

64-68

## 解释学习的效用问题

黄通 何志均 (浙江大学人工智能研究所, 杭州310027) TP18

## 摘 要

Explanation-Based Learning (EBL) is a powerful deductive learning method. But non-restricted learning would deteriorate the system's performance, which drives people to study on the utility of EBL. This paper starts with a definition of the utility, then analyzes the factors which influence the utility of a learned description and also introduces several strategies to improve the utility of EBL.

近年来,在机器学习领域,基于解释的学习引起了广泛的兴趣。解释学习是一种演绎学习方法,根据领域理论对训练实例进行解释,经过推广后获得新的知识。从可操作性的角度看,解释学习并没有学到真正新的知识,只是一种知识转换,它把原先不可操作的概念描述转换为可操作的目标概念描述,而使系统的性能得以提高。但原来的可操作性定义并没有考虑到解释学习的效用(utility)问题,人们发现这样的解释学习并不总能提高系统的性能,而是在大多数情况下会使系统的行为比未经学习时更差,这使得效用问题与不完善理论问题一样成为解释学习中令人关注的问题。本文从可操作性的定义开始,分析了解释学习的效用问题的原因,总结了效用评价所应考虑的因素,介绍了提高效率的几种策略。

## 一、解释学习及其可操作性

对于解释学习, Mitchell 给出了一个较为一般的定义<sup>[1]</sup>,如图1所示。

## 输入

- 目标概念:有关需学习概念的描述
- 训练实例:目标概念的一个例子
- 领域理论:一组规则和事实,能用来解释训

练实例是怎样满足目标概念描述的

- 操作性准则:定义在概念描述上的谓词,说明概念描述的表达式被系统使用的难易程度

## 输出

- 满足操作性准则的描述,它既是训练实例的推广,又是目标概念的特殊化

图1 Mitchell对EBL的定义

在这个定义中,概念对应于实例空间中的一个实例子集,同一概念可以有不同的描述。解释学习是针对某一概念进行的,系统原来对此概念的描述称为初始描述。初始描述往往是不可操作的,学习的目标是得到可操作的概念的目标描述。学习系统内部具有背景知识,称为领域理论,它是对某一领域的一个较完善的描述。环境提供一个训练实例,解释学习系统利用领域理论中的知识,解释为什么这个实例属于概念对应的实例子空间。解释的结果构成了训练实例满足目标概念的一个证明。然后,这个解释被推广,以适用于更大范围的实例集。这个被推广的解释必须满足一定的可操作性准则,这就构成了概念的目标描述。因此,解释学习可以

看成在概念描述空间中的搜索过程，它从概念的不可操作的初始描述开始，直至搜索到可操作的目标描述。

可操作性准则是判别能否成为目标描述的标准，可操作性准则决定了解释学习系统学到知识的正确性和质量，因此可操作性的定义在解释学习系统中是非常重要的。

概念描述的可操作性一般定义为此概念描述被用来识别实例时的迅速程度。如果系统能利用此概念描述迅速地判定某一实例是否属于此概念对应的实例子空间，则这个描述是可操作的。这个定义实现在一般系统中，往往表现为概念描述是否只包括最基本或较基本的描述基元。例如，在Winston的功能结构系统中，可操作的描述定义为只由结构描述项构成的项<sup>[2]</sup>。在符号积分系统LEX2<sup>[1]</sup>中，可操作的描述定义为用基本的演算项（例“sin”，“s”等）或从它们直接导出的项表达的描述。

在下一节，我们将会看到，解释学习系统仅仅依靠这样的可操作性定义是不够的，它没有全面地考虑学习的计算效应，反而会使系统的性质下降。

## 二、解释学习的效用问题

这里我们首先给出解释学习的效用定义。

**定义1** 解释学习的效用是指解释学习系统经过学习以后，系统的执行性能提高的程度。

我们知道解释学习实际上并没有学到真正“新”的知识，而只是一种知识的转换。知识转换的目的是得到可操作的描述，以使系统的执行性能得以提高，因此解释学习的效用是评价一个解释学习系统的重要标准。

但是，实际上图1定义的标准解释学习系统中，学习并不能改进系统的性能，反而会使系统性能降低，即具有负的效用，这是因为虽然操作性准则保证每个学习到的描述能被高效地测试是否满足，但它并没有考虑到这种测试多次出现后的积累代价。也就是

说，这种操作性准则并不能保证学习到的描述能够改进系统的性能。

这个现象在许多解释学习系统中被发现，而且性能的降低也不仅是发生在特殊情况下，而是一般情况下亦如此。例如在SOAR系统中，通过组块（chunking）机制得到的新的产生式并不都能改善系统的性能，存在某些昂贵的组块，会使系统性能降低<sup>[3]</sup>。在宏操作系统STRIPS中，也有同样的现象。

STRIPS也是典型的解释学习系统，它建立和推广“机器人规划”。机器人规划用一操作序列来代表。给出一个目标以后，系统执行搜索以寻找一列操作能把初始状态变为目标状态。这个操作序列可被组合成为单个操作，叫做宏操作。可以证明STRIPS的这种宏操作学习和标准的解释学习是等价的。

