

# 基于描述特征改进的 LVQ 神经网络 美元识别研究

## Dollar Recognition Based on Expressive Features and Improved LVQ

白明燕 贺建飏 (中南大学 信息科学与工程学院 湖南 长沙 410004)

**摘要:** 针对货币识别中残币、旧币、假币识别的难度大和正确性不高等问题,提出了一种基于描述特征的改进 LVQ 的神经网络的美元识别算法。该算法首先使用基于描述特征的主成分分析技术 (MEFFRA) 提取美元的主要特征,然后使用 MLVQ 神经网络进行识别。不仅降低了货币特征提取时的复杂度,同时也克服了 GLVQ 和 GLVQ-F 算法的性能不稳定和对初值敏感性的理论缺陷,是一种更加优化的有师学习算法。试验结果表明,把该算法用于美元识别,有很好的效果。

**关键词:** LVQ 神经网络 描述特征的主成分技术 MLVQ 算法 GLVQ-F 算法 美元识别

### 1 引言

货币的识别是比较复杂的,尤其是对于那些那些残币、污损币、旧币以及那些伪造技术逼真的假币。传统的方法对这些问题的解决能力不足,很多研究者转向机器学习方法。再加上货币比较容易获得,使得基于神经网络的货币识别成为近期主要的研究热点。F.Takeda、S.Omatu 等系统研究了神经网络进行货币识别的可行性问题<sup>[1-2]</sup>; A.Ahmadi、T.Kosaka 等先利用自组织神经网络将货币分为几个空间,然后使用主成分分析技术对每个空间信息进行优化,再使用 LVQ<sup>[3]</sup>(Learning Vector Quantization) 进行分类,试验表明此种方法对于识别意大利里拉面额有很好的效果<sup>[4-5]</sup>。在国内,张颖、陈雪波等结合三层 BP 神经网络来识别人民币<sup>[6]</sup>等等。但是,每一种方法都存在不足之处,主要体现在特征提取准确度和速度以及识别算法性能上。本文提出了一种基于描述特征的改进 LVQ 的神经网络的美元识别算法,它的优良性主要体现在:

先使用 MEFFRA 算法<sup>[7]</sup>首先把传感器所获得的

货币图像数据的右奇异向量作为主成分求解的货币图像子空间的基向量,避免了数据阵列转化成数据向量,使得协方差矩阵的大小明显得到了减少,大大降低了复杂性;然后使用 PCA 算法,减少了对内存空间的需求。

再使用 MLVQ 算法<sup>[8]</sup>进行识别。MLVQ 算法是一种改进的矢量量化学习算法。它解决 LVQ、GLVQ 等对初值敏感性<sup>[9]</sup>的问题。把亏损函数作为目标函数,对竞争元优化目标函数以确定学习因子,也提高了泛化能力。同时克服了 GLVQ、GLVQ-F 等算法的不稳定<sup>[10]</sup>。亏损函数和亏损因子的选取都有合理的理论依据。亏损函数实质的意义是能量函数,应根据能量表示去产生。而在 GLVQ-F 中亏损函数的选取存在理论问题。

本文把这种算法用于美元货币的识别,试验结果表明,该方法具有很好的识别效果。

### 2 数据预处理

为了改善采样数据的质量和提取适合人工神经网络训练的特征量,需进行采样的预处理,包括采样数

据的平滑滤波和特征提取。

### 2.1 采样数据平滑

在纸币信号的检测和采集的过程中，必然会受到外界的干扰，引进了各种干扰信号和噪声。为了改善信号质量，除了使用硬件方法实现滤波处理外，在软件中使用 5 点平滑数字滤波对 A/D 转换后的纸币信号进行平滑滤波处理，可以消除大部分的噪音，高频噪声在一定程度上也被平滑和抑制。

### 2.2 基于改进描述特征识别算法 (MEFFRA) 的特征提取

令  $TR = \{A_i \in R^{m \times n}\}_{i=1}^N$  训练图像，其中  $A_i \in R^{m \times n}$  代表第  $i$  个训练图像， $N$  为训练个数。

则训练集的均值为  $\varphi = \frac{1}{N} \sum_{i=1}^N A_i$ ，协方差矩阵为  $G_b \in R^{m \times n}$

$$G_b = \frac{1}{N} \sum_{i=1}^N (A_i - \varphi)^T (A_i - \varphi) \quad (1)$$

则子空间的基向量  $v_i$  就是  $G_b$  的第  $i$  个最大特征值对应的单位特征向量。在实际应用中，一般是选择前  $k$  个最大特征值对应的单位正交特征向量构成图像子空间  $V: V = [v_1, v_2, \dots, v_k]$ 。

