

基于证据推理的 ACM/ICPC 集训队员选拔评价方法

傅仰耿, 吴英杰, 王一蕾, 孙岚, 陈鸿

(福州大学数学与计算机科学学院, 福建 福州 350116)

摘要: 针对传统采用积分制的 ACM/ICPC 集训队员选拔评价方法所存在的缺陷与不足, 提出基于证据推理的 ACM/ICPC 集训队员选拔评价方法, 变传统的定量评价为定性评价. 实践表明, 该方法可有效处理评价信息缺失或不确定的情况, 所得评价结果更趋于合理.

关键词: 证据推理; ACM/ICPC; 集训; 队员选拔

中图分类号: N93

文献标识码: A

An evidential reasoning based approach for selection and evaluation of ACM/ICPC training players

FU Yang-geng, WU Ying-jie, WANG Yi-lei, SUN Lan, CHEN Hong

(College of Mathematics and Computer Science, Fuzhou University, Fuzhou, Fujian 350116, China)

Abstract: Due to the shortcomings of the traditional points system in selecting and evaluating the training players, we propose an evidential reasoning based approach for the selection and evaluation of ACM/ICPC training players. The proposed approach changes the traditional evaluation from quantitative into qualitative. Practice shows that this new method can effectively deal with the evaluations when information is missing or uncertain and the evaluation results tend to be more reasonable.

Keywords: evidential reasoning; ACM/ICPC; training; players selection

ACM/ICPC^[1] 是美国计算机协会主办的国际大学生程序设计竞赛, 从 1971 年开始, 至今已成功举办 36 届. 中国大陆各高校从 1996 年开始参赛. 近 5 年来, 福州大学 ACM/ICPC 集训队已经形成相对有效的队员选拔和集训的机制. 然而, 对队员进行评价带有很多的主观直觉和不确定性. 如何更好地建模这些不确定性, 更准确客观地评价和选拔队员, 一直是集训队面临的重要问题. 本文对照传统采用积分制的评价与选拔方法, 介绍将证据推理方法应用于 ACM/ICPC 集训队员的评价与选拔的具体做法, 并对两种方法进行了比较.

1 证据推理(ER)方法概述

将 D-S 理论^[2-3]用于多准则决策是 Yang 和 Singh 提出的, 他们引入 D-S 理论的证据合成法则, 推导出了部分合成和总体合成两个递推算法, 可以处理多准则决策问题的定量准则、定性准则或者定量和定性准则混合的信息合成, 并给出了方案排序选优的算法^[4-5]. 但是, 该方法是以一个在当时比较合理的假设为前提的, 即: 决策者对每个准则的评价要么选择一个等级, 要么选择相邻的两个等级. 这个假设对于单人决策比较适合, 但对于群决策就无法适用了. 另外, 该方法在计算 Mass 函数值所用到的优先系数 α 在实际的应用中也比较难确定.

为了进一步建模复杂决策问题的不确定信息, Yang 又提出了一种用于建模不完全和不精确信息的通

收稿日期: 2012-06-13

通讯作者: 傅仰耿(1981-), 讲师, E-mail: fu@fzu.edu.cn

基金项目: 国家杰出青年科学基金资助项目(70925004); 福建省教育厅科研资助项目(JA10035); 福州大学科技发展基金资助项目(2009-XY-17); 福州大学本科高等教育教学改革工程资助项目(福大教[2010]32号、[2012]47号)

用决策模型^[6],在构建通用扩展决策矩阵的基础上,使用基于规则和效用的评价信息转换方法和证据推理方法,处理决策矩阵中不同类型信息的转换和集结,并证明了转换前后评价信息的潜在效用值等价,而且合理有效的保留了原始评价信息.

上述 ER 模型在某些情况仍有可能导致不合理的结果,鉴于此, Yang 和 Xu 又对该模型进行了进一步的完善.他们研究了 ER 方法的基础特性,并提出了准则权重规范化和基本概率分配(basic probability assignments, BPA)的新方法^[7],进一步发展原有的 ER 方法,改进了不确定准则信息集结的过程,使用效用区间描述决策分析中对无知信息的影响,这些最终成为了 ER 方法的理论基础.

