

一种有效的神经网络检测器*

胡卫东 郁文贤 郭桂蓉

(国防科技大学 ATR 重点实验室 长沙 410073)

摘要 本文提出了一种有效的神经网络检测方法。该方法通过高效的自组织学习过程,使该神经网络对各种噪声或杂波分布能够快速准确地建模,最终能使在各种噪声分布条件下检测效果均逼近最佳检测器的性能。实验结果验证了该方法的有效性。

关键词 检测器,神经网络,自组织,快速建模

分类号 TN911.23

An Effective Neural Network Detector

Hu Weidong Yu Wenxian Guo Guirong

(ATR Lab. NUDT, Changsha, 410073)

Abstract An effective detection method based on the neural network is proposed in this paper. By the self-organizing learning in high efficiency, it can model different kinds of noise or clutter rapidly and accurately. This results in a good detection performance, and this detector can approximate the optimal ones on the condition of different statistical distributions. Finally the experiments have proved the effectiveness of this approach.

Key words detector, neural network, self-organizing, fast modeling

战场环境复杂多变,提高探测系统的目标检测能力显得特别重要。该领域一直是各国学者的研究热点。目前的研究内容主要集中于以下几个方面^[1]: (1) 研制更加精密准确的高灵敏度探测传感器; (2) 对背景环境引入的观测噪声或干扰进行准确建模,针对各种已知分布的噪声或干扰设计最佳的检测判决器; (3) 采用自适应信号处理手段去除、对消和压制各种噪声或干扰,使探测系统具有更强的适用性。目标检测问题的研究,虽然在理论上已日趋完善,各种方法也层出不穷,但就其战场应用而言,对观测噪声或干扰的快速准确建模已成为有效解决检测问题的瓶颈,而采用经典的统计处理方法很难达到

* 国防预研基金资助项目
1996 年 10 月 16 日收稿

高效、准确的要求。近年来,人工神经网络信号处理技术^[2]的迅猛发展为解决该问题提供了可行的途径。尤其是神经网络具有自学习和并行处理能力,为构造智能化的神经网络检测器提供了可靠的保证。

对噪声或干扰建模的一种常用方法就是估计它们的概率密度分布。以往采用的核估计方法的主要缺陷是效率低,无法适用于复杂多变的背景环境。Kohonen 提出的自组织特征映射模型^[2]在估计被测样本的概率分布方面具有潜在的应用前景^[3],但它同样存在着收敛速度慢、依赖于样本输入顺序、网络参数需要启发式调整等缺点。为此,本文从改进 Kohonen 神经网络出发,提出了模糊自组织神经网络模型,在此基础上构造了一种适用于复杂场景下实时目标检测的神经网络检测器。

1 模糊自组织神经网络

经典 Kohonen 神经网络局部性的根源在于:它的学习策略是从局部有序过程逐步演化为全局有序的过程。这种串行的输入调整方式无法体现生物神经网络的有效学习策略。人的神经系统对很多外界事物的感知,一般是通过整体优先策略的引导,并借助神经元侧抑制作用来实现的;而整体优先策略则是通过模糊处理来实现。文献^[4]通过将模糊 c-均值的模糊软划分策略与经典的 Kohonen 算法相结合,提出了一种模糊自组织神经网络(简称 FSONN),较好地实现了上述思想。

模糊 c-均值对数据集 $X = \{x_1, x_2, \dots, x_n\}$ 的聚类,通过下面的迭代完成的:

$$u_{ik} = \frac{1}{\sum_j (\|x_k - w_i\|^A / \|x_k - w_j\|^A)^{2/(m-1)} } \quad (1a)$$

$$w_i = \frac{\sum_k (u_{ik})^m x_k}{\sum_k (u_{ik})^m} \quad (1b)$$

其中 $m > 1$, $\|x_k - w_i\|^A > 0, \forall i, k$ 。

上式中 $m \in [1, \infty)$ 是每个模糊隶属度的加权幂指数, U 是 X 的模糊 c-划分, A 代表某一范数意义下, x_k 到样本空间内聚类中心 $w_i (i = 1, \dots, c)$ 的距离。