提取图像  $A_i (i = 1, 2, \dots, N)$  的特征  $Y_i$  就是把  $A_i$  向子空间投影，即：

$$Y_i = (A_i - \varphi) \times V = [y_{1i}^i, y_{2i}^i, \dots, y_{ki}^i], i = 1, 2, \dots, N \quad (2)$$

式中  $y_{ji}^i \in R^m$  代表  $Y_i$  的第  $j$  列，称为图像  $A$  的第  $j$  个主成分向量。

令  $TN = \{Y_i\}_{i=1}^N$  代表新的训练集，则训练集的协方差矩阵  $G_r$  为

$$G_r = \frac{1}{N} \sum_{i=1}^N Y_i \times (Y_i)^T \quad (3)$$

则子空间的基向量  $u_i$  就是  $G_r$  的第  $i$  个特征值对应的单位特征向量。在实际应用中，一般是由前  $k$  个最大特征值对应的单位正交特征向量组成，即  $W = \{u_1, u_2, \dots, u_k\}$

#### 特征提取

样本  $Y_i$  向子空间  $W$  投影后的特征  $P_i \in R^{k \times k}$ ，即为 MEFFRA 提取的人脸图像  $A_i$  的特征。

$$P_i = W^T Y_i \quad i = 1, 2, \dots, N \quad (4)$$

## 3 MLVQ 神经网络用于货币识别

### 3.1 LVQ 学习算法如下：

设置变量和参数：

$X(n) = [x_1(n), x_2(n), \dots, x_N(n)]$ ，为输入向量，或称训练样本， $N$  为维数  $W_i(n) = [w_{i1}(n), w_{i2}(n), \dots, w_{iN}(n)]$  为权值向量， $i = 1, 2, \dots, M$  选择学习速率的函数  $\eta(n)$ 。 $n$  为迭代次数， $K$  为迭代总次数。

初始化权值向量  $W_i(0)$  及学习速率  $\eta(0)$ 。

从训练集中选取输入向量  $X$

寻找获胜的神经元  $c$ ：

$$\|X - W_c\| = \min_i \|X - W_i\|, i = 1, 2, \dots, M \quad (5)$$

判断分类是否正确，根据以下规则调整获胜神经元的权值向量：

用  $L_{W_c}$  代表与获胜神经元权值向量相联系的类，用  $L_{X_i}$  代表与输入向量相联系的类。如果  $L_{X_i} = L_{W_c}$  则

$$W_c(n+1) = W_c(n) + \eta(n)[X - W_c(n)] \quad (6)$$

否则，当  $L_{X_i} \neq L_{W_c}$ ，有

$$W_c(n+1) = W_c(n) - \eta(n)[X - W_c(n)] \quad (7)$$

调整学习速率  $\eta(n)$ ：

$$\eta(n) = \eta(0) \left(1 - \frac{n}{N}\right)$$

判断迭代次数  $n$  是否超过：

如果  $n \leq K$ ，就将  $n$  值增加 1，转到第三步；否则结束迭代过程。

### 3.2 MLVQ 神经网络算法

MLVQ 神经网络算法仍然采用 LVQ 两层网络，算法如下：首先采用一种对初值的处理算法，这种算法既保证了每个输出元机遇均等又使得各有差别；然后以 FCM 的目标函数为亏损函数，优化后求出学习因子；对每一竞争元依据不同的学习因子进行学习直到满足收敛条件。结构如下：

选定误差  $\varepsilon_1$  或者首次学习次数  $T_1 (T_1 = 2M)$ ，把 LVQ 算法中的判别获胜元方式改为：

$$\|X - W_c\| = \max_i \|X - W_i\|, i = 1, 2, \dots, M \quad (8)$$

对获胜神经元进行学习

$$W_c(n+1) = W_c(n) + 2\eta(n)[X - W_c(n)]g_i^m \quad (9)$$

直至满足选定的误差  $\varepsilon_i$  或首次学习次数  $T_i$  ;

