

采用 RAM 加权技术的自适应模式识别系统

葛洪伟 张曦煌

(无锡轻工大学信息与控制工程学院, 无锡 214036)

摘要 简要介绍了利用 RAM 网络实现的自适应模式识别系统 (WISARD) 的结构和工作原理, 提出了利用 RAM 加权技术优化系统性能的方法, 就该方法对系统性能的优化给出了简例, 并从理论上作了初步的证明

关键词 模式识别; 神经网络; 自适应

分类号 TP391.4

0 前 言

英国 I. Aleksander 教授领导的模式识别小组经过 10 余年的不懈努力于 1985 年研制成功了利用 RAM 阵列实现的并行自适应模式识别系统——WISARD, 该系统松散地基于 McCulloch-Pitts 形式神经元模型, 与人的模式识别机制有许多相似之处, 具有大规模并行分布处理以及非算法性、自适应性和通用性等特点。该系统面世后引起了学术界和工业界的很大兴趣, 在工业视觉、字符编码识别、安全监视等诸多领域充分显示了它的应用潜力。然而该系统也有其固有的缺陷, 比如: 训练样本集较大时, RAM 网络易产生“饱和”现象; 不能区分频繁出现和较少出现的模式, 抗噪能力低, 影响了系统的识别能力。作者提出了利用 RAM 加权技术优化系统性能的方法, 该方法的基本思想是: 摒弃系统直接置位 RAM 单元的做法, 而是在训练期间先统计出训练样本各 n 元子模式的出现频率, 待训练样本输入完毕后, 再对统计出的子模式出现频率取阈值, 丢弃较少出现的伪特征信息, 保留频繁出现的模式固有特征信息, 并置位相应的单元。系统采用加权技术后, 所建立的逻辑函数能更好地反映模式的类别属性, 能有效地抑制伪特征, 突出固有特征, 并较好地解决了 RAM 网络的“饱和”问题, 提高了系统整体的识别能力。

1 自适应模式识别系统简介

WISARD 系统的逻辑结构如图 1 所示

输入模式一般是 $m_1 \times m_2$ 的二值数据阵列, 该阵列可以是一幅图象、一个字符或其它类型的模式数据。它被随机或确定地划分成 k 个子模式, 每个子模式为 n 维, 故称为 n 元子模式。每个 n 元分别连接到具有 2^n 个存贮单元的 RAM 地址端。这样, $k = m_1 \times m_2 / n$ 个内容寻址的 RAM 部件就构成了一个分类器的存贮空间。对于 M 类问题一般需要 M 个分类器与

之对应。它们的训练单独进行,而分类则同时进行。在网络训练阶段,各分类器 RAM 置为“写”状态,当训练样本的 n 元模式数据寻址 RAM 时,被选中单元置为“1”。当一个模式类数据训练完毕后,再以同样的方式进行其它分类器的训练。事实上,整个系统可视为一个组合网络系统, RAM 与逻辑函数对应,子模式和逻辑函数的最小项对应,因此,训练过程是一个逻辑函数的建立过程。在分类阶段,各分类器 RAM 置为“读”状态,当未知模式输入系统时,各 n 元子模式同时寻址各分类器的 RAM,相应单元的内容被读出,每个分类器的所有




图 1 WISARD 系统的逻辑结构

RAM 输出之和形成该分类器的响应。决策逻辑根据各分类器的响应对未知模式进行分类,其分类决策采用最大响应决策原理。WISARD 系统的工作原理、理论分析、应用结果等见文献 [1, 2]。

