

# 用于矢量量化的神经网络竞争学习算法

徐 勇 陈贺新 戴逸松

(长春邮电学院, 长春 130012)(吉林工业大学, 长春 130025)

**摘 要** 对典型的竞争学习算法进行了研究和分析, 提出了一种基于神经元获胜概率的概率敏感竞争学习算法(PSCL)。与传统竞争学习算法只有一个神经元获胜而得到学习不同, PSCL 算法按照各神经元的获胜概率并通过调整对失真距离的调整使每个神经元均得到不同程度的学习, 可以有效地克服神经元欠利用问题。

**关键词** 神经网络, 竞争学习, 矢量量化, 神经元欠利用, 算法

## 1 引 言

根据 Shannon 的“率失真理论”, 矢量量化(VQ)在数据压缩编码方面能获得优于其它标量化编码技术的性能, 且矢量维数越大性能越好, 因此受到人们的广泛重视和深入研究<sup>[1]</sup>。矢量量化的研究目的是针对特定的信息源和矢量维数, 找到一种最优的矢量量化器, 使之能够在一定的量化速率下保持最低的失真。VQ 系统是否能具有较低的失真从而具有较高的质量, 关键在于优质的码书设计和高效的快速搜索算法, 前者则更为重要。从模式识别的角度看, 矢量量化相当于一个聚类过程, 码书设计与聚类分析的目的和实质是一致的。由于人工神经网络竞争学习算法的一项非常重要的功能是通过学习实现对输入矢量的分类, 与 VQ 的功能十分相近, 所以用神经网络的竞争学习(CL, Competitive Learning)功能实现矢量量化成为目前矢量量化技术一个新的研究热点<sup>[2~5]</sup>。本文研究了神经网络竞争学习算法的一般描述及其神经网络结构, 以及竞争学习算法在矢量量化的应用; 从定义神经元获胜的概率因子出发, 提出一种概率敏感竞争学习算法, 这种算法不仅具有优良的聚类性能, 而且可以克服神经元码矢欠利用问题。

## 2 竞争学习算法

神经网络竞争学习算法是典型的无监督学习策略, 仅需给定输入模式集作为训练集, 网络自行组织训练模式, 并进行输入模式的类别划分。在用 CL 算法进行矢量量化中, 每个重构矢量对应一个神经元, 每个神经元的权矢量即为 VQ 中的重构矢量。网络模型通常为一个多层前馈网络, 其隐层按某一失真测度在输入矢量集的训练下完成调整。设输入矢量  $\mathbf{X} = (x_1, x_2, \dots, x_k) \in R^k$ , 每个神经元  $i$  对应于一个权矢量  $\mathbf{W}_i = (w_{i1}, w_{i2}, \dots, w_{ik}) \in R^k$ , 失真测度为  $d(\mathbf{X}, \mathbf{W}_i)$ , 获胜神经元为  $C$ , 基本竞争学习算法可以概括描述如下:

(1) 初始化 设置竞争神经元个数  $N$  (即为码书中码矢个数), 赋各权值矢量  $\mathbf{W}_i(0)$  ( $i = 1, 2, \dots, N$ )。

(2) 给出输入矢量  $\mathbf{X}$ 。

(3) 距离计算 对于输入矢量  $\mathbf{X}$ , 计算其与全部神经元的距离(失真测度)

$$d_i = d(\mathbf{X}, \mathbf{W}_i) \quad i = 1, 2, \dots, N \quad (1)$$

不同的算法可以采用不同的公式计算  $d_i$ 。一般地, 采用欧氏距离

$$d_i = d(\mathbf{X}, \mathbf{W}_i) = \|\mathbf{X} - \mathbf{W}_i\|^2 =$$

$$\sum_{j=1}^k (x_j - w_{ij})^2 \quad (2)$$

(4) 神经元竞争 以失真距离最小确定获胜神经元  $C$ 。即

$$d_c = \min_{1 \leq i \leq N} \{d_i\} \quad (3)$$

(5) 学习 即修改获胜神经元的权矢量

$$W_c(t+1) = W_c(t) + \alpha(t)[X - W_c(t)] \quad (4)$$

其中,  $\alpha(t)$  为学习速度函数, 是时间的单调递减函数, 且  $0 \leq \alpha(t) < 1$ 。

(6) 结束 重复步骤 (2)~(5), 直到完成规定的学习次数或满足给定的终止条件为止。

竞争学习算法用于矢量量化的神经网络结构如图 1 所示。三层前馈网络的第 1 层为输入层, 用于并行输入训练矢量, 第 2 层计算输入矢量与神经元权矢量之间的距离, 由第 3 层选择距离最小的神经元。在矢量量化中神经元权矢量对应与码书中的各码矢, 网络按一定的学习规定调整神经元码矢, 随输入矢量空间的概率分布进行自适应聚类, 完成矢量量化任务。