为了推进 ER 方法的应用,作为其发展所必不可少的一部分, ER 方法信息集结过程的非线性特性^[8]需要深入细致的研究. Yang 和 Xu 通过检验和谐(harmonic)评价、准和谐(quasi-harmonic)评价、矛盾(contradictory)评价等几种典型的推理模式,建立了对应的非递推推理函数,并应用于两个算例的决策情形,展示了 ER 方法的非线性特性,使人们更加深刻理解 ER 方法的递推性质.

迄今,基于证据推理的不确定多准则决策方法已经走向成熟.作为其理论成熟的标志,IDS 智能决策系统(intelligent decision system, IDS)软件包^[9-11]也已发布,促进了 ER 方法的推广和应用.

2 集训队员选拔评价方法

2.1 传统的选拔评价方法

福州大学集训队员选拔主要针对福州大学大一、大二的本科生(不限专业).选拔机制采取积分制,总得分(general rating, GR)主要包括平时的做题数目(problem rating, PR)、FOJ 月赛排名(monthly rating, MR)、Top Coder 排名(top coder rating, TCR)、校赛排名(programming contest rating, PCR)、训练排名(training rating, TR)和逆商等级(adversity quotient rating, AQR)共 6 个部分的积分值.

最初使用简单的加权方法(式(1))来综合候选队员在各方面的表现.

$$GR = PR + MR + TCR + PCR + TR + AQR \quad (1)$$

候选队员各个方面的表现值由具体的自定义转换公式计算得出,如 PR(平时的做题数)的表现值一般取队员在各大 OJ 的做题数与 OJ 系数乘积之和, OJ 系数一般是根据所选择 OJ 的大体难易程度而凭经验直觉给出的一个具体值,例如, POJ 和 FOJ 的 OJ 系数为 1.5, HDOJ 的 OJ 系数取为 0.8,其他的 OJ 如 UVA、SPOJ、SGU、URAL 等则取 1.8.由此,若某个候选队员在 FOJ 做了 300 题,则其在 PR 方面的表现值即为 $300 \times 1.5 = 450$.其他几个方面的表现值主要根据排名确定.表 1 给出了使用传统积分值进行队员评价与选拔的部分数据.

表 1 使用传统方法的部分评价数据

Tab.1 Partial evaluation data by using traditional method

| 队员 | 排名 | GR | PR | MR | TCR | PCR | TR | AQR |
|------|----|-------|-----|-----|-----|-----|-----|-----|
| 候选 1 | 1 | 2 151 | 791 | 420 | 100 | 300 | 410 | 130 |
| 候选 2 | 2 | 1 641 | 251 | 570 | 0 | 300 | 380 | 140 |
| 候选 3 | 3 | 1 604 | 564 | 390 | 100 | 200 | 220 | 130 |
| 候选 4 | 4 | 667 | 207 | 90 | 0 | 50 | 190 | 130 |
| 候选 5 | 5 | 505 | 0 | 120 | 0 | 100 | 150 | 135 |

很显然,上述集训队员的选拔评价问题本质上是一个多准则决策问题.可以使用一个决策矩阵 D 来描述候选队员的表现情况:

$$D = (x_{ij})_{N \times M} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1M} \\ x_{21} & x_{22} & \cdots & x_{2M} \\ \vdots & \vdots & \vdots & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{NM} \end{pmatrix} \quad (2)$$

其中:行表示待选的决策方案(候选队员) $A_1 \cdots A_N$;列表示评价准则 $C_1 \cdots C_M$; x_{ij} 表示第 i 个方案在第 j 个准则上取得的表现值.使用以下公式计算每位候选队员的最终表现值,从而进行排序与选优.

$$D_i = \sum_{j=1}^M x_{ij} \tag{3}$$

然而这种方法在某些情况下不太适合使用, 如: 某个候选队员缺少在某一准则的表现值, 即他可能因为某种原因没有参加校赛或者没有参加某几次的训练. 这间接造成了无法使用公式(1)得到最终确切的综合表现值, 目前有些研究也给出了一些解决方案, 如使用 0 或者平均值代替. 不管怎样, 这些方案都不能很客观的体现出候选队员的真实状态. 另外, 在候选队员的选拔过程中, 虽然使用了量化的评估计算方式, 其实这个过程或多或少还带有很多主观的不确定、模糊评判, 如做题数的转换公式所使用的系数、各个比赛排名的积分值等. 为了更好地评价候选队员的实力, 建模评价过程中所碰到的不确定性, 引入 ER 方法对候选队员进行评价.

