

高精度 RBP-模糊推理复合学习系统

权 太 范

(哈尔滨工业大学无线电工程系 哈尔滨 150001)

摘 要

该文提出了高精度 RBP-模糊推理复合学习系统。系统主要由基于鲁棒估计的鲁棒 BP 学习环节和基于混合合成推理的模糊推理环节构成。该学习系统的主要特点是可由鲁棒 BP 算法和 min-max, max-min 模糊推理算法简单地实现。最后通过在目标跟踪问题中应用结果,表示了该算法的高精度和鲁棒性。

关键词: BP 神经网络,模糊推理,鲁棒估计,目标跟踪系统。

1 引言

近几年来应用神经网络和模糊推理的融合技术,构造学习系统的研究受到广泛的重视^[1,2]。这种融合方法,可利用神经网的非线性映射学习功能和模糊推理的规则库,更客观地描述控制系统的同时,使系统具有处理不确定状态的学习功能。综合已发表的文献,可分为三种融合模式。一是模糊推理控制研究中引入神经网络技术解决隶属度最优设计,知识自动获取等问题。二是在神经网络设计中引入模糊推理技术,改善神经网络结构可修正性。三是各自独立工作,分别完成系统不同的功能。神经网络和模糊推理都是根据训练样本知识(不是数学模型)实现非线性映射的一种网络算法。因此,在实际应用中能否得到良好的学习(训练)数据,是设计学习系统的关键。然而,在实际学习系统中不但存在概率意义上的随机噪声,而且也存在训练样本的模糊性。这类问题的研究,需要引入神经网络和模糊推理的融合技术。本文在文[3,4]基础上主要研究在非高斯分布干扰和训练样本模糊环境中的学习系统设计问题。本文首先提出了鲁棒神经网络和权重动态模型新概念,建立了鲁棒误差反向传播算法(以下简称为 RBP: Robust Back Propagation)。在 RBP 网基础上,用快速混合模糊推理机构提高了整个学习系统性能。最后给出了应用本文学习算法,提高某超视距雷达目标跟踪精度的部分试验结果。

2 RBP 算法

2.1 RBP 算法推导

设三层 BP 网络,各层参数为

$U' \triangleq (u_1, u_2, \dots, u_n)$: 训练样本向量,

$O' \triangleq (o_1, o_2, \dots, o_m)$: 输出向量,

$V' \triangleq (v_1, v_2, \dots, v_h)$: 隐层输出向量,

$Q'_1 \triangleq (Q_1, Q_2, \dots, Q_n)$: 隐层阈值向量,

$Q'_2 \triangleq (Q_1, Q_2, \dots, Q_m)$: 输出层阈值向量.

$\{W_{ij}^1\}_{h \times n}$, $\{W_{ik}^2\}_{m \times h}$: 分别为隐层及输出层的权重.

从参数估计观点看, 传统的 BP 学习算法是对给定的训练样本集 (U_i, Y_i) , $i = 1, 2, \dots, P$, 寻找使下面误差平方函数极小权重的一种非线性估计算法, 即

$$J = \sum_{i=1}^P J_i, \quad (2.1)$$

$$J_i = \frac{1}{2} \sum_{j=1}^m (y_{ij} - o_{ij})^2. \quad (2.2)$$

式中 P 为训练样本数, y_{ij} 为第 i 个样本的 j 个教师信号, m 为输出个数. 根据鲁棒估计理论可知, 这种估计显然不是鲁棒估计, 对野值十分敏感. 为此引入鲁棒评价函数, 构造在非高斯分布干扰下仍具有学习能力的 RBP 网络. 设评价函数 J 为

$$J = \sum_{i=1}^P J_i, \quad (2.3)$$

$$J_i = \sum_{j=1}^m \rho(e_{ij}), \quad (2.4)$$

式中 e 为训练误差.

定义. 若 BP 网评价函数(2.3)中 $\rho(e)$ 满足

- 1) $\rho(e)$ 处处连续.
- 2) $\rho(0) = 0$, $\rho(e) = \rho(-e)$ 且 $|e_i| \geq |e_j|$ 时有 $\rho(e_i) \geq \rho(e_j)$.
- 3) $\lim_{e \rightarrow \infty} \rho(e)/e^2 = 0$.

则称 BP 算法为 RBP 算法.

