

用于声纳目标识别的综合决策网络初探*

刘 韬 张殿治 赵学云 李 映
(空军通信研究所 北京 100085) (空军工程大学工程学院)

摘 要 针对复杂目标识别中的一些难点问题,提出一种新的综合决策网络结构,声纳目标识别的仿真实验表明,这种新的网络模型具有较快的收敛速度,更高的识别率和更强的鲁棒性,并保持了人脑可持续学习的能力。

关键词 声纳,目标识别,神经网络,模式识别

分类号 TP 202

Compound Deciding Network of New Structure Applied to Sonar Target Detection

L i u T a o Z h a n g D i a n z h i , Z h a o X u e y u n , L i Y i n g
(The Third Institute of Air Force) (The Air Force College of Engineering)

Abstract To solve some knotty problems in sonar target detection measures, a new compound deciding network model is proposed. This model is applied to some complex recognition problems of sonar target and relevant algorithm is advanced. The simulation results show that the new network model has a faster speed to converge, a higher recognition rate, and robustness. It can retain the brain's sustained learning ability and has the ability to provide judgement of reject.

Key words sonar, target detection, neural network, pattern recognition

1 引 言

利用辐射噪声信号进行声纳目标自动识别是水声设备智能化的关键环节,因此许多神经网络的方法已用于该领域^[1,2]。某些用传统BP前向网络对目标分类的研究^[1-4]表明,一般在输入数据为理想情况下,即数据间交叠情况不太复杂时处理效果较好。而实际应用中不同类别的模式特征之间往往存在着相当大的重叠,这时如果使用单一的BP网络,则很难找到某种特征矢量能把各个类别较好地分开。

针对这些问题,已出现了一些新见解^[5,6],但效果仍不甚理想。作者从一个新的视角对此问题进行探讨,提出一种新的模型,取得了进一步的进展。

2 模糊记忆模型 FRM

FRM (Fuzzy Remembrance Model)是作者提出的一种模糊记忆模型,它利用一种新的分布式存储

方法来完成模糊记忆,而不同于其它网络(如Hopfield,ART等)。该网络中涉及到大量取值处于0,1之间的模糊权值,它们的大小从模糊的角度反映了神经节之间连接的紧密程度。为了区别于传统意义上的精确记忆,称其为模糊记忆模型。

FRM网络的结构如图1所示,它分为三个主要部分:输入层,记忆库,输出层。

该网络有4种工作状态。运行中网络依据下式




图 1 FRM 的基本结构

* 1998-09-23 收稿,1999-01-18 修回

选出“最强通路”

$$S = \frac{1}{n_{s, i, j} \quad n_r, i \ll j} W_{ij} \quad (1)$$

其中 n_s 为通路 R 内权值的个数。具有最大 S 值的通路将首先被选为最强通路。

涉取状态 Ph1 网络的初始化是在该状态下进行的。这时权值和“信息片断”(假定一个信息可划分为若干个“信息片断”)被装入网络。

训练状态 Ph2 在该状态下,按下式修改权值

$$W_{ij_{new}} = W_{ij_{old}} + \alpha_i (1 - W_{ij_{new}}) \quad (2)$$

或
$$W_{ij_{new}} = \beta_i W_{ij_{old}} \quad (3)$$

其中, $0 < \alpha_i < 1, 0 < \beta_i < 1$, 它们都是 FRM 的参数。 α_i 称为“鼓励参数”, β_i 称为“惩罚参数”。

常规状态 Ph3 在该状态下,按下式调整权值

$$W_{ij_{new}} = W_{ij_{old}} + \alpha_c (1 - W_{ij_{new}}) \quad (4)$$

或
$$W_{ij_{new}}(T_{ij} + 1) = W_{ij_{old}}(T_{ij}) e^{-\gamma T_{ij}} \quad (5)$$

