

基于 FCM 的神经网络建模及其 在智能驾驶中应用研究¹⁾

马 勇¹ 杨煜普² 许晓鸣²

¹(河南新飞电器有限公司 新乡 453002)

²(上海交通大学智能控制研究室 上海 200030)

(E-mail: my@xinfei.com)

摘要 首先对模糊 c-均值聚类算法进行了分析,然后把改进的 FCM 算法和 RBF 神经网络结合起来建模,得到一种映射能力较强的自组织 RBF 神经网络。最后把它应用到智能驾驶中对驾驶员的熟练程度和疲劳程度进行识别,得到了满意的结果。

关键词 模糊 c-均值聚类,RBF 神经网络,监督学习,自组织

中图分类号 TP18

NEURAL NETWORK MODELING BASED ON FCM CLUSTERING AND ITS APPLICATION TO INTELLIGENT DRIVING

MA Yong¹ YANG Yu-Pu² XU Xiao-Ming²

¹(Henan Xinfei Electric CO., Ltd., Xinxiang 453002)

²(Intelligent Control Research Institute, Shanghai Jiaotong University, Shanghai 200030)

(E-mail: my@xinfei.com)

Abstract The fuzzy c-means (FCM) clustering algorithm is analyzed in this paper. Then a self-organizing RBF neural network using improved FCM algorithm is proposed to increase the mapping ability. The neural network is applicable to intelligent driving, which is tested on the experimental data of the drivers' proficiency and fatigue with satisfactory results.

Key words Fuzzy c-means clustering, RBF neural network, supervised learning, self-organizing

1 引言

聚类分析经常和模糊逻辑、神经网络结合起来,从大量训练样本中提取控制规则或确定

1) 国家自然科学基金资助

收稿日期 1999-09-08 收修改稿日期 2001-02-02

相应神经元结点. 但它一般要求预先设定训练数据的聚类个数, 然而实际中往往缺乏这方面的知识, 盲目或随意地确定经常会导致不正确的分析结果. 尽管许多文献给出了聚类有效性的判断准则^[1~3], 但都不太理想. 从聚类的物理意义出发, 文中给出了一种模糊聚类合理性函数(Fuzzy Clustering Rationality Function, FCRF)可以使聚类结果满足局部最优. 聚类分析按照划分的结果分硬聚类和软聚类, 其中硬聚类每个输入仅属于距离最近的聚类中心所属的类, 如硬 c-均值(HCM)以及 Kononen 学习向量量化(Learning Vector Quantization, LVQ)^[4]; 软聚类每个输入样本可能以不同的隶属函数或概率属于一个或多个聚类, 隶属函数或概率是由输入和聚类中心关系表示的 0 到 1 的值. FCM 聚类是一种无监督的自组织学习, 只有和其他软计算方法结合起来, 才会有更好的应用前景. 本文把它和 RBF 网络结合起来得到一种自组织 RBF 网络, 具有较高的映射精度和分类能力, 用它对驾驶员的主动安全性因素辨识取得了满意的结果.

2 模糊 c-均值聚类分析

定义 1. 给定 $X = \{x^p, p=1, 2, \dots, N\} \in R^n$, 样本 $x^p = (x_{p1}, x_{p2}, \dots, x_{pn})$. 设聚类个数为 c ($2 \leq c < N$), 聚类中心为 $v = (v_1, v_2, \dots, v_c)^T \in R^n$, 则称集合 M_c 是 X 的一个模糊 c-划分, 其中

$$M_c = \{U \in V_{cN} \mid \mu_{pj} \in [0, 1], \forall j, p; \sum_{j=1}^c \mu_{pj} = 1, \forall p; 0 < \sum_{p=1}^N \mu_{pj} < N, \forall j\} \quad (1)$$

上式中 $\mu_{pj} = \mu_j(x^p)$ 表示 x^p 属于第 j 类的隶属度; $U = \{u_1, u_2, \dots, u_c\}^T$, $u_j = (u_{j1}, u_{j2}, \dots, u_{jN})$ 是样本 X 的第 j 个聚类集合; V_{cN} 是 $c \times N$ 阶实矩阵的集合.

FCM 算法是通过最小化准则函数的迭代优化来实现划分. 为实现对样本 X 的模糊 c-均值划分, 最小化准则函数

$$J_m(U, v, A) = \sum_{p=1}^N \sum_{j=1}^c \mu_{pj}^m \|x^p - v_j\|_A^2 \quad (2)$$

其中 A 为 $n \times n$ 阶正定加权矩阵. 利用加权矩阵 A 可将欧氏空间扩展到非欧氏空间内. 根据不同的数据分布采用不同的空间坐标系来计算距离

$$d_{pj}^2 = \|x^p - v_j\|_A^2 = (x^p - v_j)^T A (x^p - v_j) \quad (3)$$

对目标函数极小化得到两个必要条件为

$$\mu_{pi} = (d_{pi})^{\frac{2}{1-m}} \left/ \sum_{j=1}^c (d_{pj})^{\frac{2}{1-m}} \right., \quad v_i = \sum_{p=1}^N \mu_{pi}^m x^p \left/ \sum_{p=1}^N \mu_{pi}^m \right., \quad i = 1, 2, \dots, c; p = 1, 2, \dots, N \quad (4), (5)$$

讨论 1. c-均值算法对聚类中心的初值是敏感的, 不同的初值可能导致不同的局部极小值结果. 也有改进算法^[8], 利用模拟退火算法来避免局部极小值, 但运算量太大; 也有文献利用遗传算法寻优, 但都不能从根本上解决此问题. 本文利用一个聚类合理函数控制寻优, 尽管结果不一定全局最优, 但却有较高的实用性.

讨论 2. 如果令模糊 LVQ^[4]系数 w_{pi}, η_i 和 α_{pi} 分别为

$$w_{pi} = \mu_{pi}^m, \quad \eta_i = 1 \left/ \sum_{p=1}^N w_{pi} \right., \quad \alpha_{pi} = \eta_i w_{pi} \quad (6)$$

则式(5)可以表示为

$$\begin{aligned} v_i(t) &= \sum_{p=1}^N \alpha_{pi} x^p = v_i(t-1) + \sum_{p=1}^N \alpha_{pi} (x^p - v_i(t-1)) = \\ &v_i(t-1) + \eta_i \sum_{p=1}^N w_{pi} (x^p - v_i(t-1)) \end{aligned} \quad (7)$$

式(7)就是模糊 LVQ 的 Kohonen 离线权值自适应规则. 可见模糊 LVQ 和 FCM 有许多内在的联系, 它们样本结构信息都是根据样本和聚类中心之间的距离获得的, 距离大小都主要依靠聚类中心位置和附近样本的延伸范围. 但是二者之间仍存在着区别, 比较显然的如 FCM 算法中 m 是取值 $(1, \infty)$ 之间的常数, 而模糊 LVQ 算法中一般定义为单调减的函数, 例如 $m(t) = m_0 - \frac{t}{t_{\max}} (m_0 - m_f)$, $m_0 > m_f$.

讨论 3. 式(4)中 μ_{pi} 表示输入向量 x^p 属于聚类 i 模糊程度的隶属度, 可看作属于某聚类的相对程度大小. Karayiannis N B^[4] 称满足式(1)限制条件的 μ_{pi} 为相对隶属函数(relative fuzzy membership). 由式(4)不难看出, 如果 $\|x^p - v_i\| \rightarrow 0$, $\forall i$ 则有 $\mu_{pj} \rightarrow 1/c$, 这时被干扰污染的样本可能具有很大的隶属函数值从而影响聚类结果, 使得 FCM 聚类算法对干扰是敏感的, 具有较低的鲁棒性. 模糊 LVQ 同样存在此问题^[5].

讨论 4. FCM 算法中, 模糊指数 m 的取值是最关键的一个问题. m 越大, 聚类的范围越大, 隶属函数的模糊程度越大. 当 m 趋向于 1 时, FCM 相当于硬 c-均值算法. 对于模糊 LVQ 算法, 学习开始时具有较大的 m 值, 对每个输入量许多聚类中心都进行调整, 随着学习的深入 m 逐渐减小到 1, 仅个别中心值调整.

1) 对于 $m \rightarrow \infty$ 时, 容易得到

$$\lim_{m \rightarrow \infty} \mu_{pl} = 1/c, \forall i, \forall p \quad (8)$$

当 $m \rightarrow \infty$ 时, 不同输入向量对于所有聚类都有相同的隶属函数值, 隶属函数的模糊程度最大, 不同隶属函数之间达到完全重叠.

对于模糊 LVQ 算法, 由式(6)易得

$$\lim_{m \rightarrow \infty} \alpha_{pj} = 1/N, \lim_{m \rightarrow \infty} v_i = \sum_{p=1}^N x^p / N, \forall i, \forall k, c > 1 \quad (9)$$

式(9)表明对所有训练样本, 每个聚类都有相同的调节权值, 权值调节使邻域扩展到了所有类, 所有训练样本映射到了相同的类. 这将导致无意义的聚类, 模糊 LVQ 应该避免这种情况.