隶属函数 u_{ik} 体现了对样本集 X 的模糊划分过程。将 (1) 式与 Kohonen 网络中的神经元侧抑制作用相结合,可以获得一种体现整体优先策略的模糊自组织神经网络算法。采用高斯形式的侧抑制函数,有

$$u_{ik} = \begin{cases} \frac{\|x_k - w_i\|^{\frac{2}{A}}}{\sum_j \|x_k - w_j\|^{\frac{2}{A}}} & \text{(由(1)式计算)} \\ \frac{1}{C} \exp\left\{-\frac{(i - i_k^*)^2}{2\sigma^2}\right\} & \text{其它} \end{cases} \quad (2)$$

其中 C 为归一化常数, i_k^* 为样本 x_k 最匹配神经元, σ 由隶属度最大值根据 (2) 式确定。该算法的具体步骤可概述如下:

- (1) 给定网络输出节点数 c , A 和某一较小的正常数 ϵ 。
- (2) 初始化权矢量 $w_i(0), i = 1, \dots, c$, 选择 $m_0 > 1$ 和 $n_{max} =$ 迭代上限。
- (3) 对于 $n = 1, 2, \dots, n_{max}$ 用下式计算所有的学习率 $\{\alpha_k(n)\}$:

$$\alpha_k(n) = (u_{ik}(n))^{m(n)},$$

其中 $m(n) = (m_0 - n\Delta m), \Delta m = (m_0 - 1) / n_{max}$ 。

用下式更新所有的权矢量 $\{w_i(n)\}$:

$$w_i(n+1) = w_i(n) + \left[\sum_k \alpha_{ik}(n)(x_k - w_i(n)) \right] \sum_s \alpha_{is}(n)$$

计算 $E(n+1) = \sum_i w_i(n+1) - w_i(n)^2$ 。

若 $E(n+1) \leq \epsilon$ ，则停止；否则进行下一次迭代。

通过测试表明（详见 [5]），该网络与经典 Kohonen 网络相比具有如下优越性：

- (1) 网络收敛与数据输入顺序无关。
- (2) 收敛速度快。FSONN 的迭代次数比 Kohonen 要少得多。
- (3) 无需对学习率、侧抑制邻域大小等参数进行启发式调整。

2 概率分布的获取

获取观测噪声的概率分布对后续的检测处理带来很大的方便。利用 Kohonen 神经网络的矢量量化能力获得输入样本数据的概率分布，其过程概述如下^[5]：

- (1) 将观测样本数据进行预处理，压缩数据量，抽取有效特征。
- (2) 将等数量的信号和噪声的特征数据送入网络训练。网络收敛后，便可得到所有输入数据在网络输出各节点上的响应频数。
- (3) 将信号和噪声样本在各节点的响应频数分别进行归一化平滑处理，便得到了信号和噪声在该神经元域内的概率分布 $p(X|H_i)$ ， $i = 0, 1$ 。 H_i 表示待选假设。

由于这种概率分布是离散化的，故要想获得比较准确的结果，首先网络的输出节点要充分多，其次要用内插方法进一步提高估计精度。前一点对于经典的 Kohonen 网络来说，在短时间内收敛是难以做到的。

3 检测器的构造

检测器的结构如图 1 所示。样本数据（包括已知的和待检测的）经预处理之后，已知的样本直接送入 FSONN 进行训练，计算网络的权矢量及信号和噪声的概率密度分布，然后将其用于对未知样本的检测。同时，检测的结果又使未知的样本变为已知，将它们用于更新旧的样本，使网络始终能够跟上输入样本的变化。检测器采用似然比准则：

$$\Lambda(X) = \frac{p(X|H_1)}{p(X|H_0)} \stackrel{H_1}{\geq} \frac{P(H_1)}{P(H_0)} \quad (4)$$