以(1)的结果为初值  $W_0 = \{w_{1,0}, w_{2,0}(n), \dots, w_{M,0}\}$  进行如下计算, 设定最大循环次数  $T$  以及误差  $\varepsilon$ , 顺序选定竞争元进行学习

$$W_c(n+1) = W_c(n) + 2\eta(n)[X - W_c(n)]g_i^m \quad (10)$$

直到满足收敛条件或最大循环次数  $T$ , 其中

$$g_i = \left( \sum_{j=1}^M \left( \frac{\|x - w_j\|^{2/(m-1)}}{\|x - w_i\|^{2/(m-1)}} \right) \right)^{-1}$$

试验条件一般选择文献[11]的

试验条件:  $\eta = 0.6, T = 500, m = 2$

### 4 实验结果与分析

本实验选用的纸币为 2004 年版美元 1 元, 5 元, 10 元, 20 元共四类, 每面四个方向, 进行试验。实验选用 240 个新旧程度不同的训练样本, 每类 10 个样本; 120 个新旧程度不同的测试样本, 每类 5 个样本。其中每个样本是由光学传感器和磁传感器获得的 8128 的数据矩阵。

按照本文的识别算法, 首先进行平滑滤波, 然后使用 MEFFRA 算法进行特征提取, 结果得到 64 维的输入向量, 然后选择 MLVQ 神经网络分类器结构, 根据特征向量和模式类别知输入和输出神经元的个数分别为 64 和 16, 隐含层节点数经验为输出节点的 3~5 倍, 本实验中取隐含层节点数为输出层节点数的 3 倍即 48 个神经元。训练的误差性能曲线如图 1 所示:




图 1 MLVQ 网络训练的误差性能曲线

用数据集中另外 50 个样本组成测试集, 测试分类网络性能, 网络性能指标有: 识别率、拒识率、误识率和可靠性四个指标, 标示分类实际上正确的可靠程度, 可靠性的计算公式如下:

$$\text{可靠性} = \text{识别率} / (100\% - \text{拒识率}) * 100\%$$

MLVQ 网络仿真实验结果如下:

表 1 MLVQ 网络仿真实验结果

项目	网络规模	币种 (元)	网络性能 (%)			
			识别率	拒识率	误识率	可靠性
MLQ 网络	规模: 64 × 48 × 16	1	96	0	4	95.875
		5	95.5	0	4.5	
		10	97	0	3	
		20	95	0	5	
MLVQ 网络	规模: 64 × 48 × 16	1	97.5	0	2.5	97.5
		5	97	0	3	
		10	98.5	0	1.5	
		20	97	0	3	

### 参考文献

- 1 Takeda F, Omatu S, Inoe T. An expert system for determining the discriminative functions for bill money recognition. Trans. Info. Process. Soc. Japan, 1992, 33(7): 980-990.
- 2 Takeda F, Omatu S, Inoe T, Onami S, Konishi K. High speed conveyed bill money recognition with neural network. Trans. Inst. Elect. Eng. Japan. 199, 112 (4): 101-110.
- 3 高隽. 人工神经网络原理及仿真试验. 第四版. 北京: 机械工业出版社, 2007: 173-175.
- 4 Ahmadi A, Omatu S, Kosaka T. A Methodology to Evaluate and Improve Reliability in Paper Currency Neuro-Classifiers, Proceedings 2003 IEEE International Symposium on Computational intelligence in Robotics and (下转第 4 页)

(上接第 109 页)

Automation .2003,16(2) :1062-1071.

- 5 Takeda F, Omatu S, Kosaka T. Improvement of the Reliability of Bank Note Classifier Machines, Neural Networks, 2..4. Processings 2004 IEEE International Joint Conference 2004, 2(1):1313-1316.
- 6 张颖, 陈雪波, 吴庆洪, 梁英顺. 人民币纸币识别系统, 仪器仪表学报, 2004(S1):101-104.
- 7 高全学, 潘泉, 梁彦, 张洪才, 程咏梅. 基于描述特征的人脸识别研究. 自动化学报, 2006, 32(3):386-393.
- 8 闫德勤, 等. MLVQ 网络聚类算法, 自动化学报. 2004, 30(4):609-611.

- 9 Pal NR, Bezdek JC, Tsao ECK. Generalized clustering networks and Kohonen's Self-organizing scheme. IEEE Transaction on Neural Networks. 1993, 4(4):529-557.
- 10 Bezdek J. Pattern Recognition with Fuzzy Objective Function Algorithms. New York, Plenum, 1981:59-63.
- 11 Karayiannis N B, Bezdek J C, Pal N R, Hatharay R J. Repair to GLVQ: A new family of competitive learning schemes. IEEE Transaction on Neural Networks, 1996, 7(5):1062-1071.