

用于不变特征抽取的 MADALINE 网络的改进和硬件实现*

陈鲁林

(中国科学院上海技术物理研究所, 上海, 200083)

摘要: 从实时应用的角度讨论和改进了MADALINE神经网络. 给出了局部连接型MADALINE不变网络的算法结构, 将算法简化为一般的矩阵运算, 提出了通过学习确定固定MAJ阈值和自适应MAJ阈值的方法, 用硬件实现了处理二值输入模式的局部连接型MADALINE网络, 给出了MADALINE网络原型与改进型的比较结果.

关键词: 神经网络, 实时处理, 不变特征.

引言

畸变不变模式识别一直是人们感兴趣的研究课题. 这里的畸变是指识别系统的输入模式相对于训练或学习模式发生的位置、大小、方向、视角以及形状等的任何变化. Widrow等^[1]提出了用MADALINE神经网络抽取对输入模式的平移、缩放和旋转等畸变不变的特征. 文献[2]、[3]在模式识别应用中也采用了MADALINE神经网络抽取输入模式的不变特征. 但是, 基于MADALINE网络的算法处理时间长, 网络的全连接结构也难以用硬件实现. 本文讨论了改进的局部连接型MADALINE网络, 其基本结构是: 网络中的ADALINE神经元的权只对应输入模式的行, 即原来输入模式与神经元权矩阵的内积变为输入模式的行与神经元权矢量的内积. 通过学习确定网络中每个模块的固定MAJ阈值和自适应MAJ阈值的方法使得网络对于不同的学习模式表现出学习与自适应的特性. 对于二值输入模式, 在硬件实现上采用了RAM芯片完成运算映射, 该网络在硬件识别系统中取得了较好的结果^[4]. 实验结果表明, 网络改进型的性能也优于网络原型. 本文是将神经网络用于实时目标识别系统的窗口技术以及小目标快速识别技术的一种尝试.

本文1991年12月27日收到, 最后修改稿1993年5月12日收到.

* 国家自然科学基金资助课题.

1 原理

1.1 结构

MADALINE 网络的第一层是若干个有多输入的 ADALINE 神经元, ADALINE 神经元的输入输出关系为 $y = X^T W = W^T X$, $q = \text{sgn}(y)$. 其中 $X = [x_0, x_1, \dots, x_n]^T$, $x_0=1$ 是常量输入, $W = [w_0, w_1, \dots, w_n]^T$, 偏置权 w_0 与 x_0 相连控制阈值电平. 根据期望响应和实际响应的误差信号, 用最小均方误差 (LMS) 算法调节权矢量 W , 符号函数 sgn 在这里起阈值器件的作用. 一般来说, 单个 ADALINE 不能实现大多数函数, 而只能实现线性可分函数. 即: 对二维特征空间, 分类问题的判决边界是一条直线; 对高维特征空间, 判决边界是一个超平面. 多个 ADALINE 可以实现非线性可分逻辑函数. MADALINE 网络的第二层是各种逻辑器件, 例如与、或和多数表决器, 它们也可用 ADALINE 实现.




图 1(a) MADALINE 平移不变网络, (b) MADALINE 网络改进型的实现
 Fig. 1 (a) The MADALINE translation-invariant network,
 (b) Implementation of the improved MADALINE network

图 1(a) 是平移不变的 MADALINE 网络, 其中 AD 是 ADALINE 神经元, MAJ 是多数表决器: 图中每一个模块有相同结构. 输入模式馈给所有模块上的每一个 AD, 选择各个 AD 的权矩阵, 保证每个模块上的输出响应 Q 对输入模式的平移不敏感. 网络中的模块数 n 可以与输入模式的像素数相同, 也可以不同. 设第 j 个模块上左上角的权矩阵为 $W_j (j = 1, 2, \dots, n)$, T_{Di} 为循环下移 i 行算子, T_{Ri} 为循环右移 i 列算子 ($i=0, 1, 2, \dots, n_1$). 选择第 j 个模块上的全部权矩阵为

$$\begin{bmatrix} (W_j) & T_{R1}(W_j) & T_{R2}(W_j) & T_{R3}(W_j) \\ T_{D1}(W_j) & T_{D1}T_{R1}(W_j) & T_{D1}T_{R2}(W_j) & T_{D1}T_{R3}(W_j) \\ T_{D2}(W_j) & T_{D2}T_{R1}(W_j) & T_{D2}T_{R2}(W_j) & T_{D2}T_{R3}(W_j) \\ T_{D3}(W_j) & T_{D3}T_{R1}(W_j) & T_{D3}T_{R2}(W_j) & T_{D3}T_{R3}(W_j) \end{bmatrix} \quad (1)$$

这是一个 16×16 的阵列，这里 $n_1 = 3$ 。输入模式 X 分别与式 (1) 中的每一个权矩阵进行内积，取阈值后输入到多数表决器 MAJ。MAJ 的输出响应对于输入模式的左右、上下平移是不敏感的，因为式 (1) 中的权矩阵考虑了输入模式所有可能的平移情况。 W_j 可以随机选择，一旦选定，就可以按式 (1) 构成全部权矩阵。用类似的方法构成权矩阵阵列计算其它的不变特征。例如：让模块对应约定的形状失真，则可以获得形状失真不变性；对应约定的角度旋转，则可获得旋转不变性。