如果已知信号和噪声出现的先验概率，检测结果即可准确获得。

4 实验结果及性能比较

对检测器来说，衡量其性能的重要指标就是接收机工作特性曲线 (ROC)。本文从以下几个方面研究和比较 FSONN 检测器的性能。

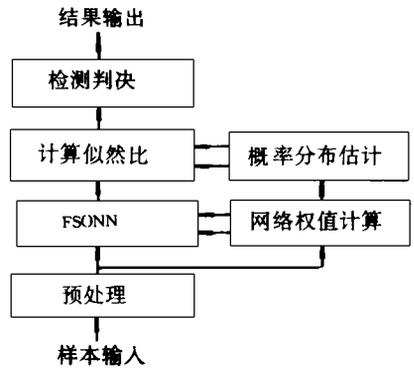


图 1 FSONN 检测器的结构示意图

(1) 收敛性。要得到比较准确的检测结果，网络规模是保证所获得的概率分布准确性的关键。以网络输出层为一维线阵为例，设观测样本为标量且服从正态分布，满足

$$H_0: z \sim N(0, 1); H_1: z \sim N(1, 1),$$

$$\text{且 } P(H_0) = P(H_1)$$

图 2 绘出了 FSONN 输出层取不同节点并采用线性内插情况下求出的接收机工作性能曲线(ROC)。由图中可见，当网络输出节点数目为 15 个时已比较准确。为计算的可靠性起见，后面的计算网络输出节点取为 30 个。

(2) 正态分布条件下的性能比较

图 3 和图 4 绘出了 FSONN 检测器在加性噪声样本服从正态分布的条件下，不同信噪比的 ROC 曲线与理想曲线。从图中可见，两者相差无几。

(3) 其它分布条件下的性能比较

为了测试 FSONN 检测器在其它噪声分布环境下的检测性能，本文采用瑞利分布和泊松分布的噪声样本进行检验。对于雷达信号而言，噪声的统计特性通常认为服从瑞利分布。瑞利噪声 n 可由两个高斯分布的噪声取包络得到，即 $n = \sqrt{x^2 + y^2}$ ，其中 $x, y \sim N(0, \sigma^2)$ 且统计独立。在图 5 的例子中，取 $\sigma^2 = 1$ 。红外图像中的热噪声是离散化的，它相当于热电子的激励。通常认为其分布近似于泊松分布。设 n_i 表示红外图像中像素点的能量等级（或热辐射强度）。当只有噪声出现时，如果 n 是热电子的激励数目，则 n_i 等于 n 的概率为 $p(n_i = n | H_0) = \frac{\nu^n}{n!} e^{-\nu}$ 。当信号 s （传感器接收到的能量）出现时，像素点的能量将增加 s ，有 $p(n_i = n | H_1) = \frac{\nu^{(n-s)}}{(n-s)!} e^{-\nu}$ 。在图 6 中，