图 1 竞争学习神经网络

Fig. 1 Competitive learning neural network

### 3 概率敏感竞争学习算法

#### 3.1 竞争学习算法分析

根据基本 CL 算法, 对于每一个输入矢量, 只有一个神经元的权矢量得到调整, 即只有一个神经元在竞争中获胜, 这就是所谓的“胜者取全部”(Winner-take-all rule) 规则。这种学习机制存在两个主要缺点: 一是神经元(码矢)欠利用问题<sup>[6]</sup>, 如距离训练矢量集的较远的码矢所对应的神经元获胜机会小, 可能得不到学习; 文献[7]指出胜者取全部训练过程的另一缺点是会因为其它输入矢量和神经元在竞争中被“抑制”而浪费有用的信息。因此, 如果权矢量初值选择不当, 就会严重影响码矢的质量。Koh-

nen 的自组织特征映射算法(SOFM)尽管在性能上优于 LBG 算法, 但在码矢初值及邻域函数选取不当, 也会产生神经元欠利用现象。为解决上述问题, 文献[8]、[9]将一种所谓的“良知”(Conscience)学习机制引入 CL 算法中, 后来被发展为频率敏感(Frequency-Sensitive)竞争学习算法(FSCL)<sup>[6]</sup>。另外, 文献[10]提出了模糊竞争学习算法(FCL)。解决竞争学习算法在矢量量化中码矢欠利用问题的基本思想是调整训练过程中神经元获胜机会, 尽可能使每个神经元码矢都得到调整, 使码书能最接近地表征输入矢量空间的概率分布。

#### 3.2 概率敏感竞争学习算法

如上所述, 基本竞争学习算法由于只有获胜的神经元得到学习, 则产生了神经元码矢欠利用问题, 影响了码书中部分码矢的利用效率。针对该问题, 我们提出了一种基于神经元获胜概率的概率敏感竞争学习算法(PSCL)。在 PSCL 算法中, 对神经元的获胜“模糊化”, 竞争学习中没有明确的“获胜”神经元, 不仅对于输入矢量失真最小的神经元得到调整, 其它神经元根据失真大小也得到调整。神经元调整程度用获胜概率因子表示, 定义为:

$$P_i(t) = \frac{e^{-\lambda(t)d[X, W_i(t)]}}{\sum_{j=1}^N e^{-\lambda(t)d[X, W_j(t)]}} \quad i = 1, 2, \dots, N \quad (5)$$

其中,  $d[X, W_i(t)] = \|X - W_i(t)\|^2$ ,  $\lambda(t)$  为一随时间  $t$  单调上升的函数, 且  $\lim_{t \rightarrow \infty} \lambda(t) = \infty$ 。可见, 神经元码矢与输入矢量距离越近,  $P_i(t)$  越大, 反之越小。将  $P_i(t)$  与失真相关联, 失真测度修改为:

$$d_i^*[X, W_i(t)] = d_i[X, W_i(t)] \cdot u_i(t-1) \quad (6)$$

其中

$$u_i(t-1) = \sum_{l=1}^{t-1} P_i^m(l) \quad (7)$$

$m$  为敏感度参数,  $m \geq 1$ , 一般取  $m = 1.25 \sim 1.75$ 。

综上所述, 本文提出的 PSCL 算法可以描述如下:

- (1) 设置初始神经元权矢量  $W_i(0)$ ,  $i = 1, 2, \dots, N$ 。
- (2) 输入训练矢量  $X(t)$
- (3) 计算失真测度

$$u_i(t-1) = \sum_{l=1}^{t-1} P_i^m(l)$$

$$d_i^*[X, W_i(t)] = d_i[X, W_i(t)] \cdot u_i(t-1)$$

- (4) 计算各神经元权矢量调整的概率因子

$$P_i(t) = \frac{e^{-\lambda(t)d[X_i, W_i(t)]}}{\sum_{j=1}^N e^{-\lambda(t)d[X_i, W_j(t)]}}$$