1.2 局部连接的 MADALINE 网络

图 1(a) 不变网络中 n 个模块的结构可以采用并行处理的方法实现，但是，输入模式与每个模块用式 (1) 运算既费时又难以用硬件实现，因为此时网络是全连接结构。下面，我们讨论局部连接型 MADALINE 不变网络。设第 j 个模块中左上角 AD 的权为一行矢量 \vec{W}_j ，对应着输入模式的行，用 \vec{W}_j 构成如下矩阵：

$$W_j = \begin{bmatrix} (\vec{W}_j) \\ T_{R1}(\vec{W}_j) \\ T_{R2}(\vec{W}_j) \\ T_{R3}(\vec{W}_j) \end{bmatrix}, \quad (2)$$

W 的大小为 4×4 。若用行矢量 W_j 构成如式 (1) 的阵列，则有

$$\begin{bmatrix} (\vec{W}_j) & T_{R1}(\vec{W}_j) & T_{R2}(\vec{W}_j) & T_{R3}(\vec{W}_j) \\ (\vec{W}_j) & T_{R1}(\vec{W}_j) & T_{R2}(\vec{W}_j) & T_{R3}(\vec{W}_j) \\ (\vec{W}_j) & T_{R1}(\vec{W}_j) & T_{R2}(\vec{W}_j) & T_{R3}(\vec{W}_j) \\ (\vec{W}_j) & T_{R1}(\vec{W}_j) & T_{R2}(\vec{W}_j) & T_{R3}(\vec{W}_j) \end{bmatrix}, \quad (3)$$

这是 4×16 的阵列，并且每一行相同。这样，输入模式的行只分别与式 (3) 中对应行的行矢量内积。此时，乘法计算量由 16×16 次下降为 4×16 次。即对于 $m \times m$ 的输入模式，计算量约下降 m 倍。现在，第 j 个模块的输入输出关系可表示为

$$Q_j = \text{MAJ}[\text{SGN}(XW(j)^T)], \quad (4)$$

其中 MAJ 为多数表决器算子，对矩阵元素进行多数表决运算；SGN 为矩阵 sgn 算子，分别作用于矩阵元素。若用阶跃函数替换式 (4) 的符号函数，则有

$$Q_j = u[IU(XW(j)^T)I^T - \theta_j], \quad (5)$$

其中 u 为单位阶跃函数算子， U 为矩阵 u 算子， I 为单位行矢量， θ_j 为阈值。对于通常采用简单多数的表决器， θ_j 等于输入模式像素数的一半。不难得知，此时的模块输出 Q_j ($j=1, 2, \dots, n$) 对于输入模式的平移也是不敏感的。

1.3 MJA 阈值

不变网络的 n 个模块的输出 Q_j 构成了对应于输入模式的不变特征模式 $Q = [Q_1, Q_2, \dots, Q_n]$ 。当识别系统采用图 1 的不变网络抽取不变特征模式并且有多个学习模式时，希望得到的不变特征模式两两之间的 Hamming 距离 (模式中对应元素取值相反的个数) 愈

大愈好, 以利于特征模式分类和识别. 但是, 采用简单多数的表决器并不能保证这一点, 它没有考虑不变特征模式之间的相互关系可能造成不变特征模式两两之间的 Hamming 距离或大或小, 甚至有些是不能分辨的. 我们认为, 不变特征抽取应尽量保持学习模式两两之间的 Hamming 距离, MAJ 阈值不是预先确定的, 而是通过学习来确定. 下面我们给出两种确定 MAJ 阈值的方法.

1.3.1 自适应 MAJ 阈值

记式 (5) 方括号中的第一项为 Y_j . 对于输入模式集 $\{X^s\}$, 记上述 Y_j 为 Y_j^s , 则取 MAJ 阈值为

$$\theta_j = \sum_{s=1}^N Y_j^s / N, \quad (6)$$

N 为学习模式总数. 由于不同的 $W(j)$ 对应不同的 Q_j , 所以, 当 $j=1, 2, \dots, n$ 时, θ_j 可能取不同的值, 即每个模块的 MAJ 阈值可能不一样, 故称之为自适应 MAJ 阈值.

1.3.2 固定 MAJ 阈值

对于学习模式集 X_s , 有相应的特征模式集 $\{Q^s\}$, 设 $\theta_j = \theta, j=1, 2, \dots, n$, 即网络中每个模块的 MAJ 阈值相同. 改变 θ 的取值, 比较 $\{Q^s\}$ 中特征模式两两之间的 Hamming 距离 $\{H_e = (h_1, h_2, \dots, h_n)_e\}$, 选择 θ 满足

$$\theta = \left\{ \theta \left| \min \left[\frac{1}{n} \sum_{i=1}^n h_i - \left(\prod_{i=1}^n h_i \right)^{\frac{1}{n}} \right], \max \left(\sum_{i=1}^n h_i \right) \right. \right\},$$

此时, 固定 MAJ 阈值 θ 可使特征模式两两之间有较大而且取值相近的 Hamming 距离.

