

# 用 HMM 框架下的神经网络分类器 识别雷达目标

周德全 郭耀红

(空军第一航空学院科研部, 河南, 信阳, 464000)

**摘要** 提出了一种 HMM 框架下的神经网络分类器, 它既克服了普通神经网络不能有效地识别时变信号的缺点, 又解决了 HMM 识别时变信号时不能突出不同信号的差异性, 用网络权的遗传算法进化学习解决了 Baum-Welch 及 BP 网络学习中易陷入局部极小点的问题, 还给出了用该网络成功识别实测雷达回波信号的实例。  
**关键词** 隐含 Markov 模型, 神经网络, 遗传算法, 目标识别。

## RADAR TARGET IDENTIFICATION USING NEURAL NETWORK CLASSIFIER BASED ON HMM FRAMEWORK

ZHOU De-Quan GUO Yao-Hong

(Dept. of Science Research, Air Force No. 1 Institute of Aeronautics, Xinyang City, Henan 464000, China)

**Abstract** A neural network classifier based on HMM framework was proposed. It can be used to identify timevarying signal, which an ordinary neural network lacks of, and can stress the differences of different signals. Evolutionary learning of the neural network weights using genetic algorithm solves the problem of falling into local minimum point which BP and Baum-Welch algorithm face. An example of recognizing radar return signal successfully by the neural network was presented.

**Key words** hidden Markov model, neural network, genetic algorithm, target recognition.

### 引言

隐含 Markov 模型(HMM)已经在语音识别及模式识别中得到了广泛的应用<sup>[1,2]</sup>, HMM 具有很强的表征时变信号的能力<sup>[1]</sup>, 很适用作动态模式分类器. 通常优化设计 HMM 参数时, 只考虑如何使得模型更贴近相应的信号. 因此, 各模型参数只包含了本信号的信息, 而不能突出不同信号差异性. 显然, 这不利于对信号的有效识别. MLP 神经网络中, 由于相邻层神经元之间相互联接, 而权的学习又是以所有类型样本的期望输出与实际输出之间的误差最小为目标, 所以, 网络不仅学习了各信号的特征, 而且突出了不同信号的差异. 理论上, MLP 神经网络可以形成任意形状的分割曲面, 能对静态信号进行有效的分类. MLP 网络和大部分神经网络一样, 缺乏学习时变信号的能力, 也就无法识别时变信号.

但客观上, 常需要有效地识别时变信号, 如, 对空中作任意姿态无规则飞行的飞机、战场上作任意姿态任意路线行驶的坦克进行识别, 语音识别等.

针对以上情况, 将 HMM 与 MLP 神经网络相结合得到一种新颖的神经网络(简称 HNN). HNN 具有学习短时平稳整体非平稳信号的能力. 遗传算法(GAs)是近年来得到较大注意的一种优化算法<sup>[3]</sup>. 用 GAs 来设计 HNN 的主要优点是克服了用于设计 HMM 参数的 Baum-Welch 算法及 BP 算法易于陷入局部极小点的缺点.

### 1 HMM 框架下的神经网络分类器

Niles 和 Siverman<sup>[4]</sup>提出的 HMM 神经网络, 它可以实现传统 HMM 的结构和算法. 图 1 给出了 HMM 的结构图, 图 1 中 ⊙、⊗、●、log 分别代表乘、除、加和对数运算, 输出为

$$\Lambda(t) = \log[P(o_t/\lambda)], \quad (1)$$

式(1)中  $o_t$  为 1 到  $t$  时刻的观测序列. 连接权矩阵 A、B 实现的是 HMM 中状态转移概率矩阵和输出概率矩阵. 输入  $y(t)$  为一  $M$  维的离散矢量.  $M$  是矢量量化的 VQ 码矢的个数. 当输入观测矢量量化为某个码字时, 与该码字对应的  $y(t)$  分量为 1, 其余分量为 0.

整个识别系统由各待识别类的 HMM 网及 Bayes 决策网构成, 如图 2 所示. 在利用 Bayes 决策时, 假设各类先验概率相同. 决策网中各连接权为 1.  $x_i$  期望输出为 1 或 0, 当  $y(t)$  属于  $\omega_i$  类时  $x_i = 1$ , 否则为 0. 网络中的权矩阵 A、B 可以不象 HMM 中的 A、B 那样满足概率非负且和为 1 的约束<sup>[4]</sup>. 正值表示激励, 负值起抑制作用.