其中, $0 < \alpha_c < 1$, 称为“生长参数”, 它与鼓励参数类似; γ 是一个小的正数, 称为“淡忘参数”; T_{ij} 是 W_{ij} 累计连续未被激活的持续次数。

纠错状态 Ph4 当 FRM 对目前输出持怀疑态度时则进入该状态, 并按一定的公式修改权值。

FRM 的输入/输出关系呈现一种非线形的动态映射。设射入向量 $X = (x_1, x_2, \dots, x_n)$, 训练后对各训练向量产生的记忆分别为 $y_{01}, y_{02}, \dots, y_{0k}, \dots$, 则

状态值

$$u = g(X) = \begin{cases} 0, & X \text{ 为原正确输入量} \\ 1, & X \text{ 为模糊联想输入量} \end{cases} \quad (6)$$

输出值

$$y = f(u) = \begin{cases} \max \frac{1}{n_{s, i, j} \quad n_r, i \ll j} W_{ij}, & u = 0 \\ \text{原来的记忆量 } y_{0k}, & u = 1 \end{cases} \quad (7)$$

可见, 这与普通的模糊逻辑映射是不同的。在运行中, 网络依照一定的算法在几种状态中进行实时转换, 从而完成特定的功能。

3 综合决策网络 CDN

本文重点介绍所提出的 CDN (Compound Deciding Network) 模型。它是将 FRM 与多层前馈网络相融合所形成的一种组合递归型网络, 从一定程度上模拟了人脑基于原有的经验和由外部反馈来的信息的一种模糊综合决策能力。

3.1 CDN 的总体结构

CDN 的结构如图 2 所示。其中输入端的输入向量 X_s, X_a 等是接收信号矢量 X 经预处理后确定出的特征矢量, 它们分别从不同侧面描述了噪声信号。在本文的实验中, 取三组特征 a, b, c 为例。在实际中可视情况而定。

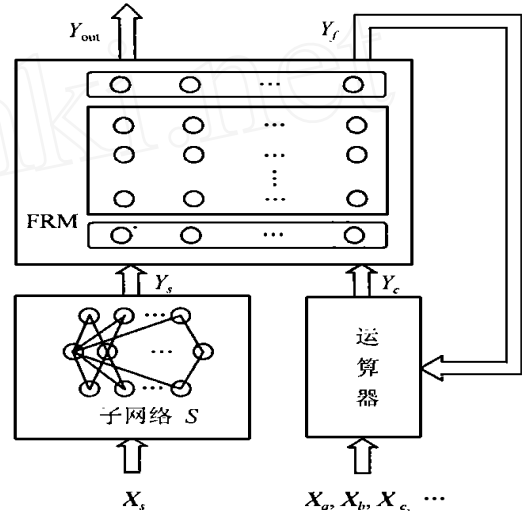


图 2 CDN 的基本结构

由于目标辐射噪声的特殊复杂性, 分别用这三种特征训练出的三种单一型网络, 它们对不同类别的分类能力是不同的。从不同网络对各类模式的总体分类效果上看, 其中必有一个特征所对应网络的总体分类效果更强些。CDN 中就用了这种特征, 其对应的特征矢量为 X_s , 用该特征训练的单一型前馈网络为网 s 。

图中的运算器由单一型网络通过分级和并联结构组成, 它起到对模式和中间结果进行初级预分类并给出临时分类结果的作用。

$$Y_c = f(WX_k - \theta), \quad k = a, b, c, \dots \quad (8)$$

其中, k 的取值由 Y_f 定出, θ 为阈值向量, $f(x)$ 一般取 Sigmoid 函数

$$f(x) = \frac{1}{1 + e^{-x}} \quad (9)$$

由子网络 s 或运算器输出的单特征初级分类结果 Y_s, Y_c 送入 FRM, 在那里进行对本次输出结果的判断和对子网络选取情况的决策。FRM 将结果输出来, 并反馈给运算器。当决策最终完成后, FRM 就输出稳定的识别结果 Y_{out} 。

