基于属性计算网络的模式识别

许广林[1] 冯嘉礼[2] 刘永昌[2]

(上海海事大学物流工程学院 上海 200135)[1] (上海海事大学信息工程学院 上海 200135)[2]

摘 要 给出了如何建立属性网络,属性网络中定性基准的学习机制以及如何使用属性网络来实现模式识别,最后给出了该方法的应用实例。

关键词 属性网路,机器学习,模式识别

Pattern Recognition Method Based on the Attribute Computing Network

XU Guang-Lin[1] FENG Jia-Li[2] LIU Yong-Chang[2]

(Logistics Engineering Institute, Shanghai Maritime University, Shanghai 200135)[1]

(Department of Computer Science, Shanghai Maritime University, Shanghai 200135)[2]

Abstract In this paper, how to build a attribute computing network and how to calculate attribute criterion is given. After that, the pattern recognition method based on the attribute computing network brings forward. An actual application using such method is given in the end.

Keywords Attribute network, Machine learning, Pattern recognition

模式识别是一个快速发展的学科,并且由于具有广泛的应用而受到人们的特别重视。比如机器人的研制,其关键就在于目标的自动识别。确实人类具有很强的模式识别能力,因此,如何让机器具有人的模式识别能力是模式识别研究的一个主要课题。

利用定性映射,我们已在模式识别、故障诊断、行情预测等方面进行了一系列探讨,例如:李文佩利用定性映射中转化程度函数与模糊截集的关系进行了汉字识别[1],王洪利用定性映射正交基空间进行了股票的预测[2],上述研究主要通过统计识别和模糊模式识别。最近,根据定性映射的输入输出关系,我们提出了属性(计算)网络模型,本文将给出一个学习算法,利用输入模式对属性网络[3]中的定性基准进行调节,使网络实现模式识别功能。

1 属性计算网络的建立

定性映射在 n 维情况下,若将每一维定性基准[4] $[\alpha_i,\beta_i]$ 拓扑粒度细分为 m 段,则得到一个以各剖分 n 维超长方体为单元的网格,使原定性映射变为一个以其剖分网格为基准的定性映射,若分别以子超长方体为基准,还诱导出一个具有 m^n 个子定性映射的簇。图1给出了这种剖分的3维示意。