HMM 网是 HMM 的网络重构, 跟 HMM 一样具有对时间序列结构的建模能力. Bayes 分类网将各 HMM 网联系在一起, 训练是以所有类型模式样本的分类误差为最小进行的, 整个系统区分不同模式样本的能力增强. Niles 和 Siverman 提出的 HMM 网是 HMM 的网络重构, 存在乘、除、对数、指数等的复杂运算, 也没有真正利用神经网络强的分类能力的优点.

大家知道, MLP 具有在特征空间中形成任意形状的分割曲面的能力, 分类能力强. 但是, MLP 不具备表征时间序列的能力. 如果能将 HMM 网与 MLP 有机地结合在一起, 将会使这一新的网络同时具有 HMM 与 MLP 的优点. 这一新网络记为 HNN.

给定一 HMM 模型  $\lambda_k = (A, B, \pi)$ ,  $k=1, 2, \dots, C$ , 以及一未知的观测序列  $O = (o_1, o_2, \dots, o_T)$ , 模型  $\lambda_k$  产生这一序列  $O$  的概率  $P(O/\lambda_k)$  可由下列前向算法完成<sup>[4]</sup>:

$$\alpha_1(i) = \pi_i b_i(o_1), \quad 1 \leq i \leq N \quad (2)$$

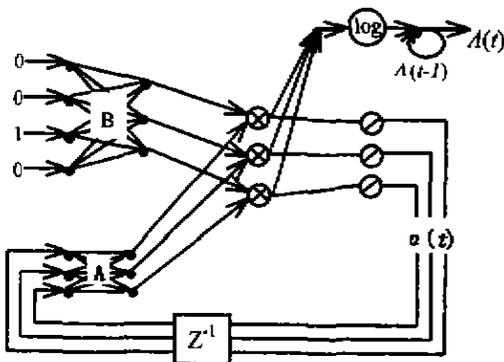


图 1 HMM 网络  
Fig. 1 HMM network

$$\alpha_{t+1}(j) = [\sum_{i=1}^N \alpha_t(i) a_{ij}] b_j(o_{t+1}), \quad 1 \leq t \leq T-1, \quad 1 \leq j \leq N \quad (3)$$

匹配概率  $P(O/\lambda_k)$  可由下式计算:

$$P(O/\lambda_k) = \sum_{i=1}^N \alpha_T(i), \quad (4)$$

通常基于 HMM 的识别系统都是选择  $P(O/\lambda_k)$  最大的模型  $\lambda_k$  所对应的目标作为识别结果.

从式(4)可见, 只要将各模型  $\lambda_k$  的  $\alpha_T(i)$ ,  $i=1, 2, \dots, N$ , 作为 MLP 网络的输入即可, 而不必进行图 2 中的乘、除、指数、对数运算. 整个 HNN 的网络结构如图 3 所示. 图 3 中的前一部分完成前向算法的功能, 即它将动态输入样本序列转换成特征矢量  $\alpha_T$ . 第二部分的 MLP 完成对静态模式的识别. 输入  $y(t)$ , 它与图 1 中的输入的含义相同. 为了理解网络的合理性, 对式(2)–(4)作如下变形:

$$\text{令 } \gamma_i(i) = \pi_i, \quad 1 \leq i \leq N \quad (5)$$

$$\alpha_1(j) = \lambda_k(j) B_j Y_1, \quad 1 \leq i \leq N, \quad (6)$$

则, 
$$\lambda_k(i) = \sum_{j=1}^N \alpha_T(j) u_{kj}, \quad 1 \leq j \leq N, \quad 1 \leq t \leq T-1 \quad (7)$$

$$\alpha_T(j) = \gamma_{T-1}(j) B_j Y_T, \quad 1 \leq j \leq N, \quad 1 \leq t \leq T \quad (8)$$

式中  $B_j$  是图 3 中 B 网络第  $j$  个输出与输入  $Y$  各分量的联结权值, 相当于输出概率矩阵的第  $j$  行矢量. 网络的输出可以看成输入序列的后验概率, 其大小为

$$P(\omega_i/O) = f \left\{ \sum_{k=1}^H w_{ik} f \left[ \sum_{j=1}^N w_{kj} \alpha_T(j, 1) \right] \right\}, \quad (9)$$