2) 当 $m \rightarrow 1^+$ 时, FCM 和模糊 LVQ 虽然非常趋近, 同样存在区别. 对于 FCM, 由式(5)和(9)可得

$$\lim_{m \rightarrow 1^+} v_i = \sum_{x^p \in C_i} x^p / n_i \quad (10)$$

其中 n_i 是集合 $S = \{x^p \in X | x^p \in C_i, p=1, 2, \dots, N\}$ 的势.

对于模糊 LVQ, 根据式(7)和(9)有

$$\lim_{m \rightarrow 1^+} \alpha_{pi} = \begin{cases} n_i, & \text{if node } i \text{ is the winner for } x^p \\ 0, & \text{if node } i \text{ is not the winner for } x^p \text{ and } n_i \geq 1 \\ 1/N, & \text{if node } i \text{ is not the winner for } x^p \text{ and } n_i = 0 \end{cases} \quad (11)$$

$$\lim_{n \rightarrow 1^+} v_i = \begin{cases} \sum_{x^p \in C_i} x^p / n_i, & \text{if } n_i \geq 1 \\ \sum_{p=1}^N x^p / N, & \text{if } n_i = 0 \end{cases} \quad (12)$$

由式(10),显然 FCM 将不能处理 $n_i=0$ 的情况. 当模糊 LVQ 遇到这种情况,聚类中心将被移向所有训练样本的重心,但学习结果也成为死区(dead unit),造成资源无法恢复的浪费^[6].

根据以上分析,FCM 算法中的 m 不应趋近 1,模糊 LVQ 算法中的 m 不应趋向极大. 目前还没发现确定合适 m 的方法. 根据经验,对于 FCM,一般取 $1.1 \leq m \leq 5$;对于模糊 LVQ,一般取 $1.1 < m_f < m_0 < 7$.

3 模糊聚类算法实现的自组织 RBF 神经网络

RBF 神经网络具有简单的拓扑结构和学习过程透明等优点,在模式分类中广泛应用,但却无法确定合适的隐层单元个数. RBF 网络中基函数个数太少,网络映射精度不高,但个数太多,也对映射性能和学习效率有影响. 本节把改进的 FCM 聚类算法和 RBF 神经网络结合起来建模,得到一种自组织 RBF 网络,可以充分利用二者的优点. 本节给出的学习算法中,首先由 FCM 无监督学习优化网络结构,并根据聚类合理性函数确定局部最优的聚类个数,然后根据 RBF 神经网络映射结果利用监督学习对聚类结果进一步优化调整,同时对输出权值学习. 这样既可确定合适的 RBF 个数,又使网络具有较高的映射精度.

3.1 改进的 FCM 算法设计

对于 FCM 聚类算法,如何确定合适的聚类数目一直没有得到合理解决^[1~3]. 本文从聚类本身的物理意义给出一个控制模糊聚类合理性函数 $f(\chi, c)$ 来指导聚类学习,意义明了,计算简单. 为此引入以下几个定义.

定义 2. 根据定义 1,称 FCM 划分的平均方差为模糊划分的紧度,表示为

$$\Omega(\chi, v) = \frac{1}{N} \sum_{j=1}^c \sum_{p=1}^N \mu_{jp}^2 (\mathbf{x}^p - \mathbf{v}_j)^T A (\mathbf{x}^p - \mathbf{v}_j) \quad (13)$$

其中 A 为 $n \times n$ 正定加权矩阵,可将欧拉空间扩展到其他空间.

定义 3. 根据定义 1,称不同聚类中心之间的平均距离为模糊划分的分离度,用 $S(\chi, v)$ 表示为

$$S(v) = \frac{1}{|R|} \sum_{j=1}^{c-1} \sum_{h=j+1}^c (\mathbf{v}_j - \mathbf{v}_h)^T A (\mathbf{v}_j - \mathbf{v}_h) \quad (14)$$

其中 $|R|$ 为集合 $R = \{(\mathbf{v}_j, \mathbf{v}_h) | d(\mathbf{v}_j, \mathbf{v}_h) = \|\mathbf{v}_j - \mathbf{v}_h\|, j \neq h, 1 \leq j, h \leq c\}$ 的势.

在定义 2 和 3 的基础上,得到本文给出的模糊聚类合理性函数

$$f(\chi, c) = \frac{\Omega(\chi, v)}{S(v)} \quad (15)$$

$f(\chi, c)$ 的意义很显然:模糊聚类划分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尽量使 $f(\chi, c)$ 越小越好. 具体应用中首先根据具体要求确定一个阈值 τ ,如果 $f(\chi, c) \leq \tau$,则此时

的聚类个数 c 满足要求,可能有不同的 c 值满足要求,一般取较小的值以提高计算效率.

根据上面 FCM 算法确定的聚类中心 v_j ,则向量 \mathbf{x}^p 属于第 j 个 RBF 的隶属度为

$$\varphi_{pj} = \varphi_j(\mathbf{x}^p) = \exp\left(-\frac{\|\mathbf{x}^p - v_j\|^2}{\sigma_j^2}\right) \quad (16)$$

为了确定参数 σ_j , 定义输入学习样本的集合

$$L_j = \{\mathbf{x}^p \in X \mid \|\mathbf{x}^p - v_j\|^2 < \|\mathbf{x}^p - v_q\|^2, \forall j \neq q\},$$

则参数 σ_j 由下式计算得

$$\sigma_j = \frac{1}{|L_j|} \sum_{\mathbf{x}^p \in L_j} \|\mathbf{x}^p - v_j\| \quad (17)$$

其中 $|L_j|$ 为集合 L_j 的势.

3.2 监督学习算法设计

利用改进 FCM 算法建模得到的 RBF 神经网络,对输入模式进行分类,当输入参数之间的特征不太明显时,可能在输入空间相近的输入样本却被划分到不同的类.为了提高网络的分类能力但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作一个折衷,通过分类条件方差对径向基函数参数进一步调节,同时用映射误差对输出权值调节^[4].

定义 4. 设上面给出的自组织 RBF 网络把 $X = \{\mathbf{x}^p, p=1, 2, \dots, N\}$ 划分成 m 个类, $C_l = \{\mathbf{x}^p \in X \mid y_{l,p}=1, \forall p\}$, $l=1, 2, \dots, m$, 则第 j 个 RBF 输出响应和第 l 个分类 C_l 之间的分类条件方差定义为

$$\delta_{jl}^2 = \sum_{p: \mathbf{x}^p \in C_l} (\langle \varphi_j, C_l \rangle - \varphi_j(\mathbf{x}^p))^2 \quad (18)$$

它表示属于同一个 l 类的输入向量对于第 j 个 RBF 响应的相关程度,其中

$$\langle \varphi_j, C_l \rangle = \frac{1}{|C_l|} \sum_{p: \mathbf{x}^p \in C_l} \varphi_j(\mathbf{x}^p).$$

定义 5. 考虑到同一个输入向量 \mathbf{x}^p 可能激活几个 RBF 函数,约定仅考虑它与激活性最大的 RBF 函数之间的作用,为此定义集合

$$H_j = \{\mathbf{x}^p \in X \mid \varphi_j(\mathbf{x}^p) > \varphi_h(\mathbf{x}^p), \forall j \neq h\} \quad (19)$$

则第 j 个基函数的输出和第 l 个分类 C_l 之间的局部分类条件方差定义为

$$\delta_{jl}^2 = \sum_{p: \mathbf{x}^p \in C_l \cap H_j} (\langle \varphi_j, C_l \cap H_j \rangle - \varphi_j(\mathbf{x}^p))^2 \quad (20)$$

其中 $\langle \varphi_j, C_l \cap H_j \rangle = \frac{1}{|C_l \cap H_j|} \sum_{p: \mathbf{x}^p \in C_l \cap H_j} \varphi_j(\mathbf{x}^p)$, 则所有基函数和类之间总的条件方差为

$$V = \frac{1}{2} \sum_{l=1}^m \sum_{j=1}^c \delta_{jl}^2 \quad (21)$$

为了利用局部分类条件方差对 RBF 参数进一步优化,根据链式梯度法则有

$$\Delta v_j = -\eta_v \frac{\partial V}{\partial v_j} = -2\eta_v \sum_{l=1}^m \sum_{p: \mathbf{x}^p \in C_l \cap H_j} (\langle \varphi_j, C_l \cap H_j \rangle - \varphi_j(\mathbf{x}^p)) (\langle s_j, C_l \cap H_j \rangle - s_{j,k}) \quad (22)$$

其中 $\eta_v > 0$ 为学习率, $s_{j,k} = \frac{\varphi_j(\mathbf{x}^p)}{\sigma_j^2} (\mathbf{x}^p - v_j)$.

$$\Delta\sigma_j = -\eta_\sigma \frac{\partial V}{\partial \sigma_j} = -2\eta_\sigma \sum_{l=1}^m \sum_{p: x^p \in C_l \cap H_j} (\langle \varphi_j, C_l \cap H_j \rangle - \varphi_j(x^p)) (\langle h_j, C_l \cap H_j \rangle - h_{j,k}) \quad (23)$$

其中 $\eta_\sigma > 0$ 为学习率, $h_{j,k} = \frac{\|x^p - v_j\|^2}{\sigma_j^3} \varphi_j(x^p)$.