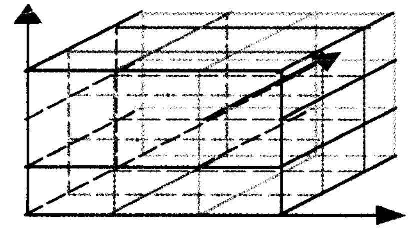

图1 基准剖分诱导的超长方体网格

定义1 设 $a_i(o)$ 是对象 o 的某个属性,$i=1,\cdots,n$,$x_i\in X_i$ 为 $a_i(o)$ 的量特征值,$p_{ij}(o)$ 是 $a_i(o)$ 的第 j 个质特征,$j=1,\cdots,m$,$|[\alpha_{ij},\beta_{ij}]\subseteq X_i$ 是 $p_{ij}(o)$ 的定性基准,$\Gamma=\{[\alpha_{ij},\beta_{ij}]\}$ 是定性基准的簇,满足:$[\alpha_{ij},\beta_{ij}]\cap[\alpha_{il},\beta_{il}]=\varnothing$,$l=1,\cdots,m$,$l\neq j$,和 $x_i=\bigcup_{j=1}^{m}[\alpha_{ij},\beta_{ij}]$。若设 $a(o)=\bigwedge_{i=1}^{n}a_i(o)$ 是属性 $a_i(o)$ 的合取属性,$x=(x_1,\cdots,x_n)\in X=X_1\times\cdots\times X_n\subseteq R^n$,为 $a(o)$ 的量特征值,若设 $[\alpha_{i_kj_l},\beta_{i_kj_l}]$ 是第 i_k 个属性 $a_{i_k}(o)$ 的第 j_l 个性质 $p_{i_kj_l}(o)$ 的定性基准,$i_k\in\{1,\cdots,n\}$,$j_l\in\{1,\cdots,m\}$,$[\alpha_v,\beta_v]=\{x=(x_1,\cdots,x_n)\in[\alpha_{i_1j_1},\beta_{i_1j_1}]\times\cdots\times[\alpha_{i_kj_l},\beta_{i_kj_l}]\times\cdots\times[\alpha_{i_nj_m},\beta_{i_nj_m}]\}$ 是不同维的 n 个定性基准 $[\alpha_{i_kj_l},\beta_{i_kj_l}]$ 构成的一个 n 维超长方体,这里,$(i_1j_1,\cdots,i_kj_l,\cdots,i_nj_m)$ 是下标 i_k 和 j_l 的一个组合,$v=v(i_1j_1,\cdots,i_kj_l,\cdots,i_nj_m)$ 是该组合的序数,由于对每一个 i_k,j_l 有 m 种不同的选择,故不同的组合共有 m^n 种,所以,$v\in\{1,\cdots,m^n\}$。设 $p_v(o)=\bigwedge_{\substack{k=1\\l=1}}^{n,m}p_{i_kj_l}(o)$ 是对象 o 的一个以 $[\alpha_v,\beta_v]$ 为定性基准的整合性质,$\Gamma=\{[\alpha_v,\beta_v]\}$ 是所有定性基准 $[\alpha_v,\beta_v]$ 格子的簇,并设 $([\alpha_v,\beta_v])=\begin{pmatrix}[\alpha_{11},\beta_{11}] & \cdots & [\alpha_{1m},\beta_{1m}]\\ \vdots & [\alpha_{i_kj_l},\beta_{i_kj_l}] & \vdots\\ [\alpha_{n1},\beta_{n1}] & \cdots & [\alpha_{nm},\beta_{nm}]\end{pmatrix}$ 是由这 m^n 个两两不相交的 n 维超长方体 $[\alpha_v,\beta_v]$ 构成的网格(grid),则以 $([\alpha_v,\beta_v])$(或 $G([\alpha_v,\beta_v])$)为基准的映射 $\tau:X\times\Gamma^n\to\{0,1\}$,若对任意 $x\in X$,存在 $[\alpha_v,\beta_v]\in\Gamma^n$ 和以 $[\alpha_v,\beta_v]$ 为基准的性质 $p_v(o)\in\mathscr{P}_o$,使得:

$$T\left((x_1,\cdots,x_n),\begin{pmatrix}[\alpha_{11},\beta_{11}] & \cdots & [\alpha_{1m},\beta_{1m}]\\ \vdots & [\alpha_{i_kj_l},\beta_{i_kj_l}] & \vdots\\ [\alpha_{n1},\beta_{n1}] & \cdots & [\alpha_{nm},\beta_{nm}]\end{pmatrix}\right)$$
$$=\bigvee_{j_l=1}^{m}\bigwedge_{i_k=1}^{n}\{(x_1,\cdots,x_n)\}\underset{?}{\in}[\alpha_{i_1j_1},\beta_{i_1j_1}]\times\cdots\times[\alpha_{i_kj_l},\beta_{i_kj_l}]\times\cdots\times[\alpha_{i_nj_m},\beta_{i_nj_m}]\}\qquad(1)$$
$$=\bigvee_{j_l=1}^{m}\{\cdots\{\bigwedge_{i_k=1}^{n}\tau_{v(j_1j_1,\cdots,i_kj_l,\cdots,i_nj_m)}(x)\}\}$$

其中,$$\tau_{v(i_1j_1,\cdots,j_kj_l,\cdots,j_nj_m)}(x)=\begin{cases}1 & \text{iff}\quad x\in[\alpha_v,\beta_v]\\ 0 & \text{iff}\quad x\notin[\alpha_v,\beta_v]\end{cases}\qquad(2)$$

