

文章编号: 1001-0920(2002)04-0497-03

随机模糊神经网络在目标状态信息融合中的应用

龙翔¹, 敬忠良², 金德琨¹, 王安¹

(1. 西北工业大学 自动控制系, 陕西 西安 710072; 2. 上海交通大学 图像与信息处理研究所, 上海 200030)

摘要: 提出一种新的基于随机模糊神经网络的多传感器状态信息融合方法, 研究和比较了基于单值模糊神经网络和基于随机模糊神经网络的雷达与红外传感器状态信息融合。仿真结果表明, 当输入被噪声污染时, 基于随机模糊神经网络的方法离线学习次数更少, 能更有效地防止噪声的干扰, 并且融合误差更小。

关键词: 随机动态系统; 随机模糊神经网络; 状态信息融合

中图分类号: V 243.2

文献标识码: A

States information fusion based on stochastic fuzzy neural network

LONG Xiang¹, JING Zhong-liang², JIN De-kun¹, WANG An¹

(1. Department of Automatic Control, Northwestern Polytechnical University, Xi an 710072, China;

2. Image and Information Processing Institute, Shanghai Jiaotong University, Shanghai 200030, China)

Abstract: A stochastic fuzzy neural network is developed with parameter and structure learning. The stochastic fuzzy neural network is investigated for radar and infrared information fusion. The proposed method is compared with the fuzzy neural network method. Simulation results show that the proposed method is of much smaller training time and higher track accuracy.

Key words: stochastic dynamic system; stochastic fuzzy neural network; state information fusion

1 引言

雷达与红外传感器作为主动与被动传感器的典型代表, 用于目标跟踪各有所长^[1], 前者跟踪距离远, 测距精度高, 但角通道精度较差; 后者跟踪角精度虽高, 但却缺乏距离分量。由于多源信息融合系统能综合利用主、被动传感器信息, 从而扩大了跟踪系统的视野, 增强了系统的鲁棒性。雷达与红外融合方式有: 借用红外系统的隐蔽性, 排除对雷达的电磁干扰; 借用雷达为红外测距; 借用红外的角精度补偿雷

达的角精度。传统的多传感器状态信息融合方法, 如推广的联合概率数据关联方法^[2], 神经联合概率数据关联方法^[3]等, 当传感器和目标数目增多时, 存在难以克服的计算组合爆炸难题, 因此迫切需要建立一种智能融合方法。

为处理智能方法中的随机情况, 本文提出一种新的具有参数和结构学习的随机模糊神经网络, 并将其应用于多传感器状态信息融合。仿真结果表明该方法取得了令人满意的结果。

收稿日期: 2001-04-25; 修回日期: 2001-07-11

作者简介: 龙翔(1970—), 男, 四川成都人, 博士生, 从事多目标跟踪、图像处理等研究; 敬忠良(1960—), 男, 四川南部人, 教授, 博士生导师, 博士, 从事多目标跟踪、信息融合等研究。

2 基于非单值逻辑的随机模糊神经网络

2.1 参数学习

基于非单值逻辑的随机模糊神经网络(SFNN)非线性系统的数学表达式为^[4]

$$y = f(x) = \frac{\prod_{i=1}^M \bar{y}^i \left[\prod_{i=1}^n \exp\left(-\left(\frac{x_{i,\max}^l - m_{x_i}}{\sigma_{x_i}}\right)^2\right) - \left(\frac{x_{i,\max}^l - m_{F_i^l}}{\sigma_{F_i^l}}\right)^2\right]}{\prod_{i=1}^M \left[\prod_{i=1}^n \exp\left(-\left(\frac{x_{i,\max}^l - m_{x_i}}{\sigma_{x_i}}\right)^2\right) - \left(\frac{x_{i,\max}^l - m_{F_i^l}}{\sigma_{F_i^l}}\right)^2\right]} / \delta \quad (1)$$

$$x_{i,\max}^l = (\sigma_{F_i^l}^2 m_{x_i} + \alpha_i^2 m_{F_i^l}) / (\sigma_{F_i^l}^2 + \alpha_i^2) \quad (2)$$