在此, 根据 M 估计理论, 令 Hampel 函数为 $\rho(e)$. 即

$$H(a, b, c) = \rho(e) = \begin{cases} \frac{1}{2} e^2 & |e| \leq a \\ a|e| - \frac{1}{2} a^2 & a < |e| \leq b \\ ab - \frac{1}{2} a^2 + (c-b) \frac{a}{2} \left[1 - \left(\frac{c-|e|}{c-b} \right)^2 \right] & b < |e| \leq c \\ ab - \frac{1}{2} a^2 + (c-b) \frac{a}{2} & |e| > c \end{cases} \quad (2.5)$$

经推导可得如下 RBP 算法,

$$W_{ji}(k+1) = W_{ji}(k) + \eta \delta_j o_i + \alpha (W_{ji}(k) - W_{ji}(k-1)), \quad (2.6)$$

$$Q_j(k+1) = Q_j(k) + \eta \delta_j + \alpha (\bar{Q}_j(k) - Q_j(k-1)). \quad (2.7)$$

式中

$$o_j = f_j(\text{net}_j) = 1 + \exp\left(-\sum_i W_{ji}o_i - Q_j\right)^{-1}, \quad (2.8)$$

$$\delta_j = \begin{cases} o_j(1 - o_j)\phi(e) & \text{(输出层),} \\ o_j(1 - o_j) \sum_k \delta_k W_{kj} & \text{(隐层)} \end{cases} \quad (2.9)$$

$$f'(\text{net}_j) = \frac{\partial o_j}{\partial \text{net}_j} = o_j(1 - o_j). \quad (2.10)$$

式中 $f(x)$: sigmoid 函数, η : 学习速率, α : 惯性项常数, $\phi(e) = \rho(e)$.

由此可知,在传统的BP算法输出的训练误差 δ_j 是误差的线性函数,即 $\delta_j = o_j(1 - o_j)(y_j - o_j)$, 因而随野值所产生的误差 $(y_j - o_j)$ 线性地作用于训练误差的计算,从而引起学习性能的严重下降.然而在 RBP 算法中(由式(2.9)可见)输出层的 δ_j 不再是误差的线性函数,而是 Hampel 函数 $\phi(e)$ 的函数,因此对大误差(即对野值)具有鲁棒(限幅)特性.在实际训练学习中,为加快学习,可采用修正的 Sigmoid 函数和把 FP 法和 Broyden 法相结合的准牛顿法^[3].

2.2 权重动态模型

以往 BP 网的权重是一个确定常阵,因此很难适用于实际输入信号与原有学习样本有所变化的情况.为此本节探讨权重动态模型问题.首先把学习系统给定的训练精度 ϵ 看作是均值为 $\bar{\epsilon}$, 方差为 σ 的高斯随机向量.设 RBP 算法满足随机精度 ϵ 的 j 节和 i 节之间权重 w_{ij} 的全体作为时间序列,表示为 $W_k = \{w_{ij}\}$, $k = 1, 2, \dots, N$, N 为满足指标的权重 w_{ij} 个数.

设权重 w_{ij} 的动态模型为

$$w_{ij}^k = w_{ij}^{k-1} + \xi_{ij}^k, \quad (2.11)$$

$$w_{ij}^0 = \bar{W}_N, \quad k = 1, 2, \dots, N. \quad (2.12)$$

下面先讨论如何给定 \bar{W}_N . 因样本均值对敏感度曲线无界,为此用平尾均值方法求序列 W_k 的均值 \bar{W}_k , 并令它为其动态模型的初值 w_{ij}^0 . 即

$$\bar{W}_{k+1} = \bar{W}_k + \frac{1}{k} h_m(W_k - \bar{W}_k), \quad (2.13)$$

$$\bar{W}_1 = W_1, \quad k_1 = 1, 2, \dots, N-1, \quad (2.14)$$

其中轻限幅器 h_m 为

$$h_m(x) = \begin{cases} m & x \geq m \\ x & |x| < m \\ -m & x \leq -m \end{cases} \quad (2.15)$$

若噪声方差为 1 时, m 可取 1—2. 其次假设随机噪声 ξ_{ij}^k 是均值为零, 方差为 σ_{ij} 的高斯噪声. 即

$$\sigma_{ij} = \sqrt{\frac{1}{N} \sum_{k=1}^N (W_k - \bar{W}_N)^2}. \quad (2.16)$$

3 RBP-模糊推理学习

3.1 系统结构

为提高 RBP 算法识别率(或适应率),引入模糊推理机构,并采用如图 1 所示的系统结构。设目标输出向量为 $Y_i = (y_1, \dots, \dots y_m)$, $i = 1, 2, \dots, P$, k 时刻 RBP 网输出为 $O_k = (o_1, o_2, \dots, o_m)$ 。若 $\|Y_n - O_k\| < \|Y_i - O_k\|$, 则 $O_k \in Y_n$, ($n \neq i$)。又若 $\|Y_n - O_k\| \leq \varepsilon$, 则判定 RBP 学习正确, 即 $O_k \in Y_n$ 。反之, 若 $\|Y_n - O_k\| > \varepsilon$, 则认为 RBP 学习含有模糊性(或学习有误), 用模糊推理机构进一步评价(修正) RBP 学习结果。其中 ε 为给定的误差。