则称式(1)是判断一个带有向量 x 的对象 o 是否具有性质 $p_v(o)$ 的定性映射,并称式(2)是以 $[\alpha_v,\beta_v]$ 为定性基准的定性映射,或式(1)的因子映射,也可记为:$\tau_p(x,[\alpha_v,\beta_v])$。

如图 2 所示，根据定性映射(1)的输入输出关系，可得到一个从定量的 x 到定性的性质 $p(o)$ 的特征转化结构图，不妨称之为定性映射单元或属性计算单元。

为图示方便，图 2 仅给出了 $m=3, n=2$ 的定性映射单元，其中，输入 $x_1(o)$ 和 $x_2(o)$ 是两属性 $a_1(o)$ 和 $a_2(o)$ 的两个量，在不同定性基准 $[\alpha_{1j},\beta_{2j}]$ 和 $[\alpha_{2j},\beta_{2j}]$，$j=1,2$ 的选择或滤波下，分别转化为两个相应的性质 $p_{1j}(o)$ 和 $p_{2j}(o)$，再经整合操作后，输出为 9 个不同的整合性质 $p_{1j,2j}(o)$。

因从特征值 $x_1(o)$ 和 $x_2(o)$ 到性质 $p_{1j}(o)$ 和 $p_{2j}(o)$ 转化，是一个从定量到定性的转化，所以，只要标定定性基准区间 $[\alpha_{1j},\beta_{2j}]$ 和 $[\alpha_{2j},\beta_{2j}]$ 的上下限，即可实现该转化操作和过程。考虑到定性基准 $[\alpha_{1j},\beta_{2j}]$ 和 $[\alpha_{2j},\beta_{2j}]$ 不仅是决定该转化操作即定性映射怎样实施，并决定其结果的关键或核心，为得到一个正确合理的判断真值，图 2 中特别增加了一个反馈调节回路。