2 基于 RAM 加权技术的系统改进

2.1 RAM 加权技术

从上述 WISARD 系统的介绍中可以看出,系统中 RAM 单元仅有一位,只记忆了特定子模式出现与否,并没有记录它们出现的次数。而事实上,真正代表模式数据性质的子模式总是频繁出现(称之为强子模式),由于噪声、畸变出现的子模式总是偶尔出现的(称之为弱子模式),因此原系统不能区分强子模式和弱子模式,也就是说系统不能有效地分辨模式真正的固有特征和伪特征信息。另外,对于非确定性的模式数据,由于模式的差异性大,要求的训练集很大,这样就使 RAM 采样的 n 元子模式过多,造成很多 RAM 单元被置位, RAM 网络出现“饱和”现象。分类时,对任何输入模式,每个 RAM 部件均有很高的概率输出 1,这样系统对不同类模式数据的响应差异也就很少,系统分类性能出现钝化。要弥补上述缺陷,在训练时可采用 RAM 加权技术,即将原系统的网络设计成可重构的 RAM 网络。当对一个分类器进行训练时,剩余空闲分类器的 RAM 附在被训练分类器上构成计数器,记录每个 n 元子模式的出现频率。训练结束后,取适当的阈值,只有出现频率超出阈值的 n 元子模式才将相应的 RAM 单元置位,这样就有效地消除了弱子模式,抑制了 RAM 的“饱和”现象,而系统成本基本不增加。

该改进的训练过程在数学上可描述如下:
设系统共有 M 个分类器,不失普遍性地设 d 为系统中任一分类器,其训练样本集为 $T = \{T_1, T_2, \dots, T_g\}$, g 为训练样本的个数。训练集中任一样本模式 $T_j (j = 1, 2, \dots, g)$ 用向量可表示为:

$$T_j = (p^j_1, p^j_2, \dots, p^j_R)^t$$

其中 R 为二值模式的维数,即 $R = m_1 \times m_2, p^j_i (i = 1, 2, \dots, R)$ 取值 0 或 1,记号 t 表示转置,该模式被随机划分成 $k = R/m$ 个子模式,其中任一子模式可表示为:

$$P^i = (p^i_1, p^i_2, \dots, p^i_n)^t, \quad (i = 1, 2, \dots, k)$$

那么用 T_j 对 d 进行训练所获得的 d 的激励矩阵 E_j 是:

$$E_j = \begin{bmatrix} e_1^j \\ e_2^j \\ \dots \\ e_k^j \end{bmatrix}, \quad \text{其中 } e_i^j = \sum_{h=1}^n 2^{h-1} \cdot p_{ih}^j, \quad i=1, 2, \dots, k$$

根据 T_j 的 n 元子模式对 d 的激励, T_j 的 n 元子模式特征矩阵为:

$$A_j = \begin{bmatrix} a_0^j \\ a_1^j \\ \dots \\ a_{2^n-1}^j \\ a_1^j \\ \dots \\ a_{2^n-1}^j \\ \dots \\ a_{(k-1) \cdot 2^n}^j \\ \dots \\ a_{k \cdot 2^n-1}^j \end{bmatrix}, \quad \text{其中 } a_{(T-1) \cdot 2^n + U}^j = \begin{cases} 1 & \text{若 } U \in e_i^j \\ 0 & \text{其它} \end{cases}, \quad T=1, 2, \dots, k$$

训练样本集 T 的所有样本在 d 中形成的 n 元子模式特征频率矩阵 W 是各样本特征矩阵之和, 即:

$$W^d = \sum_{j=1}^g A_j = \begin{bmatrix} w_0^d \\ w_1^d \\ \dots \\ w_{2^n-1}^d \\ w_1^d \\ \dots \\ w_{2^n-1}^d \\ \dots \\ w_{(k-1) \cdot 2^n}^d \\ \dots \\ w_{k \cdot 2^n-1}^d \end{bmatrix}, \quad \text{其中 } w_i = \sum_{j=1}^g a_i^j, \quad i=1, 2, \dots, (k \cdot 2^n - 1)$$

W^d 为加权度量矩阵, 对 W^d 取适当的阈值 σ , 就可得分类器 d 的逻辑函数 F^d , 它可表示为:

$$F^d = \begin{bmatrix} f_0^d \\ f_1^d \\ \dots \\ f_{k \cdot 2^n-1}^d \end{bmatrix}, \quad \text{其中 } f_i^d = \begin{cases} 1 & \text{若 } w_i^d \geq e \\ 0 & \text{若 } w_i^d < e \end{cases}, \quad i=1, 2, \dots, (k \cdot 2^n - 1)$$

显然 $e=1$ 时, 系统为非加权系统. 当对系统的 M 个分类器训练结束后, 也就建立起了整个系统的逻辑函数矩阵 $F = (F^1, F^2, \dots, F^M)$.