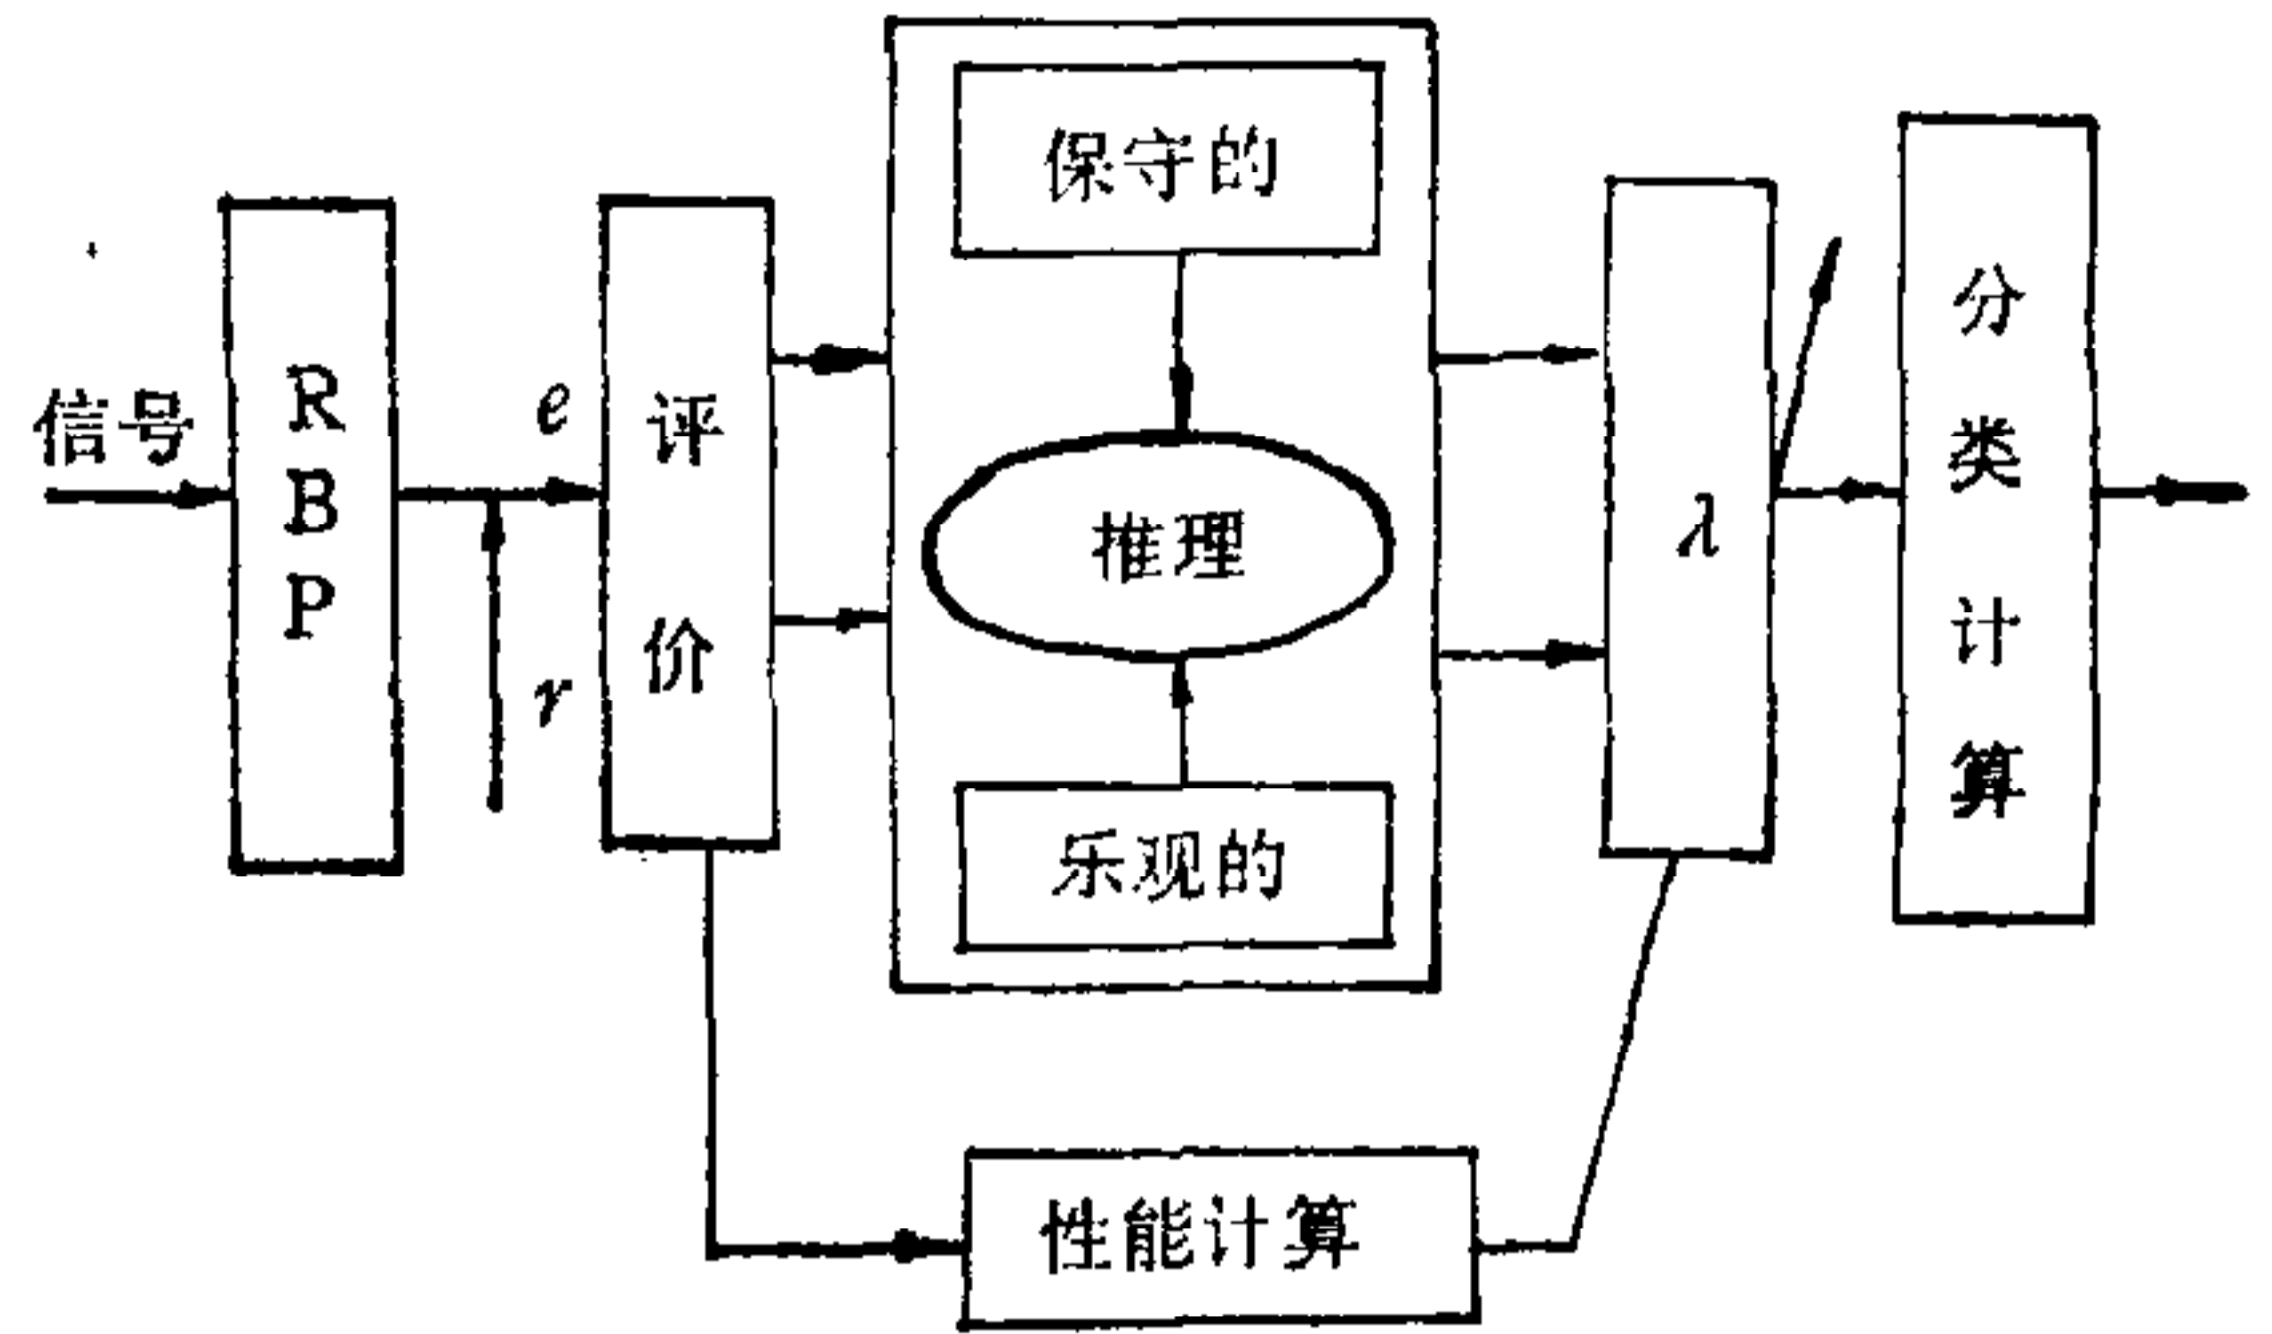


图 1 RBP-模糊推理复合学习系统

设 RBP 网输出误差 e 和部分误差

d 的模糊集分别记为 E, D , 则推理规则 R_i 可表示为

$$R_i: e = E_i, d = D_i \rightarrow m = M_i, \quad (3.1)$$

$$i = 1, 2, \dots, l$$

其中 $e = \sum_{i=1}^m (y_i - o_i)^2, d = \sum_{i=1}^n (y_i - o_i)^2.$ (3.2)

$m > n$, m 为 RBP 网输出数。

3.2 快速混合模糊推理

为实现快速推理,把原有规则库分为基于保守决策的保守规则库和基于乐观决策的乐观规则库,并分别用下标 P 和 O 来加以区分。对保守规则库有

$$\tilde{R}_P = \bigcup_{i=1}^{l_1} W_{Pi} \tilde{R}_{Pi} \in \mu_{n \times m} \quad (3.3)$$