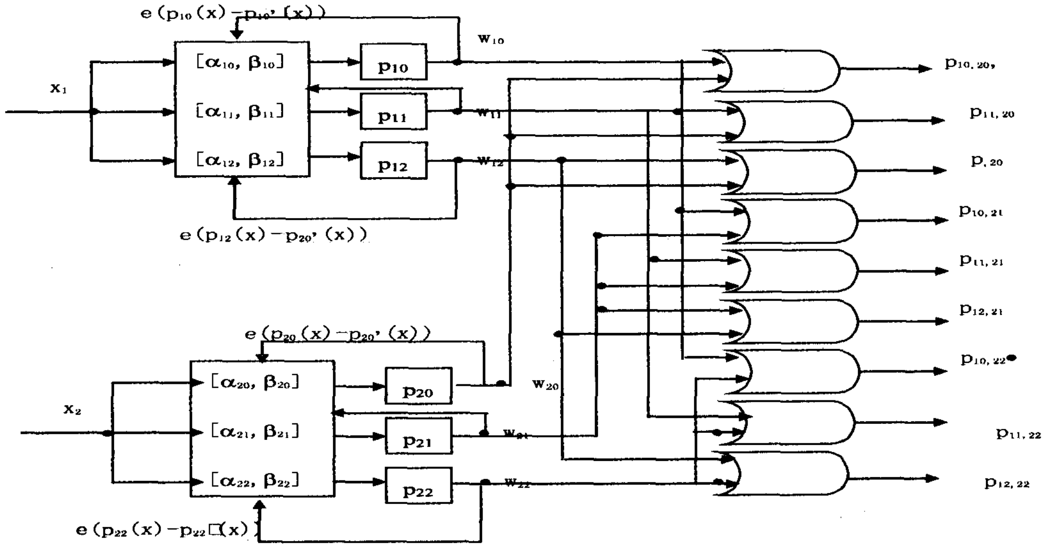

图 2　以 2 维 3×3 网络 $[\alpha,\beta]$ 为基准的定性映射诱导的属性计算单元

因属性计算网络可看作是若干定性映射单元的整合映射，所以属性计算网络可以把事物的特征通过多个定性映射单元整合而成的网络结构来记忆和表示，从而可以实现模式识别。

2　属性计算网络的训练和学习机制

属性网络建立好以后，下一步需要对属性网络进行学习和训练，也就是需要学习出网络中每个定性映射的定性基准。正如一种疾病的诊断标准是从众多患者的诊断经验中总结出来的一样，一个网格定性基准只能从一系列样本数据中，通过"去粗取精，去伪存真"的学习和总结而得到。根据这一思想，可以设计出一个反馈学习回路 π，它包括：输入——误差——反馈——修正等子过程，经过若干正、反例样本的学习和不断修正，可获得一个性质命题 $p_{ij}(o)$ 的正确的定性基准 $[\alpha_{ij},\beta_{ij}]$。下面给出相应的定义和算法。

设 $[\alpha_j,\beta_j]$ 是性质 $p_j(o)$ 的定性基准，$\{z_s(o)\}$，$s=1,\cdots n,\cdots$，为测试样本集，我们的问题是怎样从样本点的集合中，找到 $p_j(o)$ 的定性基准 $[\alpha_j,\beta_j]$。

如果设 $\{z_{jk}(o), k=1,\cdots w,\cdots\}$ 是正例样本集，则 $\{z_{jk}(0), k=1,\cdots w,\cdots\}\in[\alpha_j,\beta_j]\cap\{z_s(o)\}$，则由定性调节的本质可知，定性基准的调整可归结为一个极限过程，即：

$$\alpha_j=\lim_{k\to\infty}\{\min\{z_{jk}(o)\}\},\ \beta_j=\lim_{k\to\infty}\{\max\{z_{jk}(o)\}\} \tag{3}$$

只要从所有对应于 $p_j(o)$ 的 $\{z_{jk}(o), k=1,\cdots w,\cdots\}\subseteq\{z_s(o)\}$ 中，找到其上、下确界就行了。

由此可见在基于属性网络的模式识别技术就是一种广义模式识别技术，先建立属性网络，然后通过机器学习机制来找出属性网络中每个定性映射的定性基准，这个属性基准结构就是广义正交基空间的一个基础向量，待识别的模式就是另一个向量。