2.2 系统性能优化证明

作者所在的科研小组所做的测试工作表明: 只要合理地选取阈值 (阈值过小系统会出现“饱和”现象, 阈值过大系统可能会“欠学习”), 采用 RAM 加权技术的系统, 其分类性能将优于原系统. 下面先作 3 项定义, 再对这一论点作一初步证明.

定义 1 对于系统中任意两个逻辑函数矢量 $F^i = (f_0^i, f_1^i, \dots, f_{k \cdot 2^n-1}^i)^t$ 和 $F^j = (f_0^j, f_1^j, \dots, f_{k \cdot 2^n-1}^j)^t$. 如果当 $h=0, 1, \dots, (k \cdot 2^n - 1)$ 时, 总有 $f_h^i \leq f_h^j$, 则称 F^i 包含于 F^j , 记作 $F^i \subseteq F^j$.

定义 2 若 $F^i = (f^i_0, f^i_1, \dots, f^i_{k^{\circ}-2-1})^t$ 和 $F^j = (f^j_0, f^j_1, \dots, f^j_{k^{\circ}-2-1})^t$ 是 i, j 两类模式在相应的两个分类器中建立起的逻辑函数矢量, 则 $F^i \cap F^j$ 是两矢量对应元素的逻辑乘运算, 即:

$$F^i \cap F^j = \begin{bmatrix} \lambda^{ij}_0 \\ \lambda^{ij}_1 \\ \vdots \\ \lambda^{ij}_{k^{\circ}-2-1} \end{bmatrix}, \quad \text{其中 } \lambda^{ij}_h = f^i_h \wedge f^j_h, \quad h = 0, 1, \dots, (k^{\circ}-2-1)$$

于是称 $f(F^i, F^j) = \sum_{h=0}^{k^{\circ}-2-1} \lambda^{ij}_h \setminus (k^{\circ}-2-1)$ 为 i, j 两类模式的特征重叠度。

定义 3 如果 $F^1, F^2, \dots, F^M$ 是系统的 M 个逻辑函数矢量, 那么系统的最大特征重叠度 $f_{\max} = \max\{f(F^i, F^j) \mid i = 1, 2, \dots, M-1, j = i+1, \dots, M\}$

由定义 3 可以看出, 系统的最大特征重叠度实际上是两两模式类间特征重叠度之最大值。若系统的最大特征重叠度越小, 那么类间离散性就越大, 不同模式类间的可区分性加大, 系统分类性能得到优化。所以论点证明可转化为证明加权系统的最大特征重叠度 $f_{\max}$ 小于非加权系统的最大特征重叠度 $f'_{\max}$ 。

证 设 F^i, F^j 为加权系统中任意两个逻辑函数矢量, $i, j = 1, 2, \dots, M$ 。而 $F^{i'}, F^{j'}$ 为非加权系统中相对应的两个逻辑函数矢量, 则显然 $F^i \subseteq F^{i'}, F^j \subseteq F^{j'}$, 因而 $F^i \cap F^j \subseteq F^{i'} \cap F^{j'}$ 。

由定义 2 可得 $f(F^i, F^j) \leq f(F^{i'}, F^{j'})$ 。

由定义 3 可得 $f_{\max} \leq f'_{\max}$ 。

证毕

2.3 系统性能优化简例

为叙述方便, 现以简化的两类分类器为例来说明。设输入模式大小为 3×3 位, 并以行列分成 3 个子模式, 而训练模式如图 2 的 $T_1 \sim T_4$, 它们可认为是字母 ‘T’ 及其变形。测试模式为图 2 的 $T_5 \sim T_{12}$ 。




