Fuzzy 语义推理的自学习算法

李太航　　黄　倩[1)]
（上海计算技术研究所）
赵　红　　沈祖梁
（天津工业自动化仪表研究所）（上海工业大学）

摘　　要

对一些复杂的非线性系统的控制，Fuzzy 语义推理有其巨大优越性，但由于客观过程的高度复杂，条件语义与结论语义的对应关系很难由人预先较为确切地给定．在实际应用中，这个对应关系最好能由控制系统自我调整或生成．

由于多因素推理结果对最终结论影响的权重是随机变化的，在大的复杂系统中，人难以掌握权重的变化规律．本文还给出了解决权重变化规律自产生的一种算法．

一、问题的提出

一个复杂过程的 Fuzzy 测辨系统，它的最终测辨将是形如 $\frac{P', P \to Q}{Q'}$ 的 Fuzzy 变换的复合，其中的任一 Fuzzy 变换均可以 Fuzzy 条件语句为其约束．Fuzzy 条件语句表述的是人对该复杂系统一些基本规律的大致总结．

对于 Fuzzy 测辨系统，人的经验只应是 Fuzzy 条件语句的初态，系统必须在实际应用过程中予以随机调整．可能的话，由系统自我生成一些人事先没有觉察或没法给出的经验，也只有这样，该测辨系统才有可能获得实际应用．

此外，一个多因素作用下的大的复杂系统，存在着各因素对过程影响的权重，难点在于，这个权重是不固定的．情况不同，权重也不同．人很难觉察出由于情况变化各因素的权重的变化情况，从而即使利用了单因素作用下的人为经验，其综合作用效应仍会显得难以琢磨．鉴于此，在各种不同情况下的单因素权重的自产生，在复杂系统的测辨中也就显得至关重要．

二、条件语义区间的自修正

设某单因素条件语义区间的划分为

$$(a_0, a_1), (a_1, a_2), \cdots (a_{n-1}, a_n),$$

本文于1982年12月9日收到．

1) 首都钢铁公司柴寿仁、王濠清、李连仲、杨振家、周强、刘刚成、金岳义、徐礼格等参加了该项工作．

结论语义区间的划分为

$$(b_0,\ b_1),(b_1,\ b_2),\cdots(b_{m-1},\ b_m).$$

各区间分别对应语义名 A_1, A_2, $\cdots A_n$ 及 B_1, B_2, $\cdots B_m$. 辅以时间序列，条件语句的形式为

$$\text{if } a \in A_i \text{ and } b_{t-l} \in B_j \text{ then } b_t \in B_K.$$

由于 a 的归属有 n 种可能，b_{t-l} 有 m 种可能，所以这样的条件语句当有 mn 个. 这是单因素作用下粗略的因果规律. 然后通过条件语义区间的修正来完善与调整该条规律.

1. 修正方向

设 $b_{t-l} \in B_j$,给条件语句以表格形式,见表 1.

表　1

b_{t-l} \ a	A_1	A_2	……	A_i	A_{i+1}	……	A_n
B_j	$B_{j,1}$	$B_{j,2}$	……	$B_{j,i}$	$B_{j,i+1}$	……	$B_{j,n}$

如果当前输入 a 属于语义 A_i，则在 b_{t-l} 属 B_j 语义时，可得预测范围为 $B_{j,i}$. 今若实测值 $b_t \bar{\in} B_{j,i}$,则意味预测产生错误. 错误的原因显然是引用条件语句的不正确.

如果实测 $b_t \in B_{j,i+1}$, 由语句表不难发现,应该引用的条件语句应为

$$\text{if } a \in A_{i+1} \text{ and } b_{t-1} \in B_j \text{ then } b_t \in B_{j,i+1}.$$

也即倘若 $a \in$ 语义 A_{i+1}, 则预测语义与实测语义吻合. 鉴于此，如果将 A_i 的右端点 a_i 适当左移（减值），$a \in A_i$ 语义的可能性将会减小,而 $a \in A_{i+1}$ 语义的可能性将会增大.

如果实测 $b_t \in B_{j,i-1}$,不难推得,应将 A_i 的左端点适当右移,从而缩小 A_i 的语义范围,并使 $a \in A_{i-1}$ 语义的可能性增大.