3.2 CDN 的训练与运行

CDN 的训练采用分级训练的方法, 分为对子网络的训练和对网络的整体性训练。首先要对各个子网络进行训练, 使子网络能对特定的类别进行较好的分类, 其标准可依具体问题和具体情况而定。

CDN 的一个重要特点是: 在训练过程中就可先行把无法进行良好分类的奇异样本筛选出来, 从而为提高网络未来的分类准确性打下良好的基础。

CDN 的运行步骤如下:

Step 1: 输入模式 X 进行预处理后得到 X_a, X_b 等, 分别送入运算器及子网络 N_s 中。

Step 2: 由子网络 N_s 输出的 Y_s 作为临时分类结果 Y_{cs} 。

Step 3: 将 Y_{cs} 送入 FRM (处于常规状态), 得到 Y_f 信号并反馈给运算器。

Step 4: 运算器输出的 Y_c 与 Y_{cs} 进行比较, 若 $Y_c = Y_{cs}$, 说明网络做出的决策是成功的, 应加深记忆, 并据式 (4) 调整权值, 同时将 Y_c 作为最终结果输出出来; 否则继续。

Step 5: 如果 Y_c 与 Y_{cs} 不相同, 说明前面的决策欠妥, 此时应削弱前面的记忆, 并按式 (5) 调整权值; $L = L + 1$ (L 为连续重新决策的次数)。

Step 6: 比较 L 与 L_a (L_a 为 L 的最大允许值), 若 $L = L_a$, 说明网络经反复考虑后, 认为对该输入模式不能进行有把握的分类, 因此给出拒绝判决的信息并输出来, 本次运行结束; 否则, 令 $Y_{cs} = Y_c$, 转向 Step 3。

从 CDN 的运行方式可以看出: 它具有自适应的决策能力, 并且可在训练完成之后仍随输入样本的增加而不断学习, 如同人脑随时随地都可以不断积累经验一样。

4 仿真结果分析

从三类样本中共选取 436 个原始辐射噪声信号样本, 并将预处理后向量的包络谱特征提取到实验所需的维数。其中 218 个作为训练样本, 另外 218 个构成测试样本集。在目标识别过程中, 利用这些样本分别对以下几种网络进行性能测试: 1) 普通 BP 前馈网络 (OBPN); 2) 模糊并行子网络 (FPSN); 3) 综合决策网络 (CDN)。

表 1 三种网络的性能比较 (%)

网络	对属于一种类型的 样本识别正确率			总体分类 正确率	拒判率	分类 错误率
	类 1	类 2	类 3			
OBPN	87.50	79.01	82.19	82.569	0	17.43
FPSN	84.38	91.36	86.30	87.615	0	12.38
CDN	96.88	91.36	94.52	94.037	3.67	2.29

表 1 给出了用训练样本集进行实验时, CDN 与另外两种网络分类能力的对比情况。由表可见, CDN 具有较高的识别正确率和较低的出错率, 并可给出拒绝判决, 这是其它网络所没有的。无论是对每一个类的识别正确率, 还是总体分类正确率或错判率, CDN 模型都明显优于其它网络。




图 3 使用测试样本时对三种网络出错率的比较

图 3 给出了用测试样本集进行测试时, CDN 与另外两种网络错判率的变化情况。由图可以看出, 随着训练样本的逐渐增多, CDN 的识别率有增强的趋势, 错判率有下降的趋势, 降低量为 2—10 个百分点; 而另两种网络的分类能力则不随训练样本数的变化而呈规律变化的趋势。正如上节理论分析的那样, 这与 CDN 的自身特性是密切相关的。CDN 可以不断调整自身的内部参数, 始终使识别率向着上升的方向变化, 出错率向着减小的方向变化, 从而具有一定的自适应能力, 在整体上提高了系统的鲁棒性。

