQ | 0.840 | 86.78 |
| GLVQ | 0.880 | 90.50 |

表 3 各分类方法分类正确率(%)
Tab.3 Comparison of classifier's accuracy(%)

| | 河流 | 湖泊 | 城镇 | 道路 | 裸地 | 农田 |
|------|----|----|----|----|----|----|
| MLC | 91 | 90 | 86 | 79 | 84 | 90 |
| LVQ | 93 | 91 | 87 | 80 | 80 | 89 |
| GLVQ | 96 | 92 | 89 | 85 | 86 | 91 |

值得注意的是, 由于LVQ算法仅考虑了最优匹配神经元的权值更新, 而且其最后收敛结果与初值的设定有很大关系, 因此本文采用的LVQ分类器总的性能反而略低于传统的统计分类方法。表 4 是在相同网络结构和初始参数下GLVQ和LVQ分类器性能的比较。其中初始化权值向量 W_{01} 为[0, 1]之间的随机数, W_{02} 是从样本数据中随机抽取的(归一化到[0,1]区间)。

表 4 的数据反映出, GLVQ 分类器对初值不敏感, 不同

参数条件下均有较高正确率, 而且收敛速度较 LVQ 分类器提高了一倍多, 因此 GLVQ 网络一旦训练好之后, 其分类适应性强, 适用范围广。

表 4 不同初值和 α_0 下分类器性能比较
Tab. 4 Performance under different initialization and α_0

| W_0 | α_0 | GLVQ | | LVQ | |
|----------|------------|---------|----------|---------|----------|
| | | 训练时间(s) | 平均正确率(%) | 训练时间(s) | 平均正确率(%) |
| W_{01} | 0.4 | 45 | 89.83 | 110 | 84.50 |
| | 0.5 | 48 | 90.10 | 115 | 83.35 |
| | 0.6 | 46 | 89.85 | 105 | 83.92 |
| W_{02} | 0.4 | 46 | 90.05 | 95 | 85.55 |
| | 0.5 | 46 | 90.15 | 100 | 86.67 |
| | 0.6 | 45 | 89.90 | 98 | 87.32 |

5 结束语

本文将广义的学习矢量量化算法(GLVQ)引入到遥感影像分类领域, 并建立了 GLVQ 遥感影像分类模型, 并以实际地区的土地覆盖分类为例, 与传统的最大似然分类器和 LVQ 分类器进行了综合比较, 认为 GLVQ 分类器在分类正确率、收敛速度以及适用范围上具有一定优势, 随着卫星遥感技术的发展, 遥感影像的空间分辨率和光谱分辨率将不断提高。对图像分类来说, 由于 GLVQ 神经网络分类法不要求训练数据满足高斯统计分布, 使得神经网络比传统的分类方法在输入数据类型上要广泛得多, 如多时相数据、多传感器数据等。另外, 尽管 GLVQ 法的训练过程相当耗时, 但一旦完成充分的训练, 将可以以较快的速度来进行分类, 因此可以推广为一种有效的遥感影像分类方法。

参考文献

[1] 阎平凡, 张长水编著. 神经网络与模拟进化计算[M]. 北京: 清华大学出版社, 2000: 1-5.
 [2] Kohonen T. The self-organizing map[J]. *Pro. IEEE*, 1990, 78(9): 1464-1480.
 [3] Chung F L, Lee T. Fuzzy competitive learning[J]. *Neural Networks*, 1994, 7(3): 539-551.
 [4] Pal N R, et al.. Generalized clustering networks and Kohonen's self-organizing schemes[J]. *IEEE Trans. on Neural Networks*, 1993, 4(4): 549-557.

刘伟: 男, 1977年生, 助教, 目前从事图像处理与模式识别, 过程控制等方面的研究。
 崔宝侠: 女, 1962年生, 教授, 主要研究方向为地理信息系统, 过程控制等。