3　仿真实验

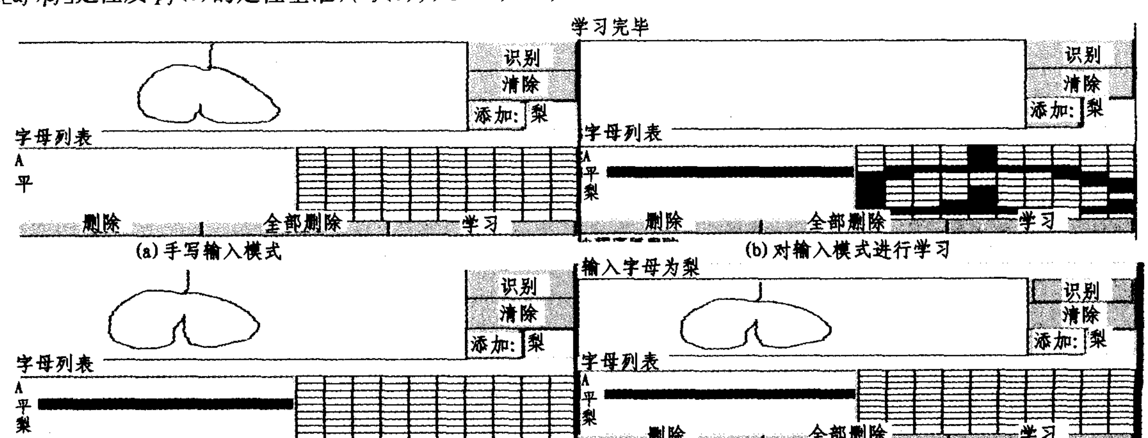

(a) 手写输入模式　(b) 对输入模式进行学习

(c) 已完全 A. 平. 梨三模式学习. 重新手写一个模式　(d) 输入被识别模式(注意输入模式与学习模式存在差异)并识别

图 3　训练属性网络记忆模式并进行识别

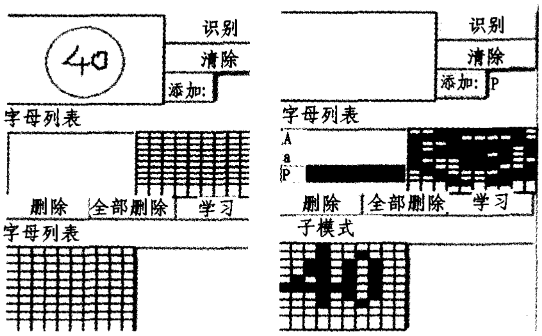

(a)限速40公里的交通标志　　(b)对图形进行学习

图4　嵌套映射结构模式识别

图3为能对输入模式进行记忆和识别的属性网络，首先在写字板(图左上角)上任画一个模式，如“”，计算机首先将模式“”在写字板中所占据的矩形划分为10×10子矩形构成的网格，并令所有与“梨”模式的交非空的子矩形染(黑)色，同时，令以染色子矩形为基准的子定性映射等于1，并将它们投射到右下角所示的记忆模式区，这时，该记忆区不仅出现了一个由10×10个子矩形所构成网格，而且，出现了一个由被染色子矩形构成的模式“”。即：一个以整个网格(整体)为基准的定性映射，和一个分别以10×10个子矩形为基准的子定性映射簇之间嵌套映射结构。在添加按纽的空格中，给所写模式命名，如命之为“梨”，再按学习按纽后，机器将在字母列表栏记下学习的结果“梨”，机器显示“学习结束”。重新写字板板中书写一个手写模式“”，按识别键，这时，机器显示“梨”。这个结果说明，计算机不仅记住了字母“”，而且，还将与“”有差异的模式“”也识别为“梨”。

图4为对输入的模式使用带有嵌套的属性网络来记忆和识别，也就是在图3例子的基础上对模式中重要的子模式单独建立相应的嵌套属性网络。图4中被识别的模式为限速40公里的交通示意图。假如使用图3中的方式来识别，子模式“40”将失真或丢失，所以在建立属性网络的同时，建立子属性网络来表示“40”的模式，这样将有效解决子模式失真或丢失问题。

结论　本文给出如何使用属性网络来实现模式识别，同时本文给出的模拟例子也充分说明了本方法在模式识别中的潜力。

参考文献

1　李文佩. 基于定性映射和转化程度函数的汉字识别[D]:[上海海事大学硕士论文]. 上海:2004

2　王洪，冯嘉礼. 定性映射正交基空间下的模式识别技术. 计算机工程,32(17)

3　Feng Jiali. Qualitative Mapping Orthogonal System Induced by Subdivision Transformation of Qualitative Criterion and Biomimetic Pattern Recognition, CHINESE JOURNAL OF ELECTRONICS, Special Issue on Biomimetic Pattern Recognition, 2006, 15 (4):850～856

4　Feng J. Support Vector Machine induced by Subdivision of Qualitative Criterion. In:Proc. of theIJCAI-2007, Workshop Theme: Complex Valued Neural Networks and Neuro-Computing: Novel Methods, Applications and Implementations. Hyderabad. India, January 2007. 48～53

(上接第192页)

从而1),2),3)成立。

充分性。设 $\bar{\omega}=(\omega,\omega_{n+1},\omega_{n+2})\in GF^n(2)$，$1\leqslant W(\bar{\omega})\leqslant m$，则总有 $0\leqslant W(\omega)\leqslant m-1$。

当 $\omega\neq 0$ 时，$1\leqslant W(\omega)\leqslant m-1$，因为 $f_1(x),f_2(x),f_3(x),f_4(x)$ 都是 m 阶相关免疫函数，所以 $S_{(f_i)}(\omega)=0$，$i=1,2,3,4$。从而 $S_{(\Psi)}(\bar{\omega})=0$。