5 结 论

CDN 是在模拟人脑的思维和记忆活动的基础上提出的一种新型网络结构, 它可以较好地处理许多复杂的识别问题。本文针对声纳目标识别的应用实验表明, CDN 具有较高的识别率, 较强的鲁棒性, 适当的拒判能力和很低的错判率。这种模拟生物组织行为的智能化类脑计算, 值得进一步探讨和推广应用。

参 考 文 献

- Goman R P, Sejnowski T J. Learned classification of sonar target using a massively parallel network. IEEE Trans on ASSP, 1988, 36(7): 1135_1140
- Moore D F. Passive sonar target recognition using a back-propagation neural network. AD - A230081. Monterey, 1991

(下转第 124 页)

其阶跃响应仿真结果如图1所示。

例2 四阶被控对象为

$$y^{(4)} = -y - (1 - y^2)y' - \frac{1}{1 + y^2}$$

$$\log(1 + |y^{(3)}|) + 0.5 \operatorname{sign}(\cos(0.4t)) + u$$

其仿真结果如图2所示。




图2 例2仿真结果

这两个例子中, $w(t) = 0.5 \operatorname{sign}(\cos(0.4t))$ 是方波外扰。串联型 ESO 的每个二阶子系统的参数都取 $\alpha = 0.2$, $\beta_{01} = 1000$, $\beta_{02} = 100$ 。图中, x 是安排的过渡过程, y 是实际响应, u 是控制量, f 是对象右端除 u 以外的扰动总和量, 而 z 是扰动总和量的估计, 几乎重合。

4 结 语

高阶 ADRC 结构中所含高阶 ESO 的参数是较难调整的。为此本文提出了用低阶 ESO 串联型代替高阶 ESO 的方法。该方法尽管提高了 ESO 的阶数, 但对参数调整却带来了极大方便, 并且用串联型 ESO 改造的 ADRC 控制高阶对象仍十分有效。

参 考 文 献

- 1 韩京清 一类不确定对象的扩张状态观测器 控制与决策, 1995, 10(1): 85- 88
- 2 韩京清, 张荣 二阶扩张状态观测器的误差分析 系统科学与数学, 1999, 10(4): 465—471
- 3 Hong Yiguang, Zhang Rong, Han Jingqing Nonlinear observer design and application. 见: 控制理论及其应用 98 年会论文集 宁波, 1998 233—236

作 者 简 介

张 荣 男, 1969 年生。1998 年于中国科学院系统科学研究所获系统理论博士学位, 现于重庆大学技术经济与管理博士后流动站工作。主要研究领域为控制系统的非线性设计, 混沌理论。

韩京清 见本刊 1998 年第 13 卷第 1 期第 23 页。

(上接第 88 页)

- 3 章新华. 神经网络在声纳目标识别中的研究进展. 火力与指挥控制, 1998, 3(1): 2—7
- 4 Duda R O, Hart P E. Pattern classification and scene analysis Menlo Park: John Wiley Publishers, 1973
- 5 Hush D, Abdallah C, Horne B. Recursive neural network for signal processing and control In: Proc of the First IEEE- SP WNN SP. Albuquerque, 1991. 523-532
- 6 蔡悦斌, 黄采金, 史可智, 等. 动态神经元模型在水下目标识别中的应用. 模式识别与人工智能, 1998, 6(2): 199—205

作 者 简 介

刘 韬 男, 1975 年生。解放军空军工程大学工程学院通信与信息系统专业硕士研究生。目前主要从事航空电子综合化系统, 自动化指挥系统等方面的科研工作。

张殿治 男, 1939 年生。空军工程学院教授。多年从事电路与系统, 功率电子学, 神经网络与模糊控制及其应用等方面的研究工作。

赵学云 女, 1963 年生。1999 年毕业于空军工程大学工程学院研究生部, 现为海军航空技术学院教员。目前主要研究自适应信号处理理论。

李 映 女, 1970 年生。西安电子科技大学博士研究生。目前主要研究神经网络与进化算法在电子系统中的应用。