2. 修正值

因 $a \in A_i$ 导出预测错误，并不意味必须立即把 $[a_{i-1},\ a]$ 或 $[a,\ a_i]$ 排除出 A_i 的语义区间,而仅说明将其排除的可信度增加. 设该可信度值为 $\bar{\mu}$,若 $\bar{\mu}=1$,当然理应将其全部排除;当 $\bar{\mu}<1$ 时,排除部分可为 $\bar{\mu}|a-a_{i-1}|$(或 $\bar{\mu}|a_i-a|$).

现不妨假定待修改的为左端点 a_{i-1}.

由于 $[a_{i-1},\ a] \bar{\in} A_i$ 的可信度即为 $[a_{i-1},\ a] \in A_i$ 的可疑度,而在文献[1]中,已给出并证明了单因素作用时 $[a_{i-1}, a] \in A_i$ 的可疑度递推生成公式

$$\eta_{Ai}^{(N)}([a_{i-1},\ a]) = \frac{G(N)}{F(N)+G(N)}.$$

其中 $G(N)=\sum_{r=1}^{N} g(\lambda_r^-)$; λ_r^- 为第 r 次预测的错误程度; g 为该错误的评价函数; N 为当前预测的次数; $F(N)=\sum_{r=1}^{N} f(\lambda_r^+)$; λ_r^+ 为第 r 次预测的正确程度; f 为该正确性的评价函数.

若把整个条件论域作M个细小分划,落在 A_i 语义区间 $[a_{i-1}, a_i)$ 共有 M_i 个分划 $a_i^{(1)}$, $a_i^{(2)}$, $\cdots$, $a_i^{(Mi)}$ (其中 $a_i^{(1)}=a_{i-1}$, $a_i^{(Mi)}=a_i$). 于是，通过实践可以生成 M_i 个正、负效

果评价累积 $\Sigma f(\lambda_{r,h}^{+})$ 与 $\Sigma g(\lambda_{r,h}^{-})$ $(h=1,2,\cdots M_i)$.

今设 $a_i^{(s)}<a\leqslant a_i^{(s+1)}$，则有

$$\bar{\eta}_{Ai}^{(N)}([a_{i-1},a])=\frac{\sum_{r=1}^{N}g(\lambda_r^-)}{\sum_{r=1}^{N}f(\lambda_r^+)+\sum_{r=1}^{N}g(\lambda_r^-)}=\frac{\sum_{r=1}^{N}\sum_{h=1}^{s}g(\lambda_{r,h}^-)}{\sum_{r=1}^{N}\sum_{h=1}^{s}f(\lambda_{r,h}^+)+\sum_{r=1}^{N}\sum_{h=1}^{s}g(\lambda_{r,h}^-)}.$$

故修正步长

$$\Delta_i=|a-a_{i-1}|\cdot\bar{\eta}_{A_i}([a_{i-1},a])=|a-a_{i-1}|\frac{\sum_{r=1}^{N}\sum_{h=1}^{s}g(\lambda_{r,h}^-)}{\sum_{r=1}^{N}\sum_{h=1}^{s}f(\lambda_{r,h}^+)+\sum_{r=1}^{N}\sum_{h=1}^{s}g(\lambda_{r,h}^-)}.$$

不难推得右端点的修正步长公式除标号的一些变动外，亦与之相仿佛．在实际应用中，可令:

$$\lambda_{r,h}^-=\begin{cases}2 & \text{语义不符且误差大于允许值,}\\ 1 & \text{语义符但误差大于允许值,或语义不符但误差小于允许值,}\\ 0 & \text{语义符且误差小于允许值或 } a\,\bar{\in}\,(a_i^{(h)}a_i^{(h+1)}),\end{cases}$$

$$\lambda_{r,h}^+=\begin{cases}2 & \text{语义符且误差小于允许值,}\\ 0 & \text{语义不符或误差大于允许值或 } a\,\bar{\in}\,(a_i^{(h)}a_i^{(h+1)}),\end{cases}$$

并且 $f(\lambda_{r,h}^+)=\lambda_{r,h}^+$，$g(\lambda_{r,h}^-)=\lambda_{r,h}^-$.