$$M_P(m_{Pi}) = \tilde{R}_P \circ (E_P \times D_P) = \tilde{R}_P \circ F_P \in \mu_{1 \times n}. \quad (3.4)$$

并对乐观规则库有

$$\tilde{R}_O = \bigcup_{i=1}^{l_2} W_{Oi} \tilde{R}_{Oi} \in \mu_{n \times m} \quad (3.5)$$

$$M_O(m_{Oi}) = \tilde{R}_O \circ (E_O \times D_O) = \tilde{R}_O \circ F_O \in \mu_{1 \times n}. \quad (3.6)$$

其中 \tilde{R}_i 为对应规则 i 的关系阵, $\tilde{R}_O = \{r_{Oij}\}, F_O = \{f_{Oij}\}, F_P = \{f_{Pij}\}, l_1, l_2$ 分别为各规则库的规则数, W_i 为对第 i 个规则的加权。这里有 $\sum_{i=1}^{l_1} W_{Pi} = 1, \sum_{i=1}^{l_2} W_{Oi} = 1$ 。可用排序法确定 W_i [5]。对(3.4)做保守推理、即 min-max 合成有

$$m_{Pi} = \bigvee_{j=1}^m (r_{Pij} \wedge f_{Pij}), \quad i = 1, 2, \dots, n, \quad (3.7)$$

对(3.6)做乐观推理、即 max-min 合成有

$$m_{oi} = \bigwedge_{j=1}^m (r_{oj} \vee f_{oj}), \quad i = 1, 2, \dots, n, \quad (3.8)$$

为综合这两种合成,引入混合因子 λ , 并构造如下混合推理算法,即

$$m_i = (1 - \lambda)m_{pi} + \lambda m_{oi}, \quad 0 \leq \lambda \leq 1, \quad (3.9)$$

可见, λ 的大小直接反映了对上述两种推理的混合程度。关于混合因子 λ 的自校正规律有待进一步探讨^[5]。

4 机动目标跟踪系统中应用

4.1 试验系统结构及条件

本节将给出作者所在研究所研制的我国第一部某超视距雷达系统中应用本算法提高目标跟踪精度的一些试验结果。如图 2 所示,本学习算法可作为该雷达目标跟踪系统(多重结构跟踪器)的目标分类器。