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

$$E = \frac{1}{2} \sum_{p=1}^N \sum_{l=1}^m (y_l^p - y_{l,p})^2 \quad (24)$$

其中 y_l^p 为期望输出, 网络实际输出 $y_{l,p} = \mathbf{w}_l^\top \boldsymbol{\varphi}_p$, 这里向量 $\boldsymbol{\varphi}_p = [1, \varphi_{1,p}, \dots, \varphi_{c,p}]^\top$, $\mathbf{w}_l = [w_{l0}, w_{l1}, \dots, w_{lc}]^\top$. 由反传算法有

$$\Delta \mathbf{w}_l = -\eta_w \frac{\partial E}{\partial \mathbf{w}_l} = \eta_w \sum_{p=1}^N \boldsymbol{\varphi}_p (y_l^p - \hat{y}_{l,p}) \quad (25)$$

其中学习率 $\eta_w > 0$. 设映射精度阈值为 $\bar{\epsilon}$, 当 $E \leq \bar{\epsilon}$, 则停止对权值学习.

4 自组织 RBF 神经网络在驾驶员主动安全性中的应用

驾驶员主动安全性因素的辨识是对整个人-车-路综合系统主动安全性评价的重点和难点. 通过传感器测量驾驶员油门踏板和离合器踏板等一些数据, 由本文设计的自组织 RBFNN 对驾驶员的主动安全性因素进行辨识. 驾驶员主动安全性包括许多不定因素, 如果不考虑具体的某一次偶然因素对驾驶员判断产生的影响, 而从统计的观点去分析, 对于驾驶员的驾驶技能(熟练程度)的辨识, 可以通过驾驶员对加速踏板、离合器踏板操作的协调性, 即通过参数 w_e (deg/s), w_c (deg/s) 和 w_g (deg/s) 进行辨识^[7].

把驾驶员的熟练程度分成很差、一般、好和很好四个等级, 则对驾驶员驾驶技能识别可以等效为对输入模式 $x^{(p)} = (w_e^p, w_c^p, w_g^p)$ ($p=1, 2, \dots, N$) 进行模式分类, 通过网络学习最后划分为四类 y_l ($l=1, 2, \dots, m$) 分别对应四个等级. 选取不同驾龄司机和初学驾驶者进行实验, 从中选取 230 组和 200 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:

模糊指数 $m=1.25$, 聚类误差阈值 $\epsilon=0.0001$, 映射误差阈值 $\bar{\epsilon}=0.01$, 学习系数 $\eta_c=0.002$, $\eta_\sigma=0.001$, $\eta_w=0.08$, FCRF 计算阈值 $\tau=0.018$.

图 1 和 2 分别给出了监督学习前后的聚类中心, 图中分别用“○”和“●”表示聚类中心的位置. 可以看出经过类条件方差监督学习后的聚类中心更能体现合理的聚类结果. 图 2 和 3

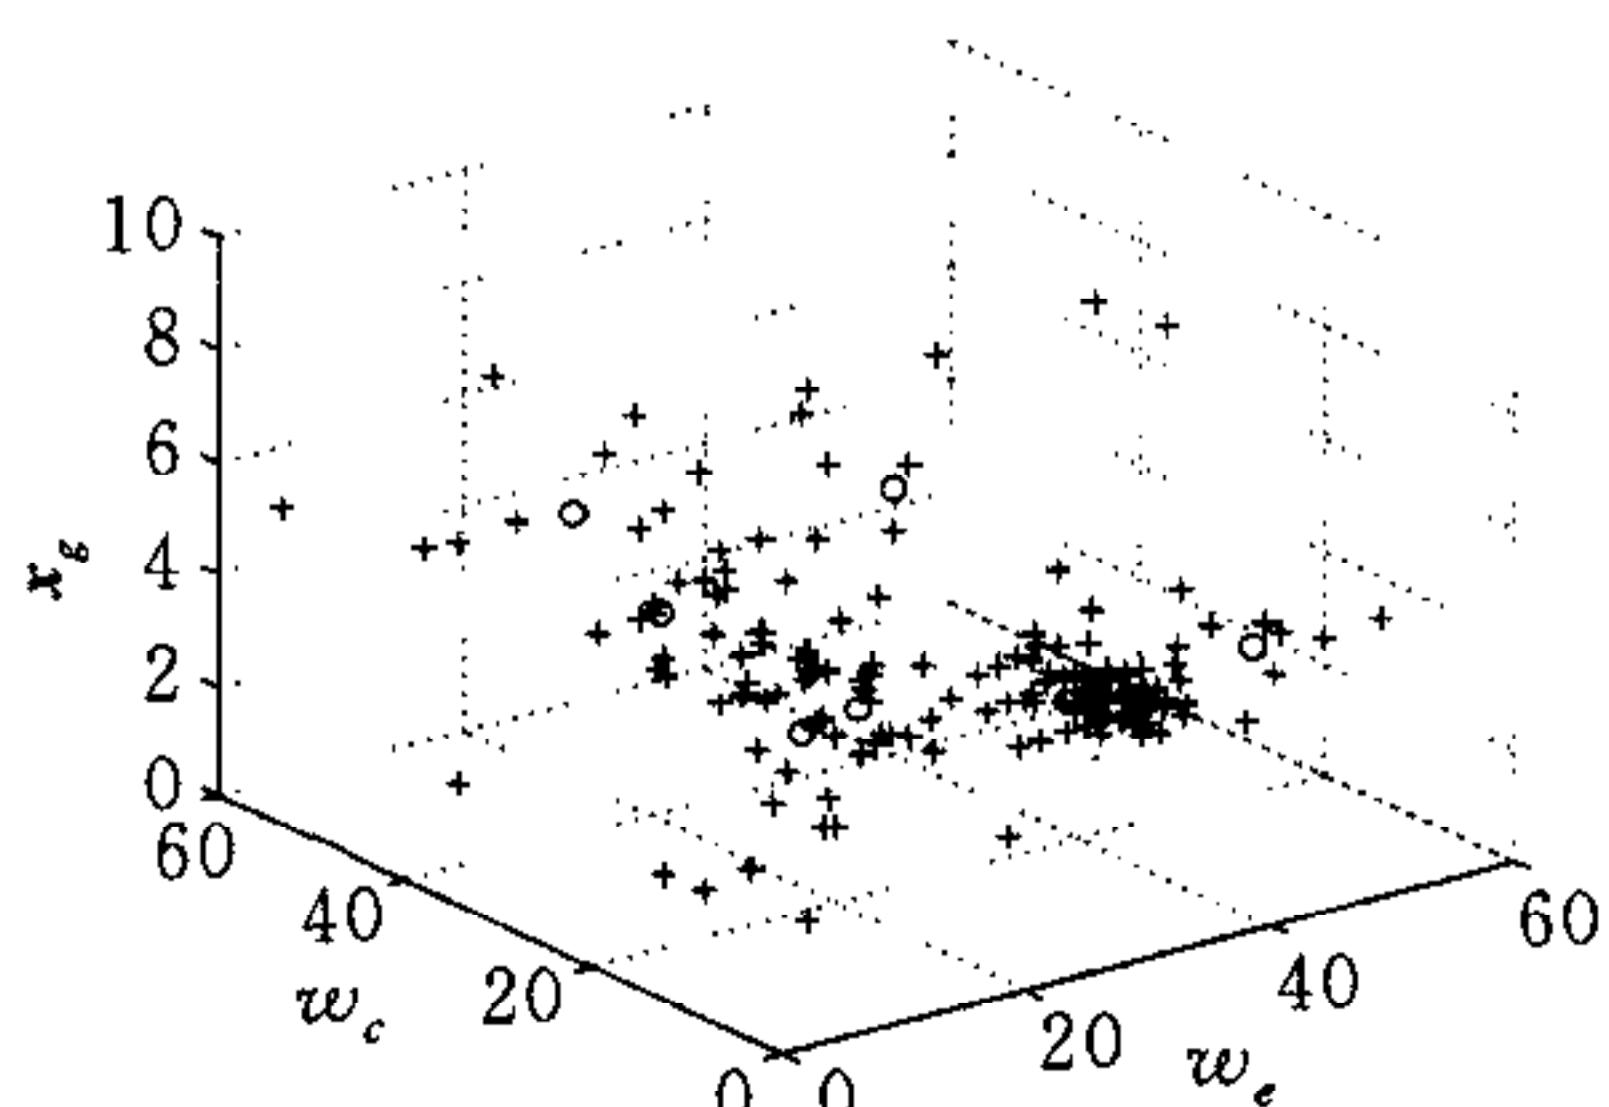


图 1 训练样本及 FCM 聚类中心
(○——聚类中心)