2 硬件实现与实验结果

对于二值输入模式, 其行矢量与 AD 的权矢量内积和取阈值过程实际上是一个二值映射, 可以用 RAM 存储器实现. RAM 中的内容就是取阈值后的 0, 1 值. 当 $m \times m$ 输入模式的 m 不太大时, 就有可能用通用 RAM 建立一个映射表. 例如 $m=8$, 就可以建立一个输入为 $2^8=256$ 个状态的映射表. $m=8$ 的循环右移的状态都包含在这个映射表中. 又由于式 (3) 中的每行的运算相同, 所以一张映射表即可完成模块中的所有内积运算. 旋转等其它不变特征的计算也都可以用类似方法实现. 图 1(b) 是模块的一种硬件实现框图. 现在, 算法中的主要处理时间只是 RAM 的读出时间, 实时处理成为可能.

表 1 输入模式之间以及采用三种 MAJ 阈值分别对应的特征模式之间 Hamming 距离的比较
Table 1 Comparison of Hamming distances between input patterns and between feature patterns corresponding to three kinds of MAJ threshold, respectively

H_1, H_2, H_3, H_4	模式 1	模式 2	模式 3
模式 2	19, 54, 27, 11		
模式 3	19, 34, 16, 11	12, 20, 11, 16	
模式 4	21, 34, 14, 16	26, 32, 15, 13	18, 38, 10, 7

图 2(a) 是 8×8 的学习模式, 图 2(b) 是对应于图 2(a) 的不变特征模式, 此时选择图 1(a) 的模块数 n 与输入模式像素数相同, 采用了固定 MAJ 阈值. 表 1 是输入模式两两之间 Hamming 距离 (H_1) 和采用自适应 MAJ 阈值、固定 MAJ 阈值以及 MADALINE 网络原型的简单多数 MAJ 阈值分别对应的特征模式两两之间 Hamming 距离 (H_2, H_3, H_4) 的比较. 表 1 说明自适应 MAJ 阈值和固定 MAJ 阈值方法比较好地保持了模式之间的 Hamming 距离, 而采用自适应 MAJ 阈值产生的特征模式之间有着更大的 Hamming 距离. 图 3 是改进的 MADALINE 网络和原型的容错性能比较, 均采用了本文的固定 MAJ 阈值方法. 图中 $D_{H,I}$ 为输入 Hamming 距离, $D_{H,O}$ 为平均输出 Hamming 距离, 实心点为网络原型数据, 空心点为网络改进型数据. 这里 Hamming 距离大于 1 的畸变模式均采用随机产生的方法.




图 2(a) 四个学习模式, (b) 对应于 (a) 的四个特征模式

Fig. 2 (a) Four learning patterns, (b) Four feature patterns corresponding to (a)




图 3 MADALINE 网络的改进型与原型的比较
Fig. 3 Comparison of the improved version with the original one of the MADALINE network

3 结语

MADALINE 神经网络的实时应用及硬件实现存在着一些难点. 本文给出的局部连接型 MADALINE 不变网络结构可以解决该网络的实时应用问题, 提出的固定 MAJ 阈值和自适应 MAJ 阈值方法赋予了该网络学习和自适应特性, 网络改进型的性能与网络原型比较亦有所提高.

参考文献

- 1 Widrow B, Winter R G, Baxter R A. *IEEE Trans. Acoust. Speech Signal Process.*, 1988;ASSP-36:1109-1118
- 2 Hosokawa M, Omat S, Fukumi M. *Proc. Inter. Joint Conf. Neural Networks*, Washington D.C., 1989, San Deigo, I-183
- 3 Cruz V, Cristobai G, Michaux T et al. *Proc. Inter. Joint Conf. Neural Networks*, Washington D.C., 1989, San Deigo, II -17
- 4 陈鲁林. 实时联想识别系统和基于光学突触器件的光电混合神经网络研究, 博士论文, 中国科学院上海技术物理研究所, 1992

IMPROVEMENT AND IMPLEMENTATION OF MADALINE NETWORK FOR INVARIANT FEATURE EXTRACTION*

CHEN LULIN

*(Shanghai Institute of Technical Physics, Chinese Academy of Sciences,
Shanghai 200083, China)*

Abstract: From the viewpoint of real-time application, the MADALINE network for invariant feature extraction is improved. Presented are the algorithm structure for the MADALINE invariant network with local interconnection, which is simplified to usual matrix computation, and the approaches by learning to determine the adaptive MAJ threshold and the fixed MAJ threshold. The improved network with local interconnection is implemented for binary patterns. The comparisons of MADALINE with its improved version are made.

Key words: neural network, real-time processing, invariant feature.

*The project supported by the National Natural Science Foundation of China.