显然，修正后 $(a_{i-1},a_{i-1}+\Delta_i]$ 归入新语义区间，其所属分划的正、负效果评价累积均置初态．

由修正步长公式不难看出，如正效果评价累积相对很大，修正值将会很小．而且，如果纯属偶然的出错，由于此时 $\sum_{r=1}^{N}\sum_{h=1}^{s}f(\lambda_{r,h}^+)\gg\sum_{r=1}^{N}\sum_{h=1}^{s}g(\lambda_{r,h}^-)$，修正值将近似于零．相反，当负效果评价累积相对很大时，修正值也相应增大，以期迅速摆脱语义区间的错误部分．

由于规律本身的动荡性与多变性，只要求使修正能不断追踪规律的变化，而没有必要强求修正必然稳定趋向于某固定值．

三、条件语句的自产生

在引用条件语句

$$\text{if } a\in A_1 \text{ and } b_{t-1}\in B_j \text{ then } b_t\in B_{j,1}$$

时，如果实测 $b_t'\,\bar{\in}\,B_{j,1}$，同时又 $b_t'\,\bar{\in}\,B_{j,i}(i=2,\cdots n)$，于是需修改的当是 A_1 的左端点 a_0，

但 a_0 的右移至 a_0'，将使条件论域上出现新的语义区间 $[a_0, a_0')$，如果把 $[b_t', b_0)$ 视作新的结论语义区间，于是构成了新的条件语句．如 A_1 语义为慢，经左端点修改后，即可产生新的条件语义"很慢"，当然还可进一步产生"非常慢"、"慢极了"……等等．同样，A_n 端点 a_n 的左移，也可产生新的语义．

这样，系统等于是在修改并扩充着人预先给定但并不完备的经验．

四、多因素协同作用的权重自生成

设 k 个因素的输入值分别为 $a^{(1)}, a^{(2)}, \cdots, a^{(k)}$，所属条件语义为 $A_i^{(1)}, A_i^{(2)}, \cdots, A_i^{(k)}$，各因素对结论的预测值分别为 $b_i^{(1)}, b_i^{(2)}, \cdots, b_i^{(k)}$，结论语义为 $B_{j,i}^{(1)}, B_{j,i}^{(2)}, \cdots, b_{j,i}^{(k)}$.

由于在修改条件语义区间时，语义规则本身被认为正确的，也即当 $b_{t-1} \in B_j$ 时，由 $A_i^{(1)} \Longrightarrow b_t \in B_{j,i}^{(1)}$ 的可信度为 $1(1=1, 2, \cdots k)$．据文献 [1] 该可信度表示为

$$\bar{\mu}_{B_{j,i}^{(l)}}(A_i^{(l)}) = 1, \quad (l = 1, 2, \cdots, k).$$

今有具体输入 $a^{(1)}$，那么由 $a^{(1)} \Longrightarrow b_t \in B_{j,i}^{(1)}$ 的可信度由文献 [1] 给出的公式当为

$$\bar{\mu}_{B_{j,i}^{(l)}}(a^{(l)}, A_i^{(l)}) = \bar{\mu}_{B_{j,i}^{(l)}}(A_i^{(l)})\bar{\mu}_{A_i^{(l)}}(a^{(l)}) = \bar{\mu}_{A_i^{(l)}}(a^{(l)}).$$

不妨设 $a^{(l)}$ 落入 $A_i^{(l)}$ 上的分划 $a_i^{(l,s)}$ 与 $a_i^{(l,s+1)}$ 之间，并设当前为第 N 次预测，于是据文献 [1] 的可信度递推生成公式当有

$$\bar{\mu}_{A_i^{(l)}}^{(N)}(a^{(l)}) = \frac{F(N)}{F(N)+G(N)} = \frac{\sum_{r=1}^{N} f(\lambda_{r,l_s}^{+})}{\sum_{r=1}^{N} f(\lambda_{r,l_s}^{+}) + \sum_{r=1}^{N} g(\lambda_{r,l_s}^{-})}.$$

也即由 $a^{(l)} \Longrightarrow b_t \in B_{j,i}^{(l)}$ 的可信度

$$\bar{\mu}_{B_{j,i}^{(l)}}^{(N)}(a^{(l)}, A_i^{(l)}) = \frac{\sum_{r=1}^{N} f(\lambda_{r,l_s}^{+})}{\sum_{r=1}^{N} f(\lambda_{r,l_s}^{+}) + \sum_{r=1}^{N} g(\lambda_{r,l_s}^{-})}.$$

