

文章编号: 1001-0920(2001)01-0114-03

自组织 RBF 神经网络对驾驶员 主动安全性因素的辨识

马 勇¹, 杨煜普¹, 许晓鸣¹, 石 坚², 卓 斌²

(1. 上海交通大学 自动化研究所, 上海 200030; 2. 上海交通大学 内燃机与汽车工程研究所, 上海 200030)

摘 要: 利用自组织 RBF 神经网络对驾驶员主动安全性因素进行辨识。对网络进行训练时, 首先由改进 FCM 算法根据输入样本内部关系确定 RBF 参数并通过 1 个聚类合理性函数控制聚类个数, 然后根据网络映射性能对 RBF 参数细调并对输出权值学习。利用本文给出的网络成功地对驾驶员的熟练程度进行了识别。

关键词: 模糊 c -均值算法; RBF 神经网络; 监督学习; 自组织
中图分类号: TP 18 文献标识码: A

Identification of the Driver's Active Safety Factors Using Self-organizing RBF Neural Network

MA Yong¹, YANG Yupu¹, XU Xiaoming², SHI Jian², ZHUO Bin²

(1. Research Institute of Automation, Shanghai Jiaotong University, Shanghai 200030, China;

2. Institute of Diesel and Motor Engineering, Shanghai Jiaotong University, Shanghai 200030, China)

Abstract: A self-organizing RBF neural network (SORBFNN) is presented to identify the driver's degrees of proficiency. A novel fuzzy c -means (FCM) algorithm is used to estimate the parameters of RBFs. The number of RBFs is determined by the clustering rationality function. A supervised learning scheme based on the class-conditional variance and the mapping error is proposed to tune the parameters of RBFs fine and the output weight values. The proposed learning algorithm estimates the clusters of the feature vectors rationally as well as increases the mapping ability of the SORBFNN. The SORBFNN is trained and tested on the experimental data of the drivers' proficiency with satisfactory results.

Key words: fuzzy c -means; RBF neural network; supervised learning; self-organizing

1 引 言

近年来, 由于径向基函数网络(RBFNN)具有拓扑结构简单和学习过程透明等优点, 在模式分类中

得到广泛的应用^[1,2]。但许多文献都没有正确体现输入模式内部之间固有的关系, 无法确定合理的基函数, 而且学习效率较低。

本文给出一种自组织 RBFNN, 把改进的 FCM

收稿日期: 1999-07-12; 修定日期: 1999-10-21

基金项目: 国家自然科学基金项目(69674023)

作者简介: 马勇(1971—), 男, 河南长垣人, 博士, 从事智能控制, 计算机网络通讯的研究; 许晓鸣(1957—), 男, 上海人, 教授, 博士生导师, 从事智能控制的研究。

和监督学习结合起来, 对网络的学习既可确定合适的基函数, 又可得到较高的映射精度。对驾驶员的主动安全性因素进行辨识, 获得驾驶员的熟练程度, 可作为建立人—车—路集成系统的主动安全性研究的基础。

2 自组织 RBFNN 算法设计

本文给出的自组织 RBFNN 对网络的学习包括两个过程: 首先利用改进的模糊 c -均值算法对学习样本聚类, 得到 RBF 的参数, 并用聚类合理性函数确定适当的 RBF 个数; 然后用类条件方差和映射误差分别对 RBF 参数和输出权值进行调节。该算法既能合理地对学习样本聚类, 又可提高网络的映射能力。

2.1 改进的 FCM 算法设计

FCM 聚类算法属于无监督学习, 不需要预知训练样本的结构信息, 能对数据自动划分。但迄今为止, 如何确定合适的聚类数目一直没有得到解决^[3,4]。为了得到合理的聚类结果, 本文从聚类本身的物理意义出发, 给出一个控制模糊聚类合理性函数 $\mathcal{R}(X, c)$, 用于指导聚类学习。它是通过逐步试探得到满足要求的聚类结果, 尽管结果只是局部最优, 但意义清晰, 算法简单。其中 $\mathcal{R}(X, c)$ 为

$$\mathcal{R}(X, c) = \frac{\frac{1}{N} \sum_{j=1}^c \sum_{p=1}^N \mu_{pj}^2 \|X^p - v_j\|^2}{\left[\frac{1}{|h|} \sum_{j \in h} d^2(v_j, v_h) \right]} \quad (1)$$