2.2 基于证据推理的选拔评价方法

证据推理方法是基于证据理论和决策理论而提出来的一种不确定多准则决策方法, 以下首先简要介绍证据理论的基本概念和 Dempster 合成法则^[2-3], 然后再引入证据推理方法.

假设 $H = \{H_1, H_2, \dots, H_L\}$ 为某问题的各个互相独立、整体上完备的命题所构成的一个有限集合, 则称 H 为识别框架. 称函数 m 为 H 上的基本概率分配(BPA), 如果函数 $m: 2^H \rightarrow [0, 1]$, 满足 $m(\phi) = 0$ 和 $\sum_{A \subseteq H} m(A) = 1$. 这里 ϕ 表示空集, A 是 H 的子集, 2^H 为 H 的幂集, 包含所有 H 的子集, 即 $2^H = \{\phi, \{H_1\}, \{H_2\}, \dots, \{H_L\}, \{H_1, H_2\}, \dots, \{H_1, H_L\}, \dots, H\}$, 对于任意 $A \subseteq H$, $m(A)$ 也称为 mass 函数, 用于表示证据支持命题 A 发生的程度, 如果 $m(A) > 0$ 则称 A 为证据的焦元, 所有焦元的集合称为核.

证据理论使用直和运算来合成不同证据源, $m = m_1 \oplus m_2 \oplus \dots \oplus m_k$, 这个直和运算就是 Dempster 合成法则, 在证据推理方法中用于合成不同准则的评价信息. 假设 m_1 和 m_2 是定义在 H 上的两个 mass 函数(来自不同的证据源), 则用于合成这两个证据的 Dempster 合成法则可以表示为:

$$m(C) = [m_1 \oplus m_2](C) = \begin{cases} 0 & (C = \phi) \\ \frac{\sum_{A \cap B = C} m_1(A)m_2(B)}{1 - \sum_{A \cap B = \phi} m_1(A)m_2(B)} & (C \neq \phi) \end{cases} \tag{4}$$

使用证据推理方法首先要建立一个评价准则的树形层次结构(即评价的指标体系), 如图 1 所示; 然后对每一个准则收集其在 H 上的分布式评价信息; 最后再使用 Dempster 合成法则自下而上逐级合成.

在传统的决策矩阵中矩阵元素是一个精确的数值, 用于表示某个方案在某个准则上的评价, 属于定量评价. 与传统方法不同, 证据推理方法使用一个分布来代替这个精确数值, 属于定性评价, 使用这样的分布式评价信息构成的决策矩阵被称为扩展的决策矩阵 ED^[7-8]:

$$ED = (S_{ij})_{N \times M} = \begin{pmatrix} S_{11} & S_{12} & \dots & S_{1M} \\ S_{21} & S_{22} & \dots & S_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ S_{N1} & S_{N2} & \dots & S_{NM} \end{pmatrix} \tag{5}$$

这里: $S_{ij} = \{(H_n, \beta_{n,j}(A_i))\}$, $n = 1, 2, \dots, L$, $\beta_{n,j}(A_i)$ 表示证据支持第 i 个方案(A_i) 在第 j 个准则上被评价为 H_n 置信度, 要求 $\sum_{n=1}^L \beta_{n,j} \leq 1$, 若 $\sum_{n=1}^L \beta_{n,j} = 1$, 则为完全评价, 否则为不完全评价. 例如定义识别框架 $H = \{\text{很好, 好, 一般, 差, 很差}\}$, 则对 $\{(好, 0.3), (很好, 0.7)\}$ 和 $\{(好, 0.2), (很好, 0.7)\}$ 这两个分布式评价信息来说, 前者属于完全评价, 而后者属于不完全评价, 因为后者还有置信度为 0.1 是无知(unknown)的. 值得注意的是, 可以使用 $\{H, 1.0\}$ 来表示完全无知的情况; 另外, 传统的定量评价也可以转化为定性评价, 如某定量评价值为 83, 定义 80 为“好”, 100 为“很好”, 则 83 可以转换为定性的分布式评价: $\{(好, 0.85), (很好, 0.15)\}$.