此即为多因素协同作用时各因素的相对权重．而实际预测值 b_t 当为

$$b_t = \frac{\sum_{l=1}^{k} \dfrac{\sum_{r=1}^{N} f(\lambda_{r,l_s}^{+})}{\sum_{r=1}^{N} f(\lambda_{r,l_s}^{+}) + \sum_{r=1}^{N} g(\lambda_{r,l_s}^{-})} b_t^{(l)}}{\sum_{l=1}^{k} \dfrac{\sum_{r=1}^{N} f(\lambda_{r,l_s}^{+})}{\sum_{r=1}^{N} f(\lambda_{r,l_s}^{+}) + \sum_{r=1}^{N} g(\lambda_{r,l_s}^{-})}}.$$

不难看出，若由输入 $a^{(l)}$ 导致的预测与实测相符，必然导致 $\sum_{r=1}^{N} f(\lambda_{r,l_s}^{+})$ 的递增，从而

该因素的相对权重增大．相反，则 $\sum_{r=1}^{N} g(\lambda_{r,ls}^{+})$ 递增，从而该因素的相对权重减小．

一个实用的预测系统当是个多因素多环节系统，此时应把后一环节对输入的期望语义看作前一环节的实测语义值，从而上述语义自修正与权重的自生成方法均可被整个系统递归采用．

五、应 用

上述方法曾应用于高炉冶炼铁水含 [Si] 量的预测系统．离线实验结果表明，通过若干炉次的自学习，系统对后续炉次铁水含 [Si] 量预测的命中率有了显著提高，一般可由 60% 提高至 85% 以上．显然，如果冶炼条件相同，学习炉次越多，预测命中率将越高．

图 1 为经过 26 炉自学习后系统预测误差情况与单纯模糊预测以及工长经验预测误差情况的对照．不难看出，无论是误差小于 0.5 的命中情况还是与实际值的贴近、跟踪程度，前者均比后两者好得多．