式(9)中  $w_{kj}$  是第  $j$  个 HMM 网的第 1 个状态输出到第  $k$  个 MLP 隐节点的连接权,  $w_{ik}$  是第  $k$  个隐节点到第  $i$  输出节点的连接权,  $\alpha_T(j, 1)$  为第  $j$  个 HMM 网的第 1 个状态在  $T$  时刻的输出, 相当于

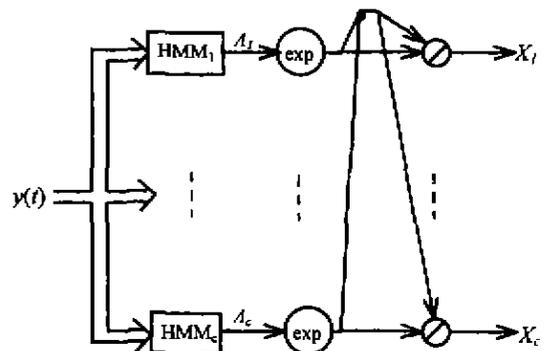


图 2 在于 HMM 网络的分类系统  
Fig. 2 HMM-based classifier system

HMM 在  $T$  时刻的前向概率,  $f$  为 sigmoid 函数, 即

$$f(x) = \frac{1}{1 + \exp(x)}, \quad (10)$$

$P(\omega_i/O)$  的理想值为 1 或者 0, 当观察序列  $O \in \omega_i$  时,  $P(\omega_i/O)=1$ , 否则为 0.

整个网络中的权值可为正或负值, 不必满足概率 1 约束.  $a_T(j, 1)$  并不代表真正的概率值, 不必担心会出现下溢现象. 由于整个网络通过 MLP 联系在一起, 并以所有学习样本的分类误差最小为目标进行训练, 所以 HNN 系统能有效地区分不同类型的相似样本序列. 而基于 HMM 的识别系统, 在估计 HMM 参数时仅用到了相应类型的样本, 其它类型的样本并未参与该模型参数的估计, 估计出的 HMM 能较好地描述学习样本序列, 但识别问题主要是要求系统能区分不同的模式. 总之, HNN 识别系统训练过程中用到了可能引起混淆的不同类型的样本序列, 因此有理由相信这一系统比 HMM 识别系统更好. 图 3 中 HNN 比 Niles 等提出的 HMM 网简洁得多, 这里消除了除、对数及指数运算, 它与常用的神经网络相比仅仅多用一个乘法运算.

### 2 网络的遗传进化学习

遗传算法(GAs)将达尔文的自然界生物进化思想灵活地运用到优化领域而产生的一种寻优算法<sup>[3]</sup>. GAs 中有三种基本运算.

#### (1) 复制

复制就是根据每个个体的适合度来复制新个体的过程. 适合度越大, 被复制的可能性就越大, 其子孙在下一代的个数就越多.

#### (2) 交叉

首先在新复制的群体中随机选取二个个体, 然

后沿着这二个个体均匀随机地取一个位置, 最后二者互换从该位置起的末尾部分. 如, 二个长度  $L$  为 4 的二进制编码个体 A、B: A=1010, B=0100; 随机选择一整数  $K \in [1, L-1]$ , 设  $K=2$ , 则交叉后的新个体分别为  $A'=1000, B'=0110$ .

#### (3) 变异

变异就是以很小的概率随机地改变个体某个位置的值. 在二进制编码中, 随机地将某个位置的“1”改为“0”, 或者“0”改为“1”. 变异可以防止由于复制与交叉而引起的某些信息的永远丢失及陷入局部极小点. 保证了遗传算法的有效性.

本文采用基本的遗传优化算法, 种群采用二进制编码方式. 目标函数为输出端总误差. 设  $C$  类信号源样本数分别为  $n_1, n_2, \dots, n_c$ , 相应的样本为  $y_1^1, y_1^2, \dots, y_1^{n_1}, y_2^1, y_2^2, \dots, y_2^{n_2}, \dots, y_c^1, y_c^2, \dots, y_c^{n_c}$ . 网络的期望输出为  $t_1, t_2, \dots, t_c$  (其中,  $t_1 = [1 \ 0 \ \dots \ 0], t_2 = [0 \ 1 \ 0 \ \dots \ 0], \dots$ ), 与每一样本对应的实际输出分别为  $x_1^1, x_1^2, \dots, x_1^{n_1}; x_2^1, x_2^2, \dots, x_2^{n_2}; \dots; x_c^1, x_c^2, \dots, x_c^{n_c}$ . 则总误差为

$$E_B = \frac{1}{2} \sum_{k=1}^c \sum_{l=1}^{n_k} (t_k - x_k^l)(t_k - x_k^l)^T, \quad (11)$$