图 1 准则的层次结构
Fig. 1 Hierarchy of criteria

尽管证据推理方法使用 Dempster 合成法则来进行不同准则之间评价信息的合成, 但不会出现证据理

论中的合成悖论问题^[12],这是因为在证据推理方法中定义了更为合理的 BPA 计算方式使得每个准则的评价信息都包含有不确定的信息. 即,第 j 个准则的 mass 函数定义为其权重乘以置信度:

$$m_{n,j} = w_j \beta_{n,j}$$

这里要求 $\sum_{j=1}^M w_j = 1$, 而 $m_{H,j} = \tilde{m}_{H,j} + \overline{m}_{H,j}$ 表示第 j 个准则所包含的不确定信息, 其中 $\overline{m}_{H,j} = 1 - w_j$ 表示

由于准则权重引起的不确定信息, $\tilde{m}_{H,j} = w_j(1 - \sum_{n=1}^L \beta_{n,j})$ 则表示评价信息不完全引起的不确定信息, 显然可以保证 $m_{H,j} > 0$.

证据推理方法给出了不同准则之间评价信息合成的迭代算法^[7-8], 在该算法的基础上, Wang 等人提出了一种解析算法^[13], 不需要迭代即可直接算出多个准则评价信息的合成结果, 大大减少了计算量. 该解析算法可以表示如下:

$$k = \left[\sum_{n=1}^L \prod_{i=1}^M (m_{n,i} + \overline{m}_{H,i} + \tilde{m}_{H,i}) - (L-1) \prod_{i=1}^M (\overline{m}_{H,i} + \tilde{m}_{H,i}) \right]^{-1} \quad (6)$$

$$\overline{m}_H = k \left[\prod_{i=1}^M \overline{m}_{H,i} \right] \quad (7)$$

$$\tilde{m}_H = k \left[\prod_{i=1}^M (\overline{m}_{H,i} + \tilde{m}_{H,i}) - \prod_{i=1}^M \overline{m}_{H,i} \right] \quad (8)$$

$$m_n = k \left[\prod_{i=1}^M (m_{n,i} + \overline{m}_{H,i} + \tilde{m}_{H,i}) - \prod_{i=1}^M (\overline{m}_{H,i} + \tilde{m}_{H,i}) \right] \quad (9)$$

然后,再使用以下公式即可算出评价信息合成后的置信度:

$$\beta_H(A_i) = \frac{\tilde{m}_H}{1 - m_H} \quad (10)$$

$$\beta_n(A_i) = \frac{m_n}{1 - m_H} \quad (11)$$

最终,使用以下公式计算每个候选方案的效用 $u(A_i)$ ^[8]:

$$u(A_i) = \sum_{n=1}^L u(H_n) \beta_n(A_i) \quad (12)$$

由于 $\beta_H(A_i)$ 是表示不确定的置信度,即无知的信息,可以分配给任意一个等级 H_n , 当分配给 H_1 是得到最小值 $u_{\min}(A_i)$, 当分配给 H_L 是得到最大值 $u_{\max}(A_i)$, 取平均值 $u_{\text{avg}}(A_i) = (u_{\min}(A_i) + u_{\max}(A_i))/2$ 作为排序的依据,即可对评价结果进行排序.

应用上述的证据推理方法来建模集训队员的选拔评价问题. 首先要建立准则的树形层次结构, 显然,按照上述给定的准则,这是一个简单的二层决策问题,如图 2 所示,仅有一级准则 6 个,树根表示的是总体决策目标 (GR). 简单起见,假设对每个准则定义模糊评价等级的识别框架均为 $H = \{\text{很好, 好, 一般, 差, 很差}\}$.




图 2 选拔评价准则的层次结构

Fig. 2 Criteria hierarchy for selection and evaluation

为了更好的建模不确定的评价信息,把原来通过给定精确数据的评价方式转换为定性评价,即通过模糊等级进行评价,如:很好、好、一般、差、很差等. 通过领域专家给出每个准则的每个等级对应的具体表现值,如 PR 对应的五个等级分值为(800, 550, 400, 200, 0),这样就可以将上述定量评价转换为定性评价. 等权法^[14]得到了广泛的应用,但实际上不同评价准则可能具有不同权重,而在大多数情况下可能无法获取各个准则的权重信息,为了便于与传统方法做比较,利用各个队员在各个准则上的表现值来确定权重,即取各个准则的权重 $w_j = \sum_{i=1}^N x_{ij} / \sum_{j=1}^M \sum_{i=1}^N x_{ij}$, 计算得到六个准则的权重为(0.301 5, 0.168 6, 0.013 4, 0.120 4, 0.196 1, 0.2). 根据得到的权重信息,取利用上述证据推理方法的解析公式,即可得到

各个准则合成后的分布式评价信息(GR)及排序,如表2所示.