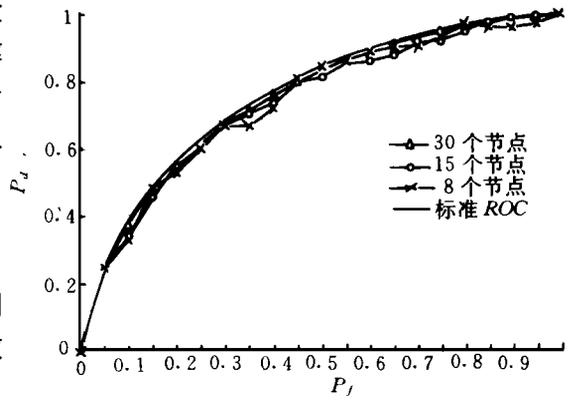


图 2 FSONN 不同输出节点下的 ROC 曲线收敛

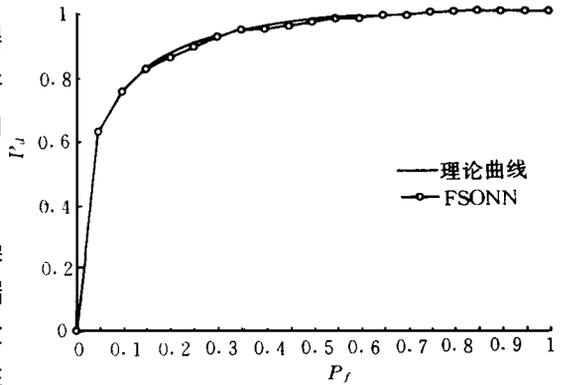


图 3 噪声服从正态分布的 ROC 曲线, SNR= 3dB

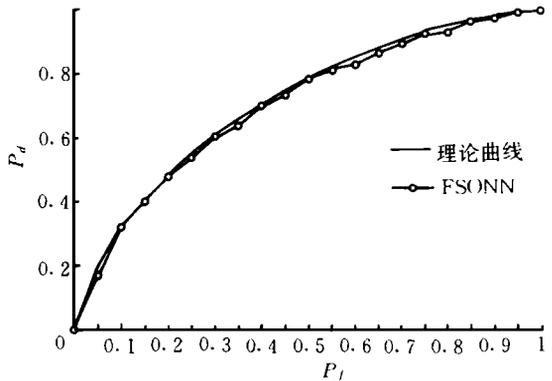


图 4 噪声服从正态分布的 ROC 曲线, SNR= -1dB

v 取为 2500, s 取为 1000。

图 5 和图 6 分别给出了上述两种噪声样本分布条件下, FSONN 检测器的工作特性曲线以及与理论结果的比较。从图中可见, 两者吻合得很好。

5 结 论

在复杂背景环境下的快速建模对提高探测系统的检测能力具有重要意义。本文利用模糊自组织神经网络所具有的快速自组织、自学习能力, 从获取概率分布的角度, 阐述了自组织神经网络检测器的结构和工作过程。利用各种统计分布的噪声进行检验, 表明效果良好。

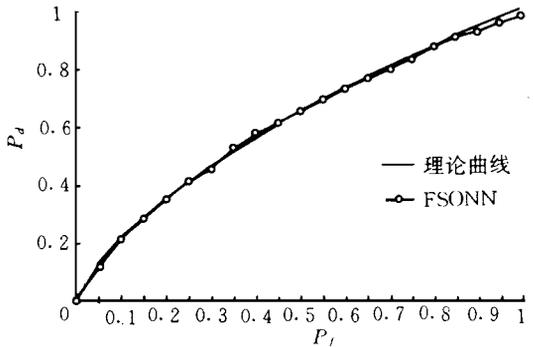


图 5 噪声服从瑞利分布的 ROC 曲线

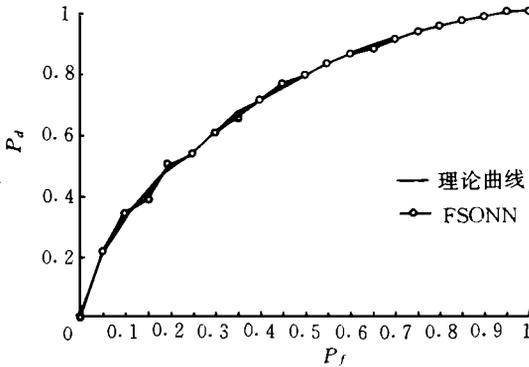


图 6 噪声服从泊松分布的 ROC 曲线

参 考 文 献

- 1 罗发龙, 李衍达. 神经网络信号处理. 北京: 电子工业出版社, 1993
- 2 Kohonen T. Self-Organization and Associative Memory. 3rd Edn. Springer, Berlin, 1989
- 3 Rogers G W, Solka J, Malyevac D S, Priebe C E. A self-organizing network for computing a posteriori conditional class probability. IEEE Trans. Syst., Man, and Cybernetics, 1993 (23): 1672 ~ 1682
- 4 胡卫东, 郁文贤. 模糊自组织特征映射. 模糊数学与系统, 1997
- 5 郁文贤, 胡卫东等. 一种新的弱目标自组织模糊分类方法. 电子学报, 1996 (6): 67 ~ 71

(责任编辑 潘 生)