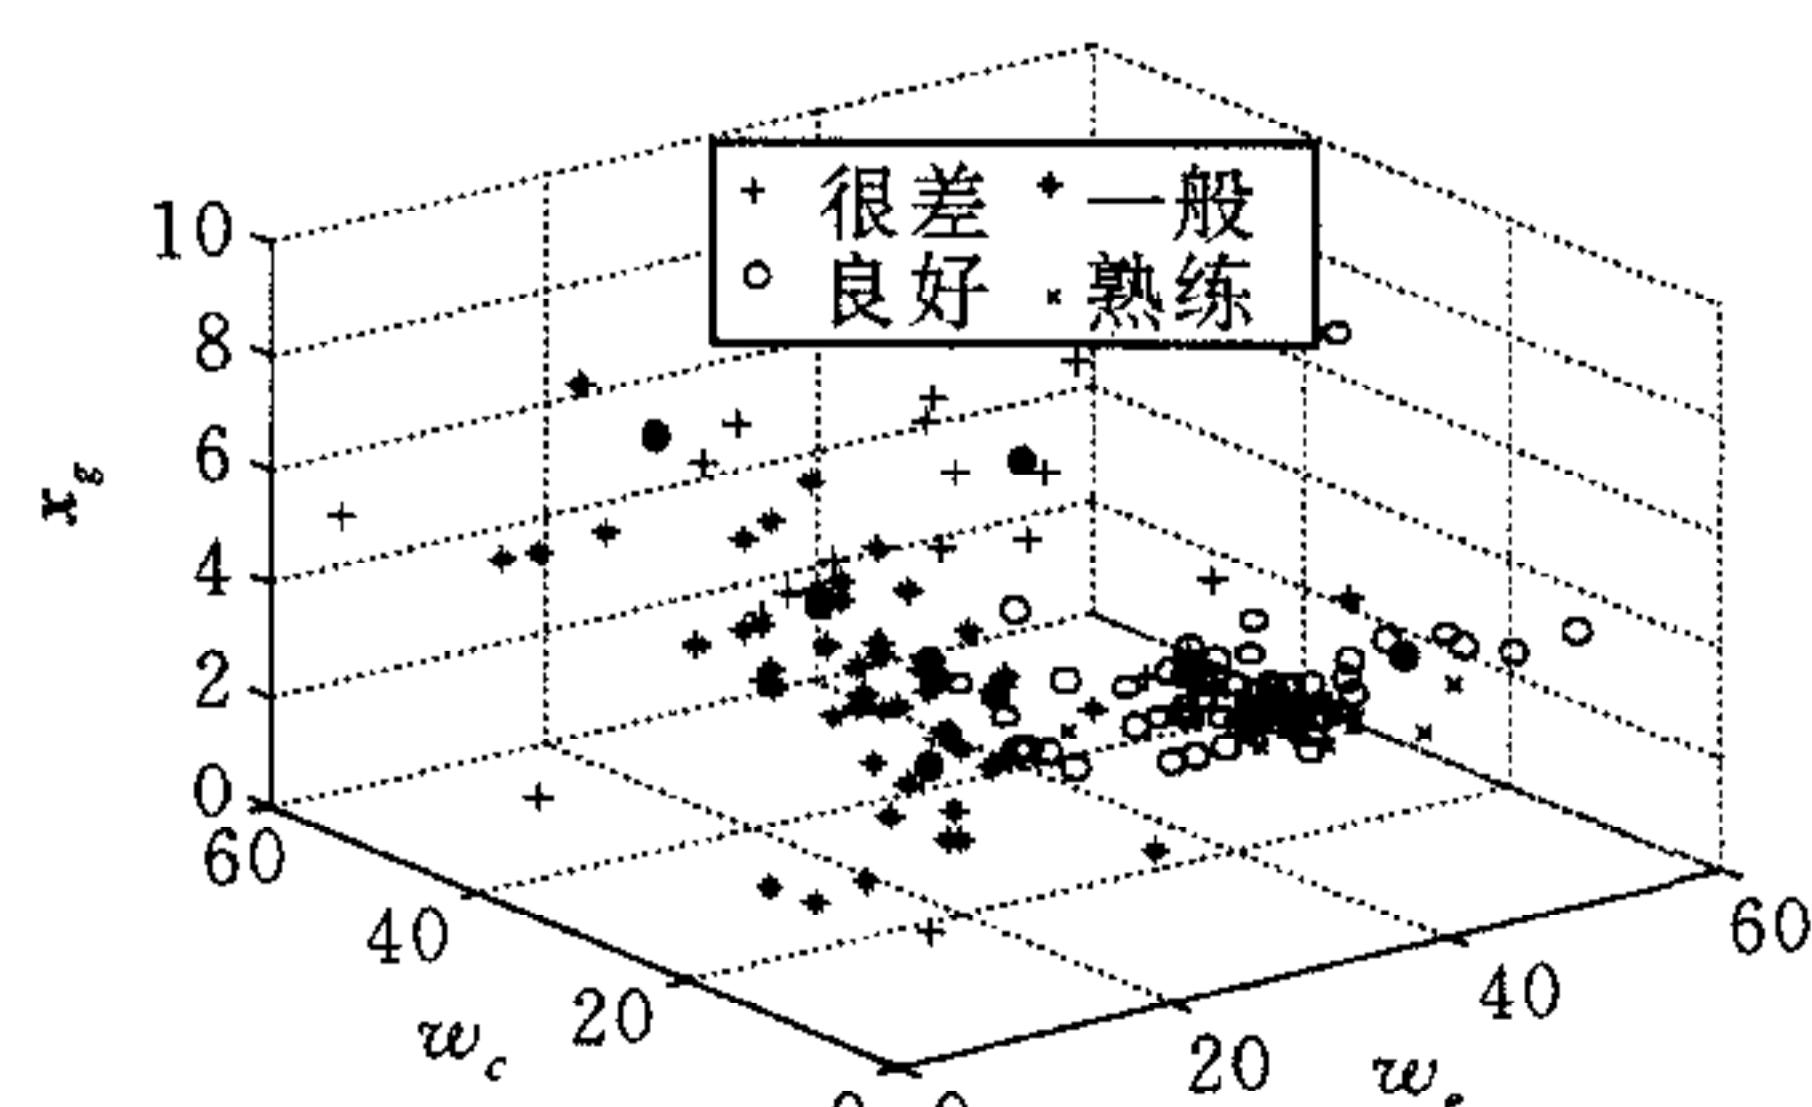


图 2 训练样本及监督学习后 FCM 聚类中心
(●——聚类中心)

仿真结果表明,训练后的自组织 RBF 网络成功地对测试样本进行了分类,尤其在类与类之间进行了较好的划分。

对驾驶员疲劳程度的辨识可以等效为对输入模式 $x^p = (\text{Amp_D2_Theta}^{(p)}, \text{WtFlat.0}^{(p)})$ ($p=1, 2, \dots, N$) 进行模式分类^[7],由 RBF 网络最后划分为三类 y_l ($l=1, 2, 3$) 分别对应正常、轻度疲劳和极度疲劳。

为了采集训练样本和测试样本,本文在自行设计的人-车-路综合系统的主动安全控制实验平台上模拟上述疲劳状态。从中分别选取 150 组有代表性的数据作为训练样本和测试样本。主要仿真参数同上。图 4 和 5 分别给出了监督学习前后的聚类中心,图中分别用“○”和“●”表示聚类中心的位置,可以看出经过类条件方差监督学习后的聚类中心更能体现合理的聚类结果。图 5 和 6 仿真结果表明,训练后的 RBF 网络成功地对测试样本进行了分类,尤其在类与类之间进行了较好的划分。图 7 给出了相应模糊聚类合理性函数和聚类数目之间的关系。