适合度定义为

$$F = -E_B. \quad (12)$$

### 3 识别实例

实验用高分辨雷达获得的空中三类飞机一维距离像对上述分类器进行了检验. 这三类飞机分别为雅克-42 小型喷气客机、安-26 小型螺旋桨运输机、及奖状小型喷气机. 每类目标共取出 5000 个距离像. 经多分辨率分解、付氏变换、非相干平均及长度

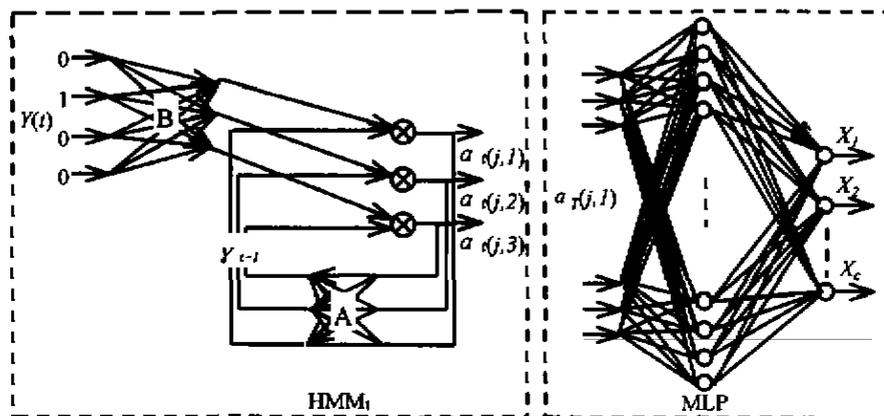


图 3 HNN 神经网络结构  
Fig. 3 Architecture of HNN neural network

信息提取等预处理后<sup>[5]</sup>,每类目标获得1000个特征矢量,三类目标共3000个.将矢量化后的300个长度为10的标号序列作为训练集,采用标准的GAs算法训练图3中的HNN.在文献(5)中,HMM的观测标号数为64,即VQ有64个码字.在这里,也用64个码字进行矢量化.

在相同飞行段,抽取与学习集不同的一维距离像(每一距离像与学习集中的相应距离像相隔2个距离像),形成每类目标1000个特征矢量的测试集.

用训练好的HNN识别测试集中的一维距离像序列,识别结果如表1所示.文献[5]中HMM的识别结果如表2所示.将表1的识别结果与表2相比较可见,HNN的正确识别率高于HMM的识别率.

表1 HNN对测试集的识别结果  
Table 1 Identification results of the HNN

类别	雅克-42	安-26	奖状
识别率(%)	97.6	98.2	99.3

表2 HMM对测试集的识别结果  
Table 2 Identification results of the HMM

类别	雅克-42	安-26	奖状
识别率(%)	96	97	95

但是,由于优化参数较多,Gas算法所需的计算机内存比HMM算法增大许多.

#### 4 结论

将HMM网络与MLP网络相结合所组成的神经网络,同时具有两者的优点,即能描述时变信号具有较强的分类能力.遗传进化学习方法的引入,又克服了Baum-Welch算法及BP算法固有的易陷入局部极小点的问题.对大视角范围内高分辨雷达目标回波的有效识别表明网络对时变信号有强的识别能力.

#### REFERENCES

- [1]Rabiner L R. A tutorial on hidden Markov models and selected application in speech recognition, *Proceedings of the IEEE*,1989,77(2):257-286
- [2]Fielding K H, Ruck D W. Spation-temporal pattern recognition using hidden Markov models, *IEEE-T-AES*,1995,31(4): 1292-1300
- [3]Goldberg D E. *Genetic Algorithms in Search, Optimization and Machine Learning*. Mass: Addison-Wesey,1989
- [4]Niles L T, Silverman H F. Combining hidden Markov model and neural network classifiers, *Proceedings of I-CASSP'90*,1990,2: 417-420
- [5]ZHOU De-Quan. Study of radar target identification based on range profiles. Doctorate Dissertation, Nanjing University of Science and Technology (周德全.基于一维距离像的雷达目标识别,博士学位论文,南京理工大学),1998