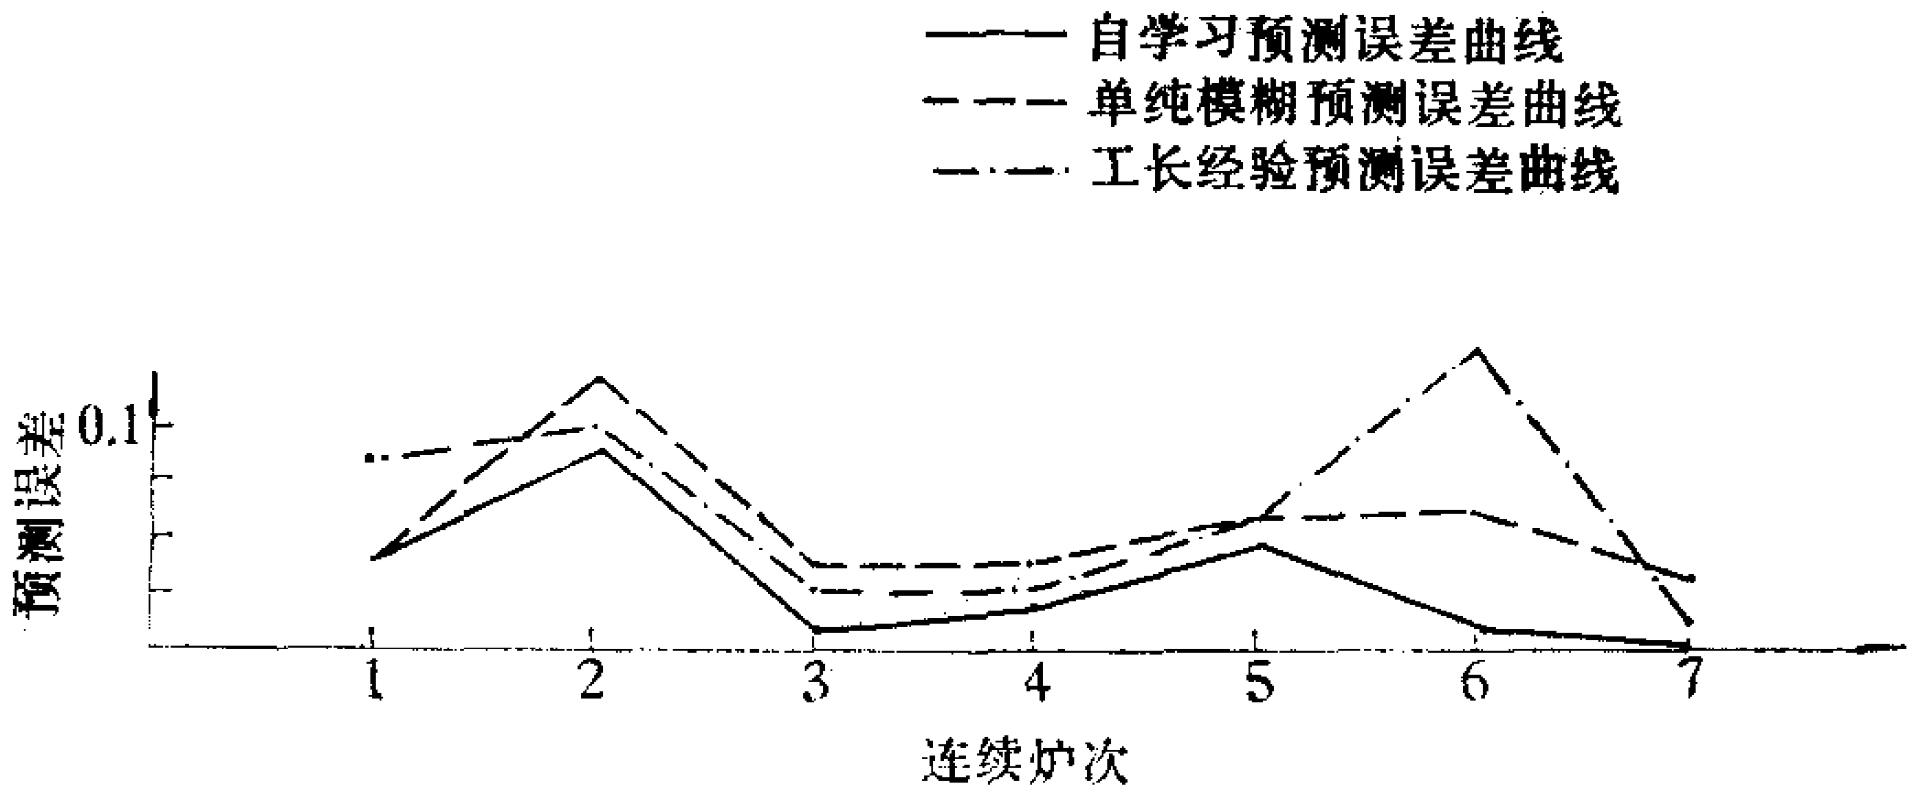

图 1

参 考 文 献

[1] 李太航，n 级概念空间中的纵向推理与隶属度的自生成，计算技术通讯，1983 年第 1 期．

[2] 李宝绥、刘志俊，用模糊集合理论设计一类控制器，自动化学报，1980 年第 1 期．

[3] 张仁生、刘俊杰等，Fuzzy 控制器与 Fuzzy 系统，模糊数学，1981 年第 1 期．

[4] 李太航，人脑思维特性的计算机模拟，计算技术通讯，1982 年第 1 期．

SELF-LEARNING ALGORITHM OF FUZZY SEMANTIC INFERENCE

LI TAIHANG　HUANG QIAN
(*Shanghai Institute of Computer Technology*)

ZHAO HONG
(*Tianjin Institute of Process Automation and Instrumentation*)

SHEN ZULIANG
(*Shanghai University of Technology*)

ABSTRACT

For the control of complicated nonlinear systems, fuzzy semantic inference has its great superiority. However, since the objective processes are very complicated,it is difficult to exactly provide the correspoding relationship between the conditional semanteme and conclusive semanteme in advance. For practical application, it is desirable for this relationship to be obtained by self-adjusting or even self-generating in the control system.

Furthermore, because the weight inference exerted by the inference consequence of multi-factor input on the final consequence varies at random, the regularity of the weight variance can hardly be observed in a large and complicated system. Therefore, this paper presents an algorithm solving the self-generating of this regularity in a control system with complicated processes.