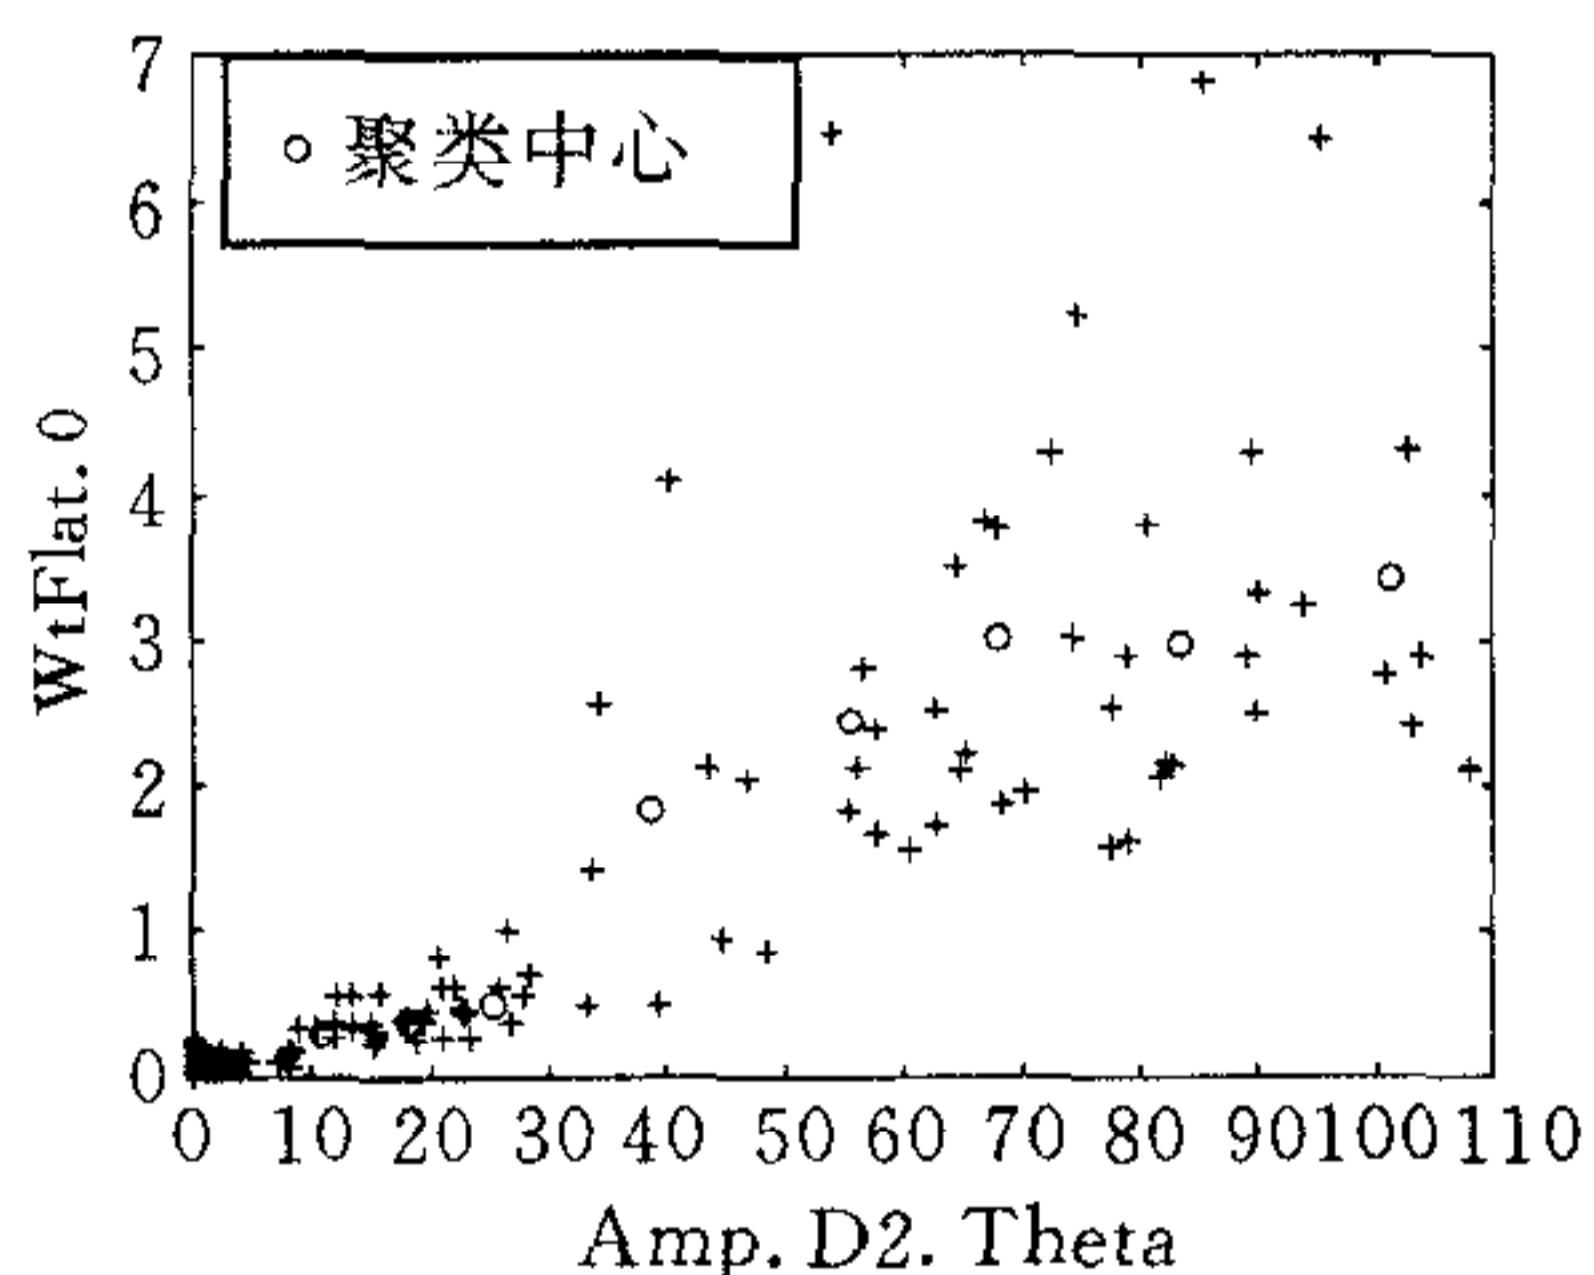


图 4 训练样本及 FCM 聚类中心

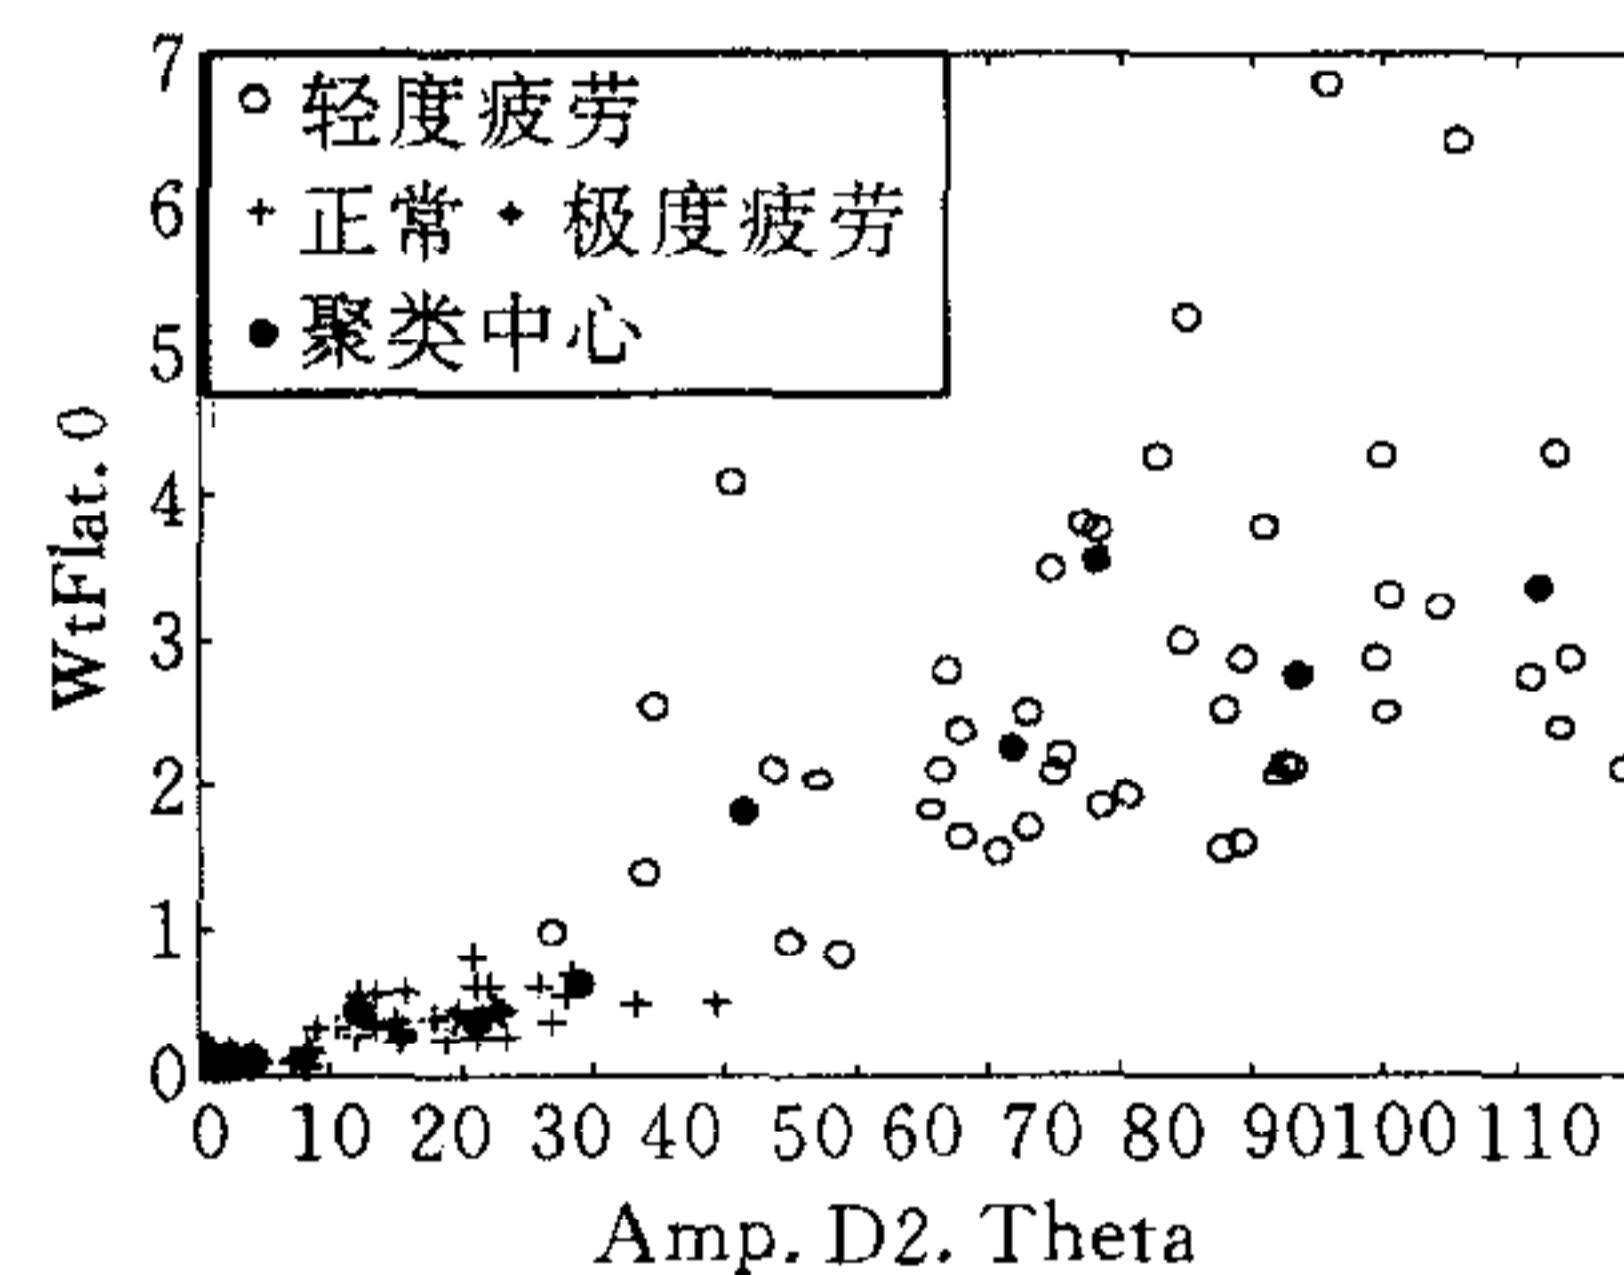


图 5 训练样本及监督学习后 FCM 聚类中心