当 $\omega=0$ 时，由条件1),2),3)知8),9),10)均成立，从而 $S_{(\Psi)}(\bar{\omega})=0$。

综上所述，我们总有 $S_{(\Psi)}(\bar{\omega})=0$，$\bar{\omega}\in GF^n(2)$，由 Xiao-Massey 定理知 $\Psi(x,x_{n+1},x_{n+2})$ 是至少 m 阶相关免疫的。

利用数学归纳法容易证明，对于任意 $x_1,x_2,\cdots,x_k\in GF(2)$，

$$(-1)^{x_1x_2\cdots x_k}=\frac{1}{2^{k-1}}[2^{k-1}-1+(-1)^2\sum_{i=1}^{k}(-1)^{x_i}+(-1)^3\sum_{i\neq j}^{k}(-1)^{x_i+x_j}+\cdots+(-1)^{k+1}(-1)^{x_1+x_2+\cdots+x_k} \qquad (11)$$

文[6]中给出了一种 Walsh 循环谱的分解式。设 $f(x),g(x),h(x)$ 都是 n 元布尔函数，则

$$S_{(f+gh)}(\omega)=\frac{1}{2}[S_{(f)}(\omega)+S_{(f+g)}(\omega)+S_{(f+h)}(\omega)-S_{(f+g+h)}(\omega)],\omega\in GF^n(2)$$

由11)，我们可以很容易证明。

有了上面的基础，我们给出这种 Walsh 谱分解式的推广形式。

引理5　设 $f(x),f_i(x),1\leqslant i\leqslant k$ 是 $k+1$ 个 n 元布尔函数，则

$$S_{(f+f_1f_2\cdots f_k)}(\omega)=\frac{1}{2^{k-1}}[(2^{k-1}-1)S_{(f)}(\omega)+(-1)^2\sum_{i=1}^{k}S_{(f+f_i)}(\omega)+(-1)^3\sum_{i\neq j}^{k}S_{(f+f_i+f_j)}(\omega)+\cdots+(-1)^{k+1}S_{(f+f_1+f_2+\cdots+f_k)}(\omega)],\omega\in GF^n(2)$$

由引理5不难得到：

定理5　设 $f(x)$，$f(x)+f_i(x)$ $(1\leqslant i\leqslant k)$，$f(x)+f_i(x)+f_j(x)(1\leqslant i,j\leqslant k)$，$\cdots$，$f(x)+f_1(x)+f_2(x)+\cdots+f_k(x)$ 都是 n 元 m 阶相关免疫函数，则 $f+f_1f_2\cdots f_k$ 是 n 元 m 阶相关免疫函数。

参考文献

1　Xiao Guozheng, Massey. A Spectral Characterization of Correlation-Immune Function. IEEE Transactions on Information Theory, 1988, 34 (3): 569～571

2　丁存生，肖国镇. 流密码及其应用. 国防工业出版社，1994

3　冯登国. 频谱理论及其在密码学中的应用. 北京：科学出版社，2000

4　Siegenthaler T. Correlation-immunity of nonlinear combining functions for cryptographic applications. IEEE Transactions on Information Theory, 1984, 30 (5): 776～780

5　Zhang Weiguo. Construction of plateaued functions satisfying multiple criteria. High Technology Letters, 2005, 11(4):364～366

6　Zheng Y, Zhang X M. Improved upper bound on the nonlinearity of high order correlation immune functions. In:Selected Areas in Cryptography. 7th Annual International Workshop, SAC 2000, Lecture Notes in Computer Science, Springer-Verlag, 2001, 2012:262～274

7　Chee S, Lee S, Sung S H. On the correlation immune functions and their nonlinearity. In:Advances in Cryptology-Asiacrypt'96, Lecture Notes in Computer Science, Springer-Verlag, 1996, 1163:232～243

8　王育民，何大可. 保密学——基础与应用. 西安电子科技大学出版社，1990