式中, $\bar{y}^l, m_{x_i}, m_{F_i^l}, \sigma_{x_i}, \sigma_{F_i^l}$ 和 δ^l 为可调参数, δ^l 是决定输出隶属函数 $\mu^l(y)$ 形状的特征参数, 比如曲线的宽窄等。在 $x_{i,\max}^l$ 点上, 输出空间模糊集的隶属函数达到它的上确界。同样, 利用反向传播学习算法对非单值模糊逻辑系统参数 $\bar{y}^l, m_{x_i}, m_{F_i^l}, \alpha_i, \sigma_{F_i^l}, \delta^l$ 等进行训练, 从而达到模糊逻辑系统学习的目的。系统学习过程分为前向计算和反向调整两步: 第 1 步, 对于一组给定的输入 $x = (x_1, \dots, x_n)$, 沿网络前向计算出 y ; 第 2 步, 反向调整参数使网络误差最小。

2.2 结构学习

2.2.1 相似测度

对于两个矢量 $f, g \in R^n$, 根据欧几里得距离, 它们的相似测度可表示为

$$D = [f - g]^p \quad (3)$$

其中, p 为常数, 通常取为 2; \cdot 表示范数。采用其它相似测度方法, 如模糊相似测度、方差和马氏距离等, 也可获得类似的结果。

相似测度可以推广到在不同空间的多个矢量。假设 $f_1, f_2 \in R^n, g_1, g_2 \in R^m$, 那么 (f_1, f_2) 的距离矩阵为 $A = \{a_{ij}\}$, 这里 $a_{ij} = |f_i - f_j|$; (g_1, g_2) 的距离矩阵为 $B = \{b_{ij}\}$, 这里 $b_{ij} = |g_i - g_j|, i, j = 1, 2$ 。进而, 相似测度可定义如下

$$s = \prod_{i,j} (a_{ij} \ln \frac{a_{ij}}{b_{ij}} + b_{ij} \ln \frac{b_{ij}}{a_{ij}}), \quad i, j \quad (4)$$

2.2.2 结构学习

我们的任务是确定 SFNN 的最优结构, 即最优模糊规则数 M_p 。当模糊规则数为 M_p 时, 网络的计算量最小。结构学习的基本思想是: 最佳的 SFNN 最类似于训练样本 (即输入数据)。给定一个 SFNN, 对于输入空间的一个样本 $x(k) = [x_1(k), \dots, x_n(k)]$, k

$= 1, \dots, N$, 将对应于第 3 隐层空间的一个矢量 $z(k) = [z_1(k), \dots, z_M(k)]$ 和输出空间的一个标量 $y(k)$ 。因此, 输入数据 $x(k)$ 与对应的矢量 $z(k)$ 之间的相似测度可定义如下

$$s_1 = \prod_{i,j} (a_{ij} \ln \frac{a_{ij}}{b_{ij}} + b_{ij} \ln \frac{b_{ij}}{a_{ij}}), \quad i, j \quad (5)$$

其中, $a_{ij} = |x(i) - x(j)|$ 是 $N \times N$ 的距离矩阵 A 的元素, $b_{ij} = |z(i) - z(j)|$ 是 $N \times N$ 的距离矩阵 B 的元素, 这里 $i, j = 1, \dots, N$ 。 $z(k)$ 与 $y(k)$ 之间的相似测度可定义如下

$$s_2 = \prod_{i,j} (c_{ij} \ln \frac{c_{ij}}{b_{ij}} + b_{ij} \ln \frac{b_{ij}}{c_{ij}}), \quad i, j \quad (6)$$

其中 $c_{ij} = |y(i) - y(j)|$ 是 $N \times N$ 的距离矩阵 C 的元素, $i, j = 1, 2, \dots, N$ 。

整个网络的相似测度为

$$s(M) = s_1 + s_2 \quad (7)$$

式中 M 是 SFNN 中第 3 层的节点数。

SFNN 的最优结构就是使整个网络相似测度最小的结构, 即

$$M_p = \arg\{\min S(M)\} \quad (8)$$

这里 M_p 是 SFNN 中第 3 层的最优节点数。这种方法是一种离线结构学习算法。

3 基于 SFNN 的雷达与红外状态信息融合结构与算法

3.1 余弦坐标系下的机动目标模型

在余弦坐标系下, 雷达的目标量测为两个方向余弦 Λ_x 和 Λ_y 以及目标径距 R , 红外的目标量测只取两个方向余弦 Λ_x 和 Λ_y 。机动目标跟踪采用机动目标当前统计模型^[1]。