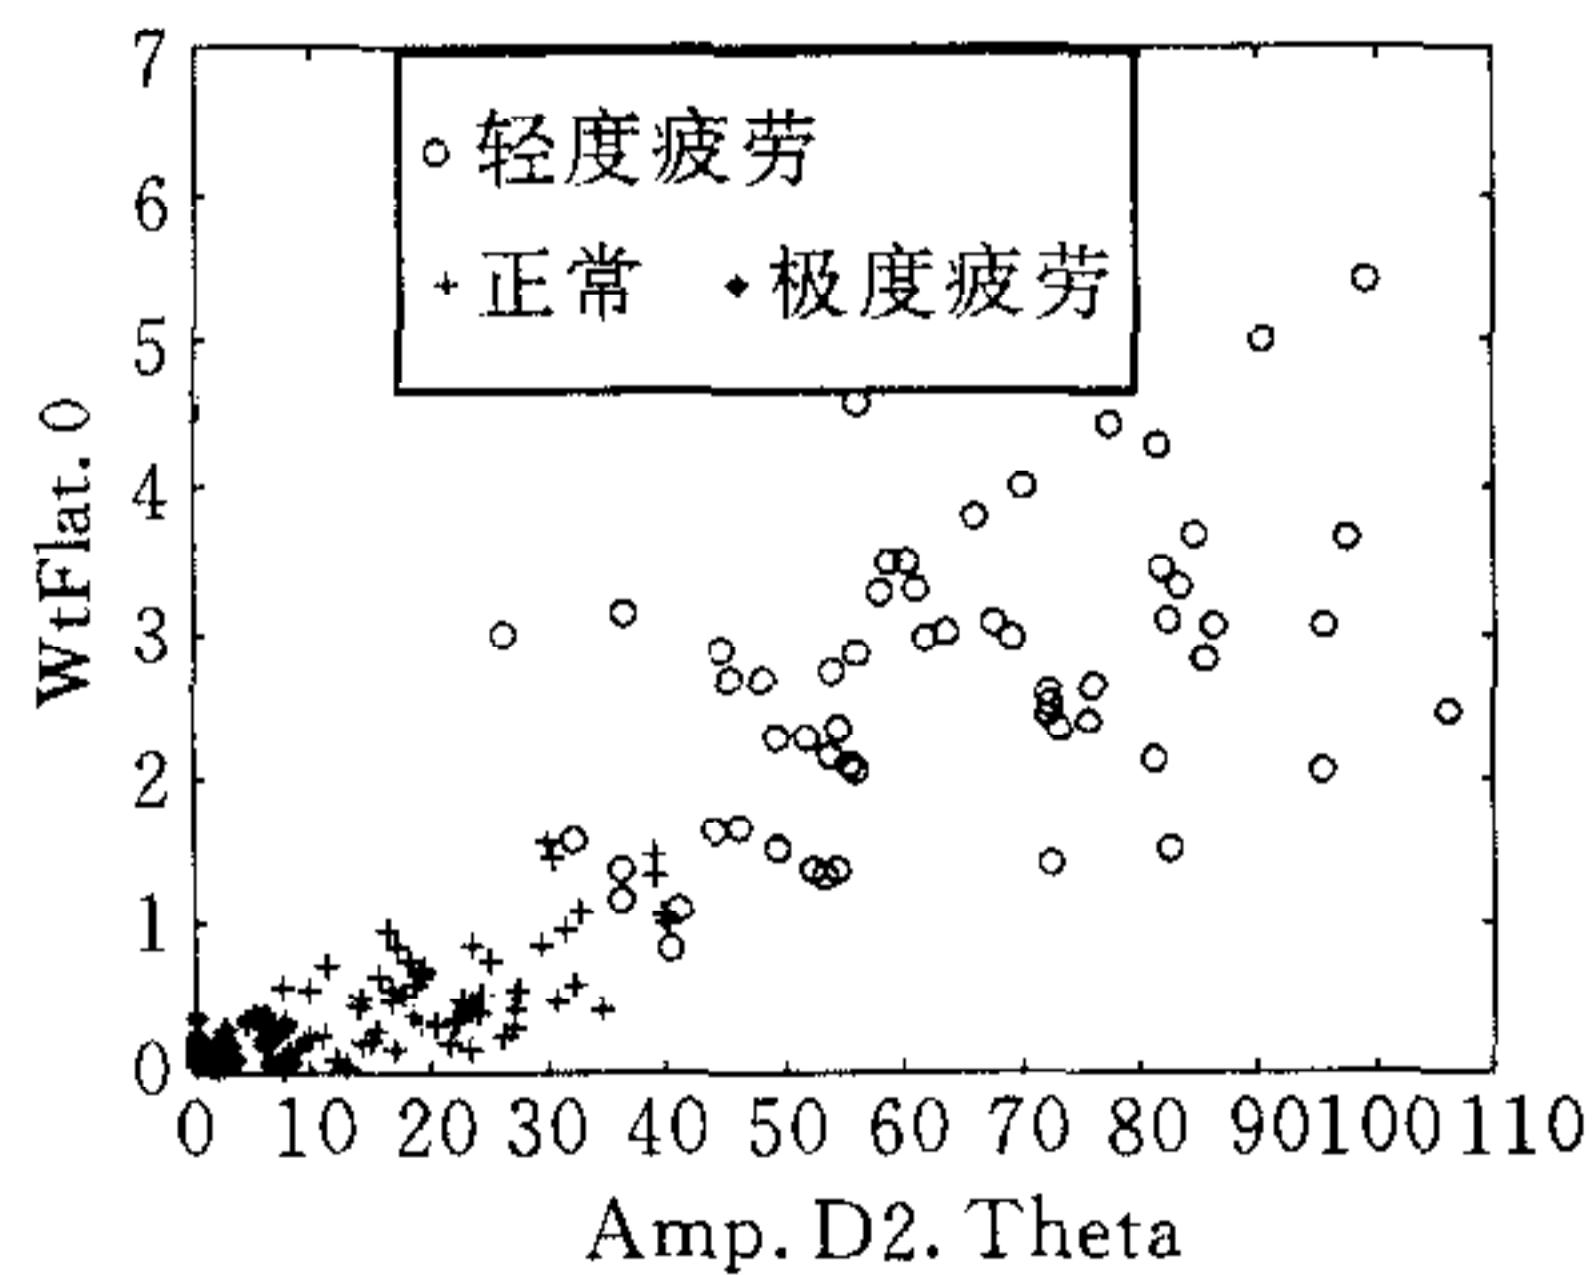


图 6 测试样本的分类结果

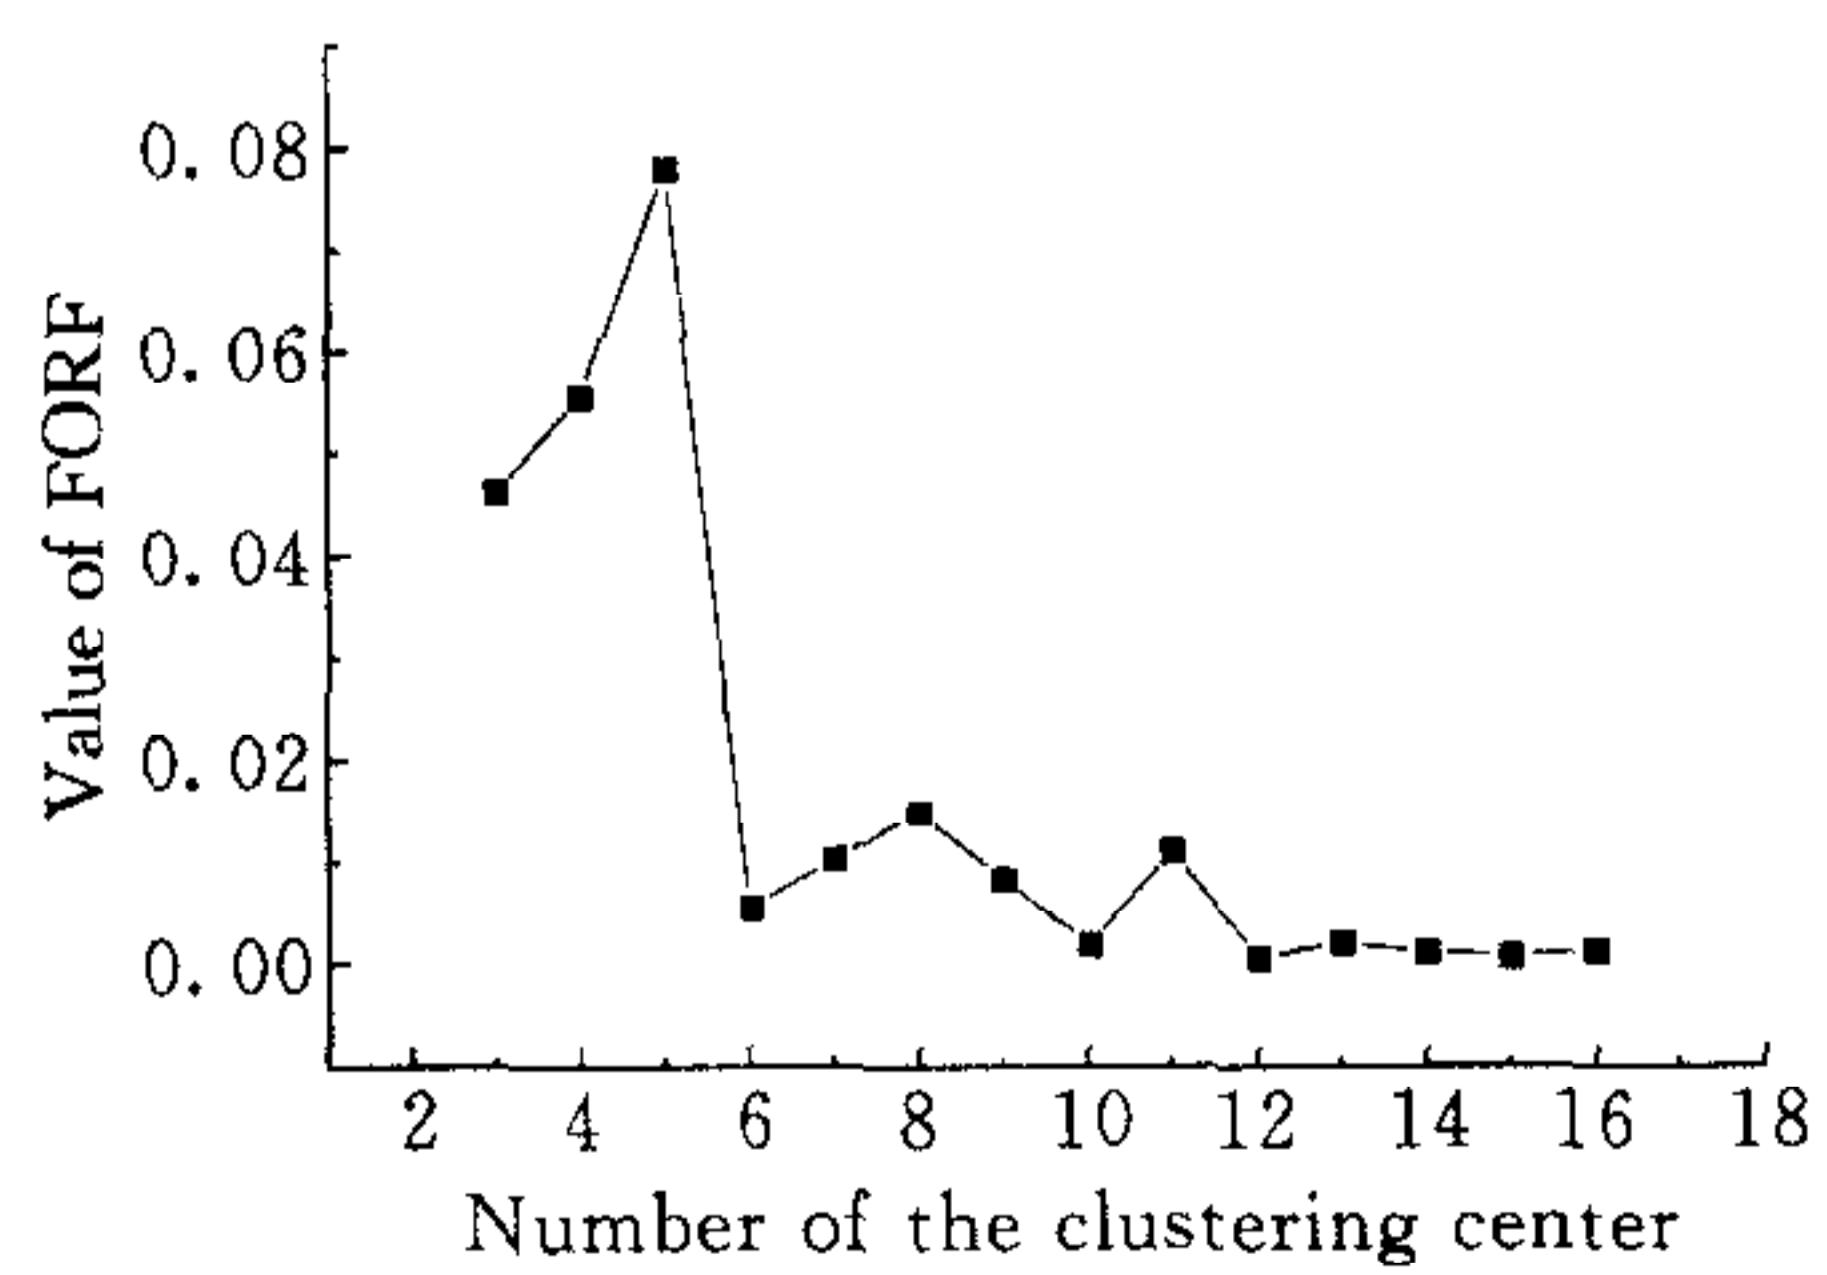


图 7 模糊聚类个数与 FCRF 值之间的关系

5 结论

- 1) 讨论了模糊 c-均值算法的优缺点以及它与模糊 LVQ 之间的联系和区别。并针对模糊聚类的合理性问题,给出了一种清晰简单 FCRF 评价方法。
- 2) 给出了一种自组织 RBF 网络具有较强的网络映射能力,经过类条件方差监督学习