式中, $|h|$ 为集合 $h = \{(v_j, v_h) \mid d(v_j, v_h) = \|v_j - v_h\|, j, h, 1 < j, h < c\}$ 的势。 $\mathcal{R}(X, c)$ 的意义为: 模糊聚类划分所形成同一聚类中的输入学习样本靠得越紧, 不同聚类中心的距离越远, 则模糊聚类结果的合理程度就越好。模糊聚类的合理划分就是使 $\mathcal{R}(X, c)$ 越小越好。实际应用时首先根据具体要求确定一个阈值 τ , 如果 $\mathcal{R}(X, c) < \tau$, 则此时的聚类个数 c 满足要求; 当有不同的 c 值满足要求时, 一般取较小的值以减少计算量。

根据上述 FCM 算法确定的聚类中心 v_j , 向量 X^p 属于第 j 个 RBF 的隶属度 φ_j 为

$$\varphi_j = \varphi(X^p) = \exp\left[-\frac{\|X^p - v_j\|^2}{\sigma_j^2}\right] \quad (2)$$

为了确定参数 σ_j , 定义输入学习样本的集合

$$l_j = \{X^p \mid \|X^p - v_j\|^2 < X^p - v_q, \forall j, q\}$$

则参数 σ_j 计算如下

$$\sigma_j = \left[\frac{1}{|l_j|} \sum_{X^p \in l_j} \|X^p - v_j\|^2 \right]^{1/2} \quad (3)$$

其中 $|l_j|$ 为集合 l_j 的势。

2.2 监督学习算法设计

由上述 FCM 算法可得到径向基函数参数的 RBFNN。对输入模式进行分类时, 可能有在输入空间相近的输入样本却被划分到不同的类, 尤其对驾驶员驾驶技能识别的输入参数本来差别就不大, 更不容易得到合适的分类。为了提高网络的分类能力又不降低网络的泛化能力, 在聚类的合理程度和网络的映射能力之间做折衷选择, 通过分类条件方差对径向基函数参数进行细调, 并用映射误差对输出权值进行调节。

设 RBFNN 把 $\mathcal{X} = \{X^p, p = 1, 2, \dots, N\}$ 划分成 M 个类 $C_l = \{X^p \mid y_{l,p} = 1, \forall p\}, l = 1, 2, \dots, M$ 。第 l 个分类 C_l 与第 j 个 RBF 输出响应之间的分类条件方差, 定义为属于同一个类的输入向量对于第 j 个 RBF 响应的相近程度。考虑到同一个输入向量 X^p 可能激活几个 RBF 函数, 约定仅考虑它与激活响应最大的 RBF 函数之间的作用。为此定义集合 $\bar{\lambda} = \{X^p \mid \mathcal{B}^T \varphi(X^p) > \varphi(X^p), \forall j \in h\}$ (4) 则第 j 个基函数的输出响应和第 l 个分类 C_l 之间的局部分类条件方差为

$$\delta_{jl}^2 = \sum_{p: X^p \in C_l, \bar{\lambda}_j} [\varphi_j(C_l, \bar{\lambda}_j) - \varphi_j(X^p)]^2 \quad (5)$$

其中

$$\varphi_j(C_l, \bar{\lambda}_j) = \left[\frac{1}{|C_l \cap \bar{\lambda}_j|} \sum_{p: X^p \in C_l, \bar{\lambda}_j} \varphi_j(X^p) \right]$$

则所有基函数和类之间总的条件方差 V 为

$$V = \left(\frac{1}{2} \right) \sum_{l=1}^M \sum_{j=1}^c \delta_{jl}^2 \quad (6)$$

利用局部分类条件方差对 RBF 参数进一步优化。由梯度法得

$$\Delta v_j = -\eta_b \left[\frac{\partial V}{\partial v_j} \right] = -2\eta_b \sum_{l=1}^M \sum_{p: X^p \in C_l, \bar{\lambda}_j} [\varphi_j(C_l, \bar{\lambda}_j) - \varphi_j(X^p)] [s_{j,k} - s_{j,k}] \quad (7)$$

其中, $s_{j,k} = [\varphi_j(X^p) / \sigma_j^2] (X^p - v_j)$, $\eta_b > 0$ 为学习率。同理有

$$\Delta \sigma_j = -\eta_\sigma \frac{\partial V}{\partial \sigma_j} = -2\eta_\sigma \sum_{l=1}^M \sum_{p: X^p \in C_l, \bar{\lambda}_j} [\varphi_j(C_l, \bar{\lambda}_j) - \varphi_j(X^p)] [h_{j,k} - h_{j,k}] \quad (8)$$