3.2 状态信息融合结构与算法

本文采用混联状态信息融合算法, 具体算法如下: 雷达采用自适应滤波算法对量测 $X_1 = [r \ \Lambda_x \ \Lambda_y]$ 进行跟踪滤波, 同时对 R 通道引入残差滤波, 得到滤波结果 $\hat{X}_1 = [r \ \hat{\Lambda}_x \ \hat{\Lambda}_y]$; 红外传感器则借用雷达径距滤波值 \hat{r} 对其量测 $X_2 = [\Lambda_x \ \Lambda_y]$ 进行跟踪滤波, 得滤波值 $\hat{X}_2 = [\hat{\Lambda}_x \ \hat{\Lambda}_y]$; 最后将雷达与红外方向余弦通道滤波结果送入随机模糊神经网络融合器进行融合, 随机模糊神经网络融合器采用离线训练、在线融合方式。输出 $\hat{X} = [R \ \hat{\Lambda}_x \ \hat{\Lambda}_y]$ 即为最终状态信息融合结果。

4 状态信息融合仿真分析

网络离线训练完毕后直接用于融合结构。本文仿真采用转圈运动的仿真曲线, 包括雷达和红外单传感器跟踪, FNN 融合和 SFNN 融合的 $r, \Delta x, \Delta y$ 三通道的估计均值误差、均方根误差(见表 1), 以及跟踪误差曲线(见图 1)。从表 1 和图 1 可以看出, 基于 SFNN 的状态融合方法具有较高的跟踪精度。更为重要的是, 由于引入了随机的概念, SFNN 可以更有效地防止量测噪声的干扰。

表 2 列出了采用不同的规则数进行训练时, 计算出的 SFNN 结构相似测度 $S(M)$ 。从表 2 可以看出, 最佳隐层节点数(规则数) $M_p = 11$ 时的相似测度最小, 并且相似测度并不是单调下降的。这可能是由于以下两方面原因: 1) 训练中使用的 BP 算法找

到的只是局部极小点, 而不是全局极小点; 2) 当达到最优节点数(规则数)后, SFNN 有获取训练样本中无关紧要的特征的可能。这便增加了网络的敏感性, 所以引起相似测度的变化。

5 结 论


本文提出一种新的基于 SFNN 的多传感器状态信息融合方法, 并分析和比较了基于 SFNN 和基于 FNN 的雷达与红外传感器状态信息融合算法。仿真结果表明, 当输入被噪声污染时, 基于 SFNN 的多传感器状态信息融合方法, 离线学习次数少, 跟踪误差小。该方法很容易推广到多传感器多目标的信息融合场合。

表 1 转圈运动目标估计的均值误差和均方根误差

融合方式	R 通道 / m		Δx 通道 / ($10e - 4$ rad)		Δy 通道 / ($10e - 4$ rad)	
	MS	RMSE	MS	RMSE	MS	RMSE
雷 达	105.27	462.18	- 10.91	90.22	- 7.12	135.73
红 外	—	—	8.14	68.11	9.33	102.06
FNN 融合	35.79	322.44	- 6.93	51.62	4.14	69.94
SFNN 融合	6.41	290.38	- 3.09	51.16	0.99	62.89

表 2 SFNN 的结构相似测度

规则数	7	8	9	10	11*	12*	13	14	
$S(M)$	Δx 通道	3.88	3.30	3.48	3.62	2.80	2.92	3.50	3.93
	Δy 通道	6.11	7.17	8.07	7.17	6.94	4.90	6.83	5.87



— · · · · · 雷达 - · · · · · 红外 - - - FNN — SFNN

图 1 转圈运动 Δx 通道跟踪误差曲线

参考文献(References):

[1] 敬忠良, 周宏仁, 王培德. 机动目标跟踪[M]. 北京: 国防工业出版社, 1991.
 [2] Chang C B, Tabaczynski J A. Application of state estimation to target tracking[J]. *IEEE Trans on Autom Control*, 1994, 39(2): 98-109.

[3] 敬忠良. 神经网络跟踪理论及应用[M]. 北京: 国防工业出版社, 1995.
 [4] Zhongliang Jing, Albert C J Luo, M Tomizuka. A stochastic, fuzzy, neural network for unknown dynamic systems[J]. *Dynam, Acous & Simul*, 1998, 98: 128-134.