(5)按下式调整码矢

$$W_i(t+1) = W_i(t) + \alpha_i(t)P_i^n(t)[X - W_i(t)]$$

$$i = 1, 2, \dots, N$$

其中,

$$\alpha_i(t) = \frac{\alpha_0}{n_i(t)}, n_i(t) = n_i(t-1) + P_i(t),$$

$$n_i(0) = 1, 0 < \alpha_0 < 1$$

(6)对所有输入矢量重复步骤(2)~(5)。

根据上述训练算法,每个神经元在学习过程中按其对于输入矢量的距离远近得到不同程度的修改,可以有效地克服某些神经元欠利用问题,并充分利用了各神经元码矢与输入矢量之间距离的信息来控制学习过程。

在 PSCL 中,当  $\lambda(t) \rightarrow \infty$  时,

$$P_i(t) = \begin{cases} 1, & d_i = \min_{1 \leq j \leq N} \{d_j\} \\ 0, & j \neq i \end{cases}$$

此时,PSCL 与基本 CL 相当。当  $\lambda(t) = 0$  时,  $P_i(t) = 1/N, i = 1, 2, \dots, N$ , 和码矢与输入矢量的距离无关。当  $0 < \lambda(t) < \infty$  时,失真最小的码矢对应的调整概率  $P_i(t)$  最大,其码矢调整幅度也最大。 $\lambda(t)$  的最佳选取为  $\lambda(t) = c_1 \ln c_2 t$ 。另外,每个码矢对应于自己的  $\alpha_i(t)$ ,其学习速率不一样,调整量大的神经元调整步幅降得快,反之则慢。

### 4 实验结果和分析

为了分析本文所提出的 PSCL 算法的聚类及矢量量化的性能,以 4 类二维 Gaussian 分布输入模式训练具有 4 个输出单元的神经网络。用 C 语言编程,在 586 微机(8M/75)上运行。如图 2 所示,4 类输入模式的类中心分别为 (2.5, 7.4)、(8.3, 1.7)、(12.9, 6.7)和(6.9, 13.8),方差均为 1。每类包含 100 个样本矢量,且相互没有重叠。矢量量化码书尺寸为 4,初始码矢从输入训练模式中随机选取。最大训练次数设为 30。实验中, $\lambda(t) = \ln(\frac{t}{400})$ ,平均失真定义为

$$D = \frac{1}{n} \sum_{j=1}^n \|X_j - \hat{X}\| = \frac{1}{n} \sum_{j=1}^n \sqrt{\sum_{i=1}^k (x_{ji} - \hat{x}_{ji})^2}$$

其中,  $X, \hat{X}$  分别为 Gaussian 类中心和实验所得到的类中心,  $n$  为类中心数,  $k$  为类中心维数。图 2 同时示

出了用 PSCL 算法训练神经网络得到的 4 个类中心,从中可以看出所得到的类中心几乎与原输入模式类中心相同。在 20 次以不同初始码矢训练神经网络的实验中,4 个输出神经元均能正确收敛至输入模式的类中心,没有出现神经元欠利用问题。反复模拟的结果表明,由于 PSCL 网络中每个神经元都相应于获胜概率和失真动态调整获胜机会,PSCL 算法可以精确地收敛至所期望的 Gaussian 分布类中心(即矢量量化的码矢),有效地克服了神经元欠利用现象,提高了码书质量。

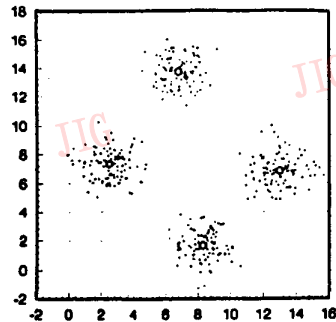


图 2 非重叠数据和聚类结果(码矢)

Fig. 2 The nonoverlapping cluster data sets and the cluster results(codevectors)

表 1 给出了几种竞争学习算法在同样训练条件下当训练次数为 5 时对上述数据聚类的平均失真及所需训练时间。可以看出,PSCL 算法具有较小的失真。此外,在模拟实验中还可以观察到,PSCL 算法比其它算法能更快地收敛于类中心,且对输入训练数据顺序不敏感。

表 1 聚类结果比较

Table 1 Comparison of the cluster results

算 法	BCL	SOFM	FSCL	FCL	PSL
平均失真	1.000 5	0.076 9	0.190 8	0.025 4	0.025 8
训练时间	0'48"97	1'07"65	0'47"38	0'34"84	0'34"78

对照上述非重叠数据集的实验方法,用类中心分别为(2.418, 2.173)、(2.865, 7.433)、(7.784, 2.528)和(6.772, 6.921),方差为 1 的重叠 Gaussian 分布数据集来训练 PSCL 网络。如图 3 所示,PSCL 算法对于重叠或模糊数据集同样能够获得满意的聚类性能。




图3 重叠数据和聚类结果(码矢)