其中, $h_{j,k} = \left(\frac{1}{\sigma_j^2} \frac{\partial \varphi_j(X^p)}{\partial \sigma_j} \right) (X^p - v_j)$, $\eta_\sigma > 0$ 为学

习率。

根据期望输出和实际输出之间的映射误差 E 对映射层权值进行学习。误差 E 为

$$E = \frac{1}{2} \sum_{p=1}^N \sum_{l=1}^M (y_l^p - y_{l,p})^2 \quad (9)$$

其中, y_l^p 为期望输出, $y_{l,p} = w_l^T \Phi_p$ 为网络实际输出。这里向量 $\Phi_p = [1, \Phi_{p1}, \dots, \Phi_{pn}]^T$, $w_l = [w_{l0}, w_{l1}, \dots, w_{ln}]^T$ 。由反传算法有

$$\Delta w_l = - \eta_w \left(\frac{\partial E}{\partial w_l} \right) = \eta_w \sum_{p=1}^N \Phi_p (y_l^p - \hat{y}_{l,p}) \quad (10)$$

其中 $\eta_w > 0$ 为学习率。设映射精度阈值为 $\bar{\epsilon}$, 当 $E < \bar{\epsilon}$ 时, 则停止权值学习。具体算法过程略。

3 驾驶员主动安全性因素的辨识

利用本文设计的 RBF 网络对驾驶员熟练程度进行辨识。可通过驾驶员对加速踏板、离合器踏板操作的协调性, 即通过以下参数进行辨识:

- 1) 起步中离合器空行程时离合器踏板的角速度 ω (deg/s);
- 2) 离合器与加速踏板半联动时离合器踏板的角速度 ω (deg/s);
- 3) 离合器结合半联动时加速踏板的角速度 ω (deg/s)。

把驾驶员的熟练程度分成很差(W)、一般(M)、好(G)和很好(E)四个等级, 则对驾驶员驾驶技能识别可等效为对输入模式 $X^{(p)} = (\omega_1^p, \omega_2^p, \omega_3^p)$ ($p = 1, 2, \dots, N$) 进行模式分类。通过网络学习最后划分为 4 类 y_l ($l = 1, 2, \dots, M$), 分别对应 W, M, G, E 四个等级。




图 1 训练样本及监督学习后聚类中心

•: 聚类中心; +: 很差; *: 一般
○: 良好; ×: 熟练

为了采集训练样本和测试样本, 选取不同驾龄的司机和初学驾驶者驾驶 SVW-Santana2000 型轿车在一段直道上进行实验, 从中选取 230 组和 200




图 2 测试样本的分类结果

+ : 很差; * : 一般
○ : 良好; × : 熟练

组有代表性的数据, 分别作为训练样本和测试样本。主要仿真参数如下: $m = 1.25$, $\epsilon = 0.0001$, $\eta_c = 0.002$, $\eta_\sigma = 0.001$, $\eta_w = 0.08$, $\tau = 0.018$, $\bar{\epsilon} = 0.01$ 。

训练样本及监督学习后聚类中心如图 1 所示, 测试样本的分类结果如图 2 所示。仿真结果表明, 训练后的自组织 RBF 网络可对测试样本成功地进行分类, 尤其能对类与类之间进行合理的划分。

4 结 语

本文给出一种自组织 RBF 神经网络, 分别通过模糊聚类学习和监督学习对网络参数和权值进行训练, 既可以根据训练样本合理地聚类确定 RBF 的个数和相应参数, 又具有较强的网络映射能力。在对驾驶员熟练程度的辨识中取得了满意的结果。

参考文献:

- [1] Lu Y W, Narashiman S, Saratchandran P. Performance evaluation of a sequential minimal radial basis function neural network learning algorithm [J]. IEEE Trans on NN, 1998, 9(2): 308-318.
- [2] Karayiannis N B, Glenn W M. Growing radial basis neural networks: merging supervised and unsupervised learning with network growth techniques [J]. IEEE Trans on NN, 1997, 8(6): 1492-1507.
- [3] Klawonn F, Kruse R. Constructing a fuzzy controller from data [J]. Fuzzy Sets and Systems, 1997, 85: 177-193.
- [4] Xie X L, Beni G. A validity measure for fuzzy clustering [J]. IEEE Trans on Pattern Analysis, 1991, 13: 841-847.