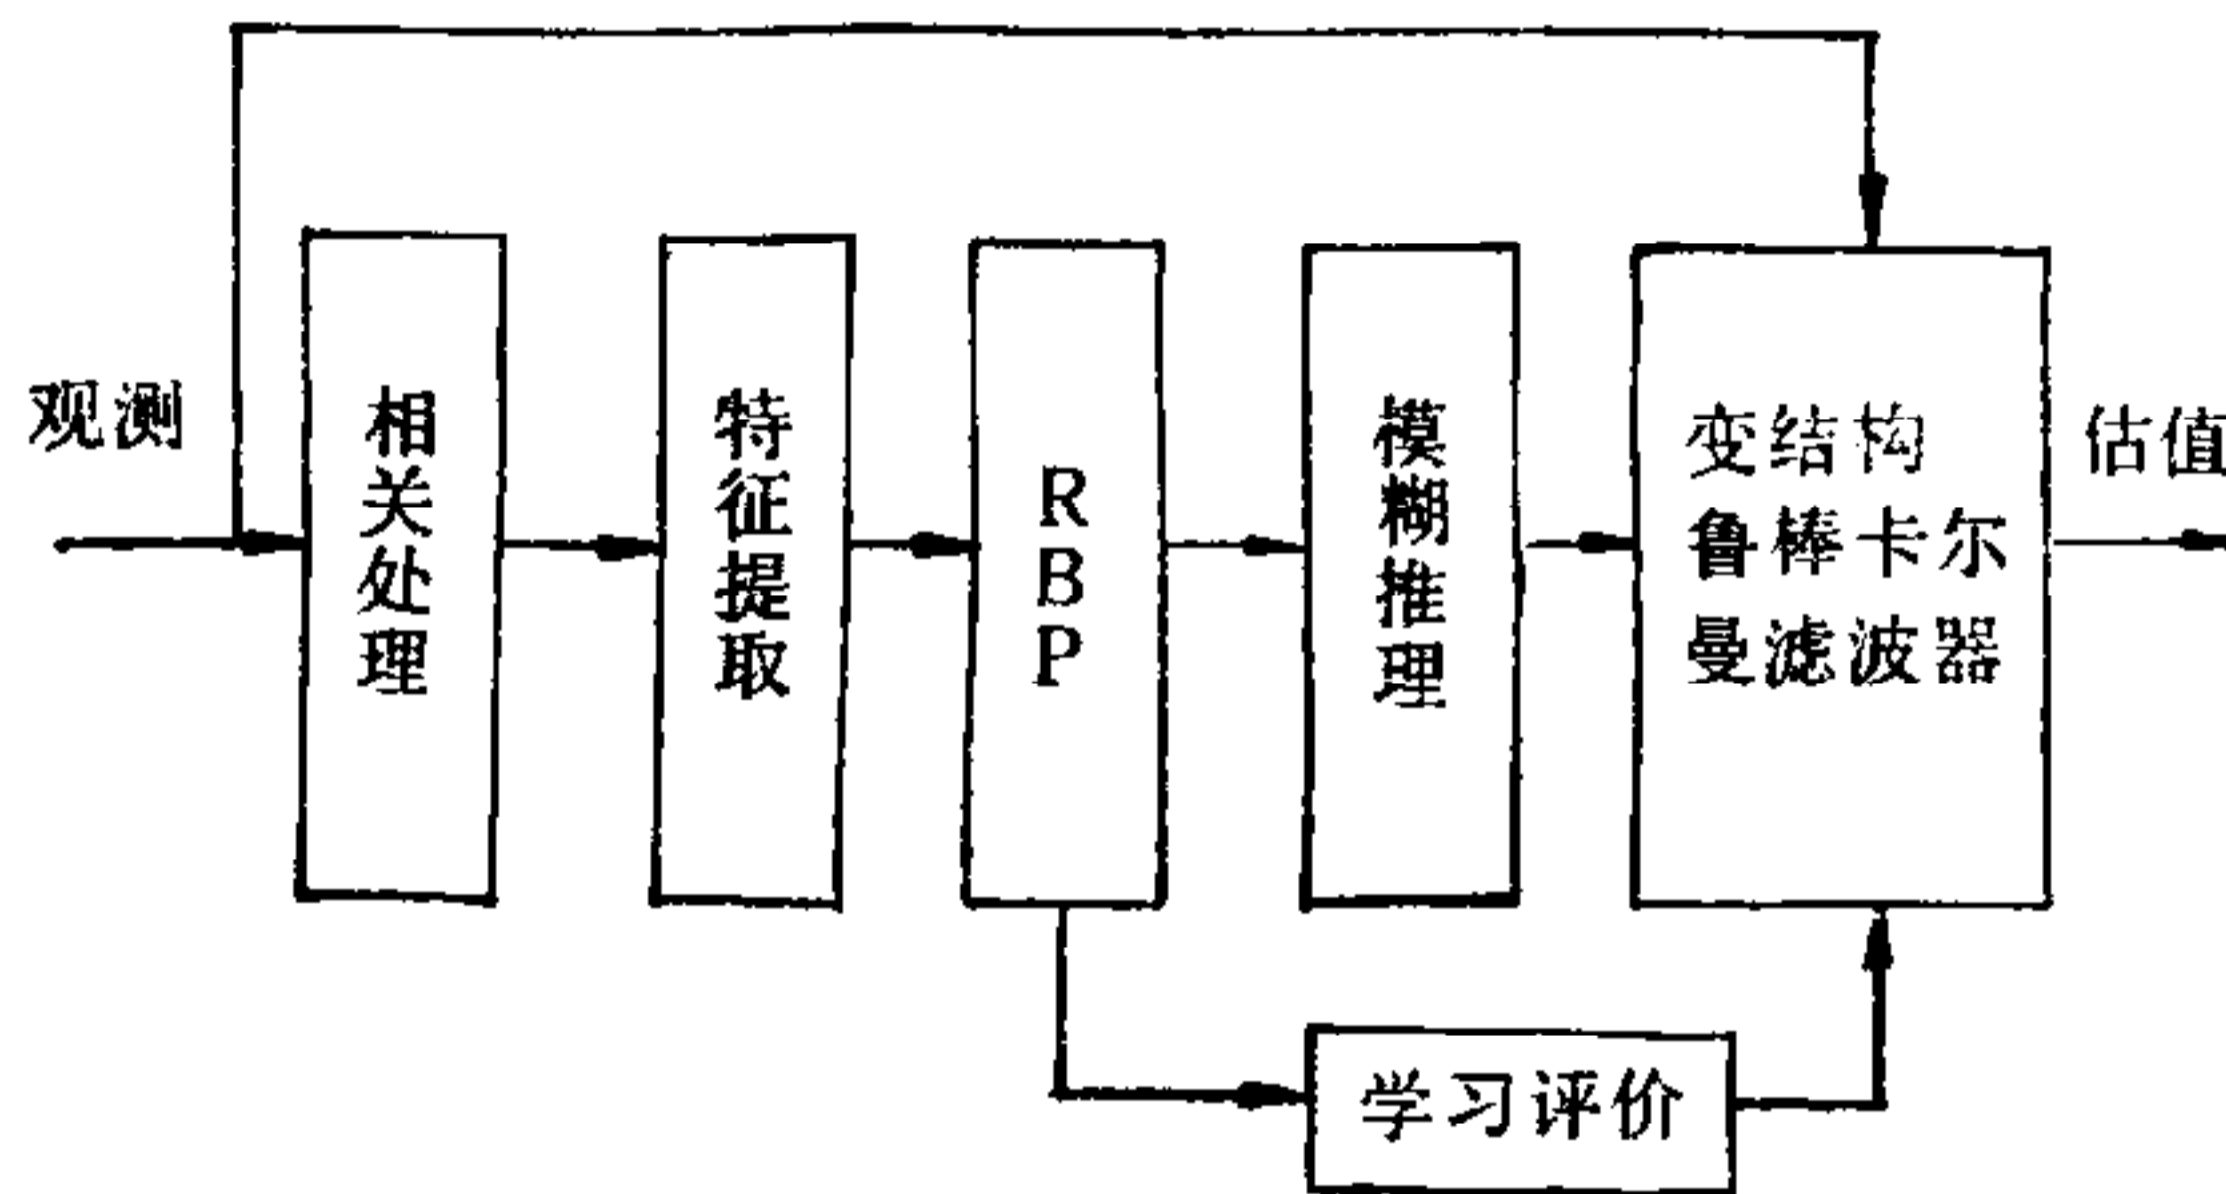


图 2 雷达目标跟踪系统

图中,观测数据是经该雷达的发射机,接收天线阵,波束形成网络、信号处理机、检测器与估值器等设备得到的;相关处理环节的主要任务是真假目标分类和同一个波束内多个近相距目标的分辨。跟踪模型采用变维跟踪滤波模型^[6],并根据目标运动特性,选择不同的系统

噪声特性。因该雷达测角特性和其观测精度较差,角通道采用了自适应鲁棒平滑器。^[7]

非机动目标模型分为径向、相对平行与 x 轴或 Y 轴等三种,并把对应于该模型的鲁棒卡尔曼滤波器分别记为 RKF1, RKF2, RKF3。机动目标模型分为弱、强机动二种,并把相对应的鲁棒卡尔曼滤波器分别记为 RKF4, RKF5。^[7] RBP 网输入端特征提取及训练样本见附录 A。规则库是由现场试验和仿真构造的。

4.2 试验结果

表 1 给出了近几年来该雷达站录取的试验数据中,挑选典型的 27 次试验数据来进行各种跟踪滤波算法的统计均方误差。在每一次试验数据中包括几十批非合作目标数据。在精度计算中对非合作目标因不知道目标真实轨迹,为此把经相关处理后的所有观测值的分段曲线拟合作为理想轨迹而进行的。在表 1 中,类型号分别表示

- 1) 基于等速运动模型的跟踪精度
- 2) 基于机动运动模型的跟踪精度
- 3) 采用 BP-模糊推理学习算法的跟踪系统精度
- 4) 采用 RBP-模糊推理学习算法的跟踪系统精度
- 5) 采用 RBP (即无模糊推理)学习算法的跟踪系统精度