Fig. 3 The overlapping cluster data sets and the cluster results (codevectors)

## 5 结 论

由于神经网络具有大规模并行处理及自适应等特性,与矢量量化相结合,既有助于形成高质量的码书,又自然地解决了快速搜索的问题。各种竞争学习算法在应用于矢量量化时,均致力于提高码书设计质量和提高码矢利用率上。本文提出的概率敏感竞争学习算法,在学习训练过程中所有权矢量都参与调整,调整幅度按概率因子计算,可以有效地解决码矢欠利用问题,同时又充分利用了与输入矢量距离的信息,重构矢量能更好地表征输入矢量的空间分

布特性。实验证明该算法用于矢量量化具有优良性能,可以广泛应用于语音、图象数据压缩及模式识别等领域。

## 参 考 文 献

- 1 Gershoand A, Gray R M. Vector quantization and signal compression, Norwell, MA:Kluwer, 1992.
- 2 Grossberg S. Adaptive pattern classification and coding of neural feature detectors. Biological Cybernetics, 1976, 23: 121~134.
- 3 Kohonen T. Self-organization and associative memory. New York: Spinger-Verlag, 1984.
- 4 Rumelhart D E, Zipser D. Feature discovery by competitive learning. Cambridge, MA: AIT Press, 1986.
- 5 Kosko B. Neural networks and fuzzy systems. Englewood Cliffs: Prentice Hall, 1992.
- 6 Ahalt S C, Krishnamurthy A K, Chen p et. al. Competitive learning algorithms for vector quantization. Neural Networks, et. al. 1990, 3: 225~290.
- 7 Clustering Daccaestecker c. Proceedings of International Networks Conference, 1990, 2: 833.
- 8 Desieno D. Adding a conscience to competitive learning. Proceedings of IEEE International conference on Neural Networks (San Diego), 1988, 1: 1117~1124.
- 9 Hecht-Nielsen R. Application to counterpropagation networks. Neural Networ 1988, 1(2): 13~141.
- 10 Chung F L, Lee T. Fuzzy Competitive learning. Neural Network, 1994, 7(3): 539~551.



徐勇, 长春邮电学院副教授, 中国电子学会高级会员。1984年7月毕业于湖南大学无线电技术专业, 获学士学位; 1990年6月获吉林工业大学通信与电子系统专业硕士学位; 现为吉林工业大学通信与电子系统专业在职博士生。主要从事信息处理、神经网络理论与应用和图象处理等领域的研究。

(下转 914 页)

# A Fast VQ Coding Method of Wavelet Tree-Structure

Yan Jingwen

(Dept. of Communication Engineering, Changchun Institute of Posts & Telecommunication, Changchun 130012)

Sun Hui, Zhang Shenghua

(The State Key Lab. of Applied Optics, Changchun Institute of Fine Mechanics & Optics, Changchun 130022)

**Abstract** A fast VQ image coding method based on humans visual attribution and applying wavelet tree-structure is proposed in this paper, naming tree-structure fast VQ coding. After the characteristics of VQ was analyzed, a statistic method generating a codebook was designed, and a fast VQ coding method was represented. This method can efficiently remove correlation in image data, obtaining a low transmission bit stream. The apparent advantage of the method is to establish statistics codebooks for various image data, and each treating need not generate codebooks with a high coding efficient achieved, while it can apply to any opportunity with wavelet transformation used in various image and signal data compression. The experimental results show: The fast VQ coding method proposed in this paper can achieve a compression ratio of 40 with a PSNR of 36. 21dB, while its total performance is superior to other methods, and a real-time compression using this method may be implemented.

**Keywords** Wavelet transformation, Data compression, Vector quantization.

(上接 904 页)

# Neural Network Competitive Learning Algorithms for Vector Quantization

Xu Yong, Chen Hexin\*, Dai Yisong\*

(Changchun Institute of Posts and Telecommunications Changchun, 130012)

(\* Jilin University of Technology, Changchun 130025)

**Abstract** Neural network competitive learning algorithms are widely used for vector quantization. In this paper, some typical competitive learning algorithms have been specially investigated and analyzed. A new competitive learning algorithm based on the neuron win probability is presented for vector quantization. Unlike the traditional competitive learning algorithms where only one neuron will win and learn at each competition, every neuron in the proposed probability-sensitive competitive learning algorithm (PSCL) will win to some extent, depending on its win probability and adjustment of distortion distance to the input vector. The new algorithm is shown to be efficient to overcome the problem of neuron underutilization.

**Keywords** Neural network, Competitive learning, Vector quantization, Neuron underutilization, Algorithm