图 2 训练和测试样本

在加权系统中, 当训练结束后, $W = (0, 0, 1, 0, 3, 0, 0, 0, 0, 0, 0, 0, 0, 1, 3, 0, 0, 1, 0, 3, 0, 0, 0)^t$, 取 $\epsilon = 2$, 可得 $F = (0, 0, 0, 0,$

表 1 系统训练后的测试结果

样本	T_1	T_2	T_3	T_4	T_5	T_6	T_7	T_8	T_9	T_{10}	T_{11}	T_{12}
响应	3	2	2	2	2	2	2	2	0	0	1	0
分类	O_1								O_2			

根据表 1 各模式的响应值, 很容易找到一个阈值将它们分成两类, 即 $T_1 \sim T_8$ 为一类, T_9

$\sim T_{12}$ 为另一类 取得上述结果是合理的,因为 $T_1\sim T_4$ 为训练样本,它们可以认为是字符‘ T’和它的变形,而 $T_4\sim T_8$ 和字符‘ T’相似,它们是训练集的推广,是识别系统智能的体现,而 T_9 为字符‘ H’, T_{10} 为字符‘ O’, T_{11} 为字符‘ +’, T_{12} 为字符‘ -’,它们和字符‘ T’差异较大,理应不属于 O_1 .

在非加权系统中,训练结束后, $F=(0,0,1,0,1,0,0,0,0,0,0,0,0,1,1,0,0,1,0,1,0,0,0,0)$,其测试结果如表 2所示

表 2 非加权系统中训练后的测试结果

样本	T_1	T_2	T_3	T_4	T_5	T_6	T_7	T_8	T_9	T_{10}	T_{11}	T_{12}
响应	3	3	3	3	2	2	2	2	0	0	3	2
分类	O_1								O_2			

从表 2中可以看出,原系统很难区分两类模式,分辨性能明显弱于加权系统,其原因在于原系统中将强、弱子模式一视同仁,无法有效地分辨主要和次要的特征信息。另外例中很明显 $F\subseteq F'$,即加权系统的 RAM“饱和”度要小于非加权系统。当然这里只是给出了一个简介,实际工作中,训练样本集一般较大,加权系统的优化性能得以充分体现。要抑制 RAM“饱和”现象,提高系统的分类识别能力,还可以采用许多其它方法,如多窗口技术、反馈技术等,希望能和读者共同探讨。

参 考 文 献

1 Aleksander I, Thomas W V, Bowden P A. WISARD a Radical Step Forward in Image Recognition. Sensor Review, 1984, 4(3): 120~ 124

2 孙燕唐,葛洪伟. 利用逻辑神经网络实现图象的边缘检测和压缩. 电子计算机, 1997, (2): 48~ 52

3 Aleksander I, Morton H. An Introduction to Neural Computing. Chapman and Hall, 1992 70~ 90

4 王意洁,王勇军,李晓梅等. 人工神经网络的分布并行处理. 计算机学报, 1997, (9): 806~ 811

5 施洪宝. 神经网络及其应用. 西安: 西安交通大学出版社, 1994.

RAM Weighted Adaptive Pattern Recognition System

Ge Hongwei Zhang Xihuang

(Wuxi University of Light Industry, Wuxi University of Light Industry, Wuxi 214036)

Abstract Adaptive pattern recognition system based on ram network (WISARD) has found extensive application in various areas because of its massive parallel distributed processing ability, versatility and self-adaptability. In this paper, we introduce briefly the structure and work principle of the system, and present a new method to improve the system with the ram weight technology. One example and tentative proof in theory also has been given in this paper to prove this method is effective.

Key words pattern recognition; neural network; self-adaptive

(责任编辑: 秦和平)