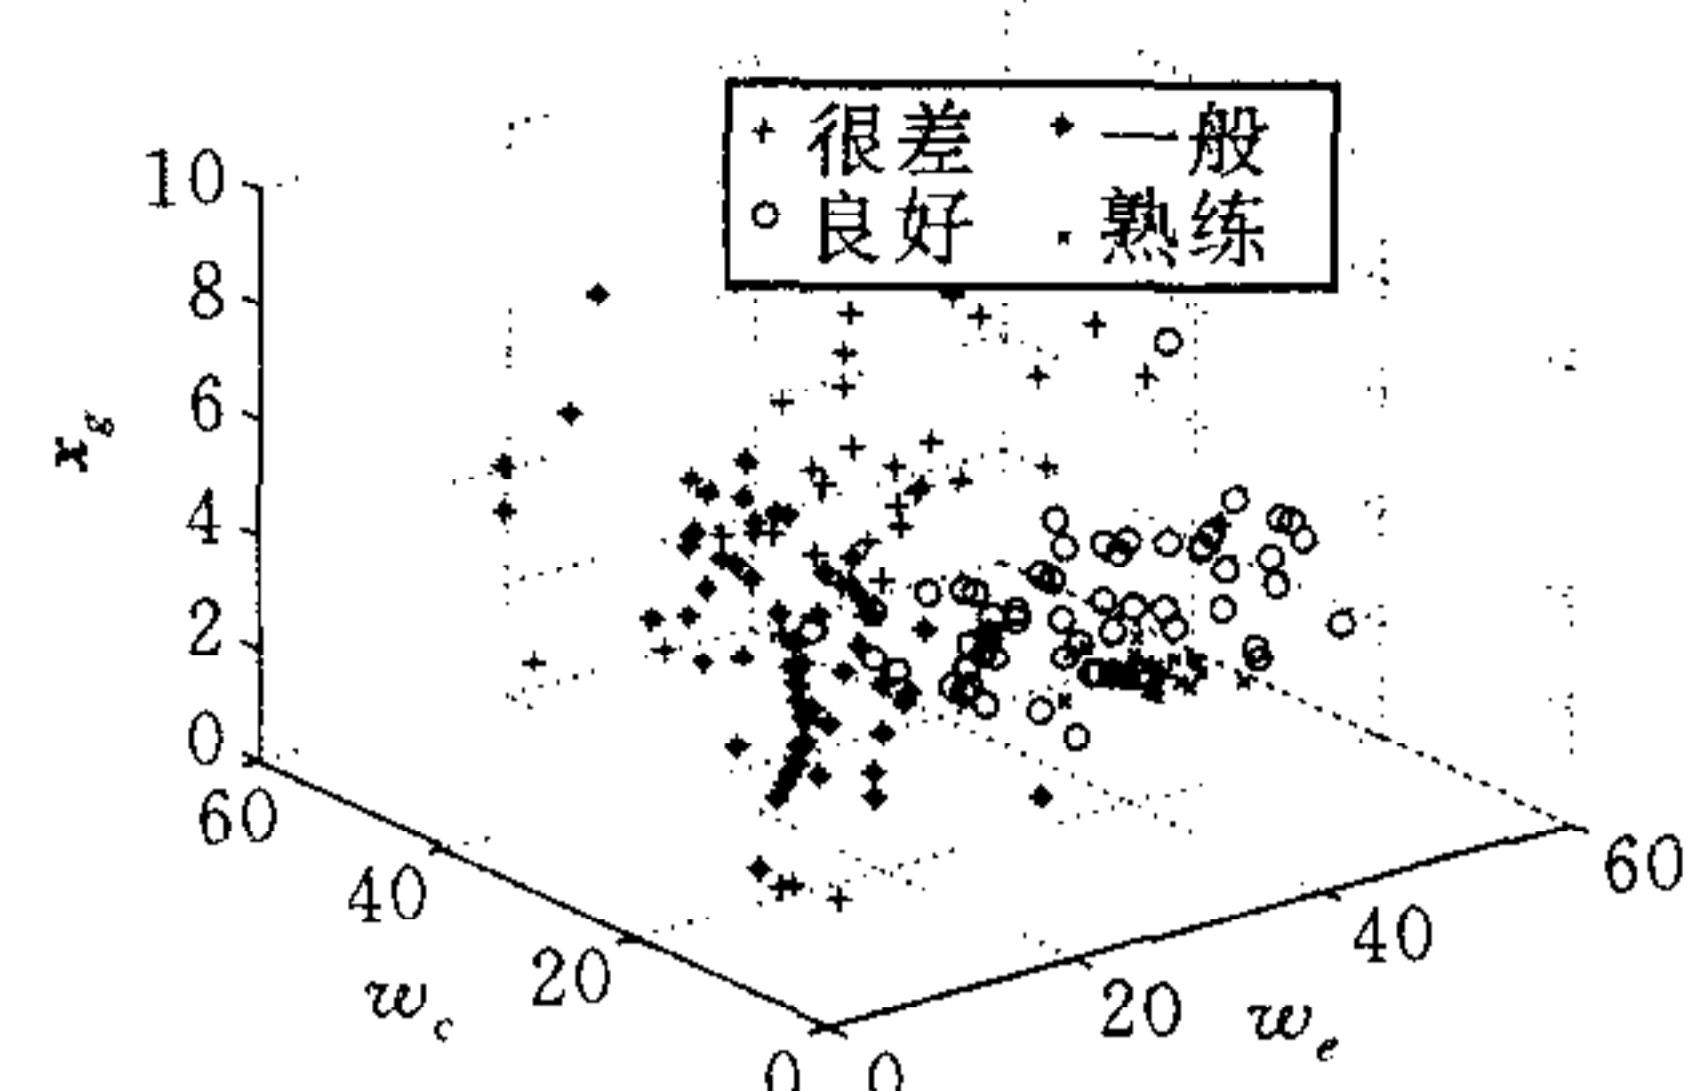


图 3 测试样本的分类结果

后的聚类中心更能体现合理的聚类结果,可以对相近输入模式进行分类.把它应用到智能驾驶中,尽管表征疲劳程度和熟练程度的样本空间特征相似,对驾驶员仍给出了正确的辨识结果.

参 考 文 献

- 1 Xie X L, Beni G. A validity measure for fuzzy clustering. *IEEE Trans. Pattern Analysis*, 1991, **13**:841~847
- 2 Chen C P, Lu Y. Fuzz; a fuzzy-based concept formation system that integrates human categorization and numerical clustering. *IEEE Trans. SMC*, 1997, **27**(1):79~94
- 3 施展,李郝林. 实验数据聚类有效性的评价及其应用. 模式识别与人工智能, 1997, **10**(2):184~188
- 4 Bezdek J C, Pal N R. An integrated approach to fuzzy learning vector quantization and fuzzy c-means clustering. *IEEE Trans. Fuzzy Systems*, 1997, **5**:622~628
- 5 Krishnapuram R, Keller J M. A possibilistic approach to clustering. *IEEE Trans. Fuzzy Systems*, 1993, **1**:98~110
- 6 Bezdek J C, Pal N R. Two soft relative of learning vector quantization. *Neural Networks*, 1995, **8**(5):729~743
- 7 马勇,石坚等. 运用模糊神经网络对驾驶员安全因素的识别. 计算技术和自动化, 1999, **18**(2):32~36
- 8 Alpaydin E. Soft vector quantization and the EM algorithm. *Neural Networks*, 1998, **11**:467~477

马 勇 1994 和 1997 年分别从天津大学和上海交通大学自动化专业获硕士和博士学位,现在河南新飞电器有限公司负责技术工作.研究方向为智能控制、图像识别和计算机网络通讯等.

杨煜普 博士后,现为上海交通大学智能研究室副主任.研究方向为智能控制等.

许晓鸣 博士生导师,现为上海交通大学副校长.研究方向为智能控制等.

第三届国际多智能体系统、复杂大系统及电子化商务学术会议征稿启示

3rd International Symposium on Multi-Agent Systems,

Large Complex Systems, and E-Businesses (MALCEB'2002)

会议时间:2002年10月8~10日

截稿时间:2002年6月30日

会议语言:英语

会议地点:德国图林根(Thuringia)州
爱尔福特(Erfurt)市

电 话:0044 141 331 8025

传 真:0044 141 331 8445

E-mail: lcsr@gcal.ac.uk

会议投稿地址:Prof. H. Tianfield

MALCEB'2002

Department of computing

Glasgow Caledonian University

City Campus

70 Cowcaddens Road

Glasgow G4 0BA

Scotland, United Kingdom

会议 URL 地址(区分大小写):<http://www.com.gcal.ac.uk/international/MALCEB2002.htm>

<http://www.netobjectdays.org/>

会议分类主题领域:多智能体系统(Multi-Agent Systems);复杂大系统(Large Complex Systems);电子化商务(E-Businesses);应用.

(各主题领域的具体征稿范围详见会议 URL).