表2 使用证据推理方法对各个准则转换成定性评价信息后的合成结果

Tab.2 The aggregation results via ER approach after transformation of qualitative assessment on all criteria

| 队员 | 排名 | GR | 效用 |
|-----|----|---|---------|
| 候选1 | 1 | {(差, 0.008 8), (一般, 0.026 4), (好, 0.389 7), (很好, 0.575 1)} | 0.882 8 |
| 候选2 | 2 | {(差, 0.227 2), (一般, 0.077 8), (好, 0.241 4), (很好, 0.444 1), (H, 0.009 5)} | 0.725 6 |
| 候选3 | 3 | {(差, 0.008 1), (一般, 0.145 4), (好, 0.786 5), (很好, 0.06)} | 0.7246 |
| 候选4 | 5 | {(很差, 0.074 9), (差, 0.545 4), (一般, 0.147 1), (好, 0.187 7), (很好, 0.035 4), (H, 0.009 5)} | 0.390 8 |
| 候选5 | 4 | {(很差, 0.034 5), (差, 0.183 3), (一般, 0.304 4), (好, 0.127 8), (很好, 0.085 2), (H, 0.264 8)} | 0.511 4 |

与传统的方法不同的是,证据推理方法可以使用 (H, β_H) 来表示不确定或者无知的信息.如表2所示,候选2、候选4和候选5都存在不确定的信息,这是因为在前面定量评价的表中他们都包含了评价值为0的评价信息,这原本是不确定的评价信息.在出现评价信息缺失或不确定时,显然用证据推理方法的不确定或者无知的表述比传统方法用0来表示更为合理.与表1相比,表2上的候选4和候选5排序发生了变化,主要的原因是候选4比候选5更大的不确定性,按照上述效用的计算,候选5应该在区间 $[u_{\min}(\text{候选5}), u_{\max}(\text{候选5})]$ 上浮动,具有较大的可塑性,这样就能够提醒我们要对候选5进一步考查.此外,使用分布式的评价信息来表述候选队员的总体表现比传统的精确数值表示更具信息含量,比如,对于两个效用值一样的分布式评价 $\{(差, 0.4), (一般, 0.2), (好, 0.4)\}$ 和 $\{(一般, 1.0)\}$,被评价为 $\{(一般, 1.0)\}$ 虽然可以说明他的各方面表现都是一般而且很稳定,但参加比赛仅是一般表现是无法取得突破性的成绩的,相反被评价为 $\{(差, 0.4), (一般, 0.2), (好, 0.4)\}$ 的队员反而有更大发展的潜质,因为他只要克服一些“差”的因素完全有可能继续向“好”的方向再迈进.

3 结语

为了更好地进行ACM/ICPC集训队员的评价与选拔,针对传统评价队员方法所存在的不足,引入证据推理方法对队员进行评价与选拔,在传统定量评价的基础上,通过确立评价等级并为各个准则分配权重,将定量评价问题转换成定性评价问题.实际算例表明,证据推理方法所实现的队员评价不但有建模缺失数据和不确定信息的能力,而且分布式的评价具有更大的信息量,更加适合队员的选拔与评价.

在后续工作中,将进一步针对排名与评价等级的关系、各个准则权重的分配方法、不同OJ题目数量的等价转换等问题开展深入的研究,以期形成更合理的ACM/ICPC集训队员选拔评价方法.

参考文献:

- [1] ACM international collegiate programming contest (ICPC) [EB/OL]. [2012-06-13]. <http://cm.baylor.edu/welcome.icpc>.
- [2] Dempster A P. A generalization of Bayesian inference (with discussion)[J]. Journal of the Royal Statistical Society Series B, 1968, 30(2): 205-247.
- [3] Shafer G. A mathematical theory of evidence[M]. Princeton: Princeton University Press, 1976.
- [4] Yang J B, Singh M G. An evidential reasoning approach for multiple attribute decision making with uncertainty[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1994, 24: 1-18.
- [5] Yang J B, Sen P. A general multi-level evaluation process for hybrid MADM with uncertainty[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1994, 24: 1458-1473.
- [6] Yang J B. Rule and utility based evidential reasoning approach for multiple attribute decision analysis under uncertainty[J]. European Journal of Operational Research, 2001, 131(1): 31-61.