表 1

类型 \ 精度	距离(公里)	方位角(度)	速度(公里/小时)
1	0.68	0.59	0.34
2	0.64	0.72	0.30
3	0.56	0.43	0.29
4	0.28	0.24	0.16
5	0.41	0.33	0.24

由试验结果可知,基于 RBP 学习算法的跟踪精度优于 BP 算法,本文提出的学习算法可提高 RBP 网学习识别率,因而有效地实现多重结构跟踪系统。

5 结论

1) 采用鲁棒性能指标(2.3)设计的 RBP 算法比传统的 BP 算法具有更高的鲁棒特性。这对提高神经网络的推广能力具有积极的意义。

2) 混合模糊推理一是把原有(庞大的)规则库分为保守和乐观两个子库,二是混合两种合成推理,因而可实现快速推理。

3) 神经网络和模糊推理的融合技术是解决系统随机性和模糊性两大问题的一种有效途径,也是实现高精度学习系统的一种方法。

4) 应用结果表明,这种学习算法对多目标相关处理、跟踪滤波等方面具有很大的潜力。同样,本算法可推广到复杂系统的控制和信号处理。

注: 文[3],[4]的第二作者白井良明教授是日本模式识别学会委员长。

参 考 文 献

- [1] Bart Kosko. Neural networks and fuzzy systems, Prentice-Hall, Inc., 1992.
- [2] Hayashi. Fusion method between fuzzy control and neural networks. *Electronic Technology*, 1992, 34(1):17—20.
- [3] 权太范, 白井良明. Robust Back-Propagation error learning using robust estimator, 信学技報, 1992, NC92, 107: 15—24.
- [4] 权太范, 白井良明. A robust BP-Fuzzy reasoning system for learning combination, 信学技報, 1992, NC92, 230: 44—59.
- [5] 权太范, 宗成阁. 变结构自校正模糊控制系统及其应用. 控制理论与应用, 1989, 3: 114—122.
- [6] Bar-Shalom Y, Birmiwal K. Variable dimension filter for maneuvering target tracking. *IEEE Transactions on AES*, 1982, 18(5): 611—619.
- [7] 权太范, 刘永坦. 提高角跟踪精度的自适应鲁棒平滑器. 宇航学报, 1991(3): 63—67.

附 录 A

表 A

	训 练 模 式						教师信号
	Δx_0 Δy_0	$\Delta \theta_0$	Δv_0	Δx_1 Δy_1	$\Delta \theta_1$	Δv_1	$y_1 y_2 y_3 y_4$
等速运动 1	1 1	0 0	0 0	1 1	0 0	0 0	0 0 1 0
等速运动 2	1 0	0 1	0 1	1 0	0 1	0 1	0 1 0 0
	1 0	1 0	0 1	1 0	1 0	0 1	
等速运动 3	0 1	0 1	0 1	0 1	0 1	0 1	1 0 0 0
	0 1	1 0	0 1	0 1	1 0	0 1	
弱机动运动 4	0 1	0 1	1 0	0 1	0 1	1 0	0 0 0 1
	1 0	0 1	1 0	1 0	0 1	1 0	
强机动运动 5	1 0	1 0	1 0	1 0	1 0	1 0	1 0 0 1
	0 1	1 0	1 0	0 1	1 0	1 0	

表中, $\Delta X_0 = X(k-1) - X(k-2)$, $\Delta X_1 = X(k) - X(k-1)$, x, y 分别表示径向距离 r 在 $X-Y$ 坐标系上的分量, θ 为方位角, v 为速度, 1: 有变化, 0: 无变化, 00: 无变化, 01: 小变化, 11: 大变化. 三层 RBP 网的输入端个数为 12, 输出端个数为 4, 隐层节点数为 9.

A HIGHLY ACCURATE ROBUST BP-FUZZY REASONING SYSTEM FOR LEARNING COMBINATION

QUAN TAIFAN

(Dept. of Radio Engineering, Harbin Institute of Technology Harbin 150001)

ABSTRACT

A new accurately robust BP-fuzzy reasoning system for learning combination is proposed. This learning system is mainly constructed with a robust BP network with fuzzy reasoning which replaced robust estimation and mixed fuzzy reasoning. The main feature of this learning system is a simple algorithm constructed from the following three parts: RBP learning algorithm, max-min fuzzy reasoning and min-max fuzzy reasoning. This learning system is applied to a target tracking problem. The results of test show that this tracking system is more accurate and more robust.

Key words: BP network, fuzzy reasoning, robust estimator, target tracking system.



权太范 1949年10月生 1977年清华大学电机系毕业,1983年哈尔滨工业大学自动控制专业研究生毕业。1990年晋升为教授。曾获国家科技进步一等奖和航天工业部科技进步一等奖。研究领域有多目标鲁棒跟踪,飞行器制导与控制,数据融合,模糊神经网络等。