我们针对宏操作系统，分析解释学习对问题求解时的搜索过程的影响。

首先，学习改变了搜索空间被遍历的次序。以前成功使用的操作序列被记录成为宏操作，它比其它操作序列被得到优先考虑。学习的这种影响被称为重排效果。

其次，学习使得路径费用降低。通过宏操作到达一个状态的费用比起逐一测试相应的基本操作序列而到达此状态的费用低。但是，这与重排效果和使用其它编译方案的效果相比，影响甚小。一般地，匹配一个宏操作的前提和按次序匹配相应基本操作的前提，代价几乎没什么差别。

学习的第三个影响，是冗余度增加，这使得系统的性能降低。冗余度的增加首先来源于学习到的宏操作重复了一部分原始搜索空间。如果在某一状态所有宏操作都不能用，系统只能使用基本操作，测试宏操作的工作就成了重要劳动。另外，学习产生的宏操作相互间也会有大量的重复。例如，一个宏操作由基本操作op1和op2构成，另一宏操作由op1和op3构成，那么这两个宏操作的部分前提条件是相同的。因此，基本操作op1的前提可能会被一次又一次地重复测试。图

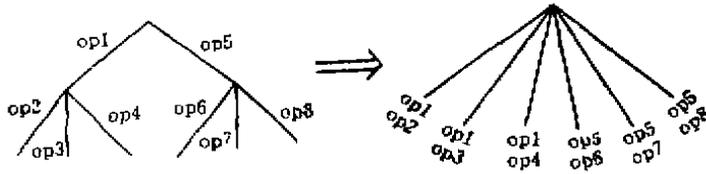


图2 宏操作所带来的冗余性

2反映了所有操作序列转化为宏操作时所产生的冗余性。一般地，由于冗余度增加，系统的性能将比没有学习的时候更差。

宏操作学习系统的经验表明，当一小部分学习到的宏操作能够解决大部分问题时，宏操作学习的效用最高。在这种情况下，重排的正效果最大，而冗余性的负效果最小。亦即学习到的宏操作达到一定的使用频率，学习才能获得正的效用。

这个从宏操作学习系统得到的经验适用于一般的解释学习系统，因为，标准解释学习系统虽然与宏操作学习系统有着不同的描述，但它们工作的过程却非常相似，两种方法可以建立对应的关系。

随着计算机性能的不断提高和并行技术的发展，解释学习的效用问题可以在一定程度上被缓和，但并不能得到完全解决。因为如果解释学习对学到的描述在数量和大小都不可限制，则学到描述的数量和大小都将不断增长，匹配的计算代价也将迅速上升，而使系统的性能不断下降，最终变得一无所用。

学到的描述相当于宏规则的前提部分，描述的数量依赖于搜索空间中被认为有用的路径数，因为每个有用的路径被转化为不同的描述，在最坏的情况下，每条路径都被认为是有用的。而描述的大小依赖于解释中用到的规则数目，一般来说，学到的描述往往是很大的，一个简单的棋类领域，学习到的描述可以拥有多达几百个项。

匹配的代价将随着被匹配规则的大小和数目的增长而迅速上升。包含存在量词的台取描述的匹配已是一个NP完全问题，表达能

力强的描述，其匹配复杂度会更高。

因此，解决解释学习的效用问题，应该在根本上依靠学习机制的改进和完善，依靠对效用的更加深刻的理

解。首先应找到解释学习系统中效用的客观而准确的评价准则。

### 三、解释学习中效用的评价

图1所示的标准解释学习系统并没有考虑到效用的问题。Keller<sup>[4]</sup>认为传统解释学习的可操作性定义是不全面的，必须加以改进以包含效用的评价。他给出的可操作性定义如下：

**定义2** 概念描述的可操作性包括下列两点要求：

- 能用性 (usability)：能够被学习系统用来识别它描述的概念实例。
- 效用：当学习系统使用该描述时，系统的执行性能应该得到改善。

是否把效用归在可操作性的定义下，或是独立地作为解释学习中的一个特性来处理并不重要。关键是要进一步理解解释学习的效用问题并加以妥善解决。现在我们给出单个概念描述的效用定义：

**定义3** 概念描述的效用是指学习系统在拥有此描述时与没有此描述时相比，系统执行性能的平均改善程度。

为了评价某一概念描述的效用而每次都进行试验运行是既不可取也不可能的，必须寻找较为简单有效的效用评价方法，在这一方面，人们已作了许多努力。

在PRODIGY系统中利用解释学习方法来获取中间结局法问题求解的控制知识，其解释学习的效用由下面的开销/收益公式来计算<sup>[4]</sup>。

$$\text{utility} = (\text{AvrSavings} \times \text{ApplicFreq}) - \text{AvrMatchCost}$$

其中AvrSavings是应用此学到知识消除相应搜索后所带来的平均时间节省，App-

licFreq是学到知识接受测试能够成功应用的概率。AvrMatchCost是匹配此知识的平均时间开销。其中AvrMatchCost和Applic-Freq比较容易测定,而AvrSaving的确定比较困难,这里只是平均节省的估计。

学到一条控制知识后,PRODIGY根据产生此规则的训练实例来作知识效用的初始评价。只有效用为正时,这条控制知识才能放入到控制知识集中。在系统运行过程中,PRODIGY还及时修正知识效用的估计,并及时消除效用变为负值的知识。

对于不同的解释学习系统,由于学习的目标、学习策略等各不相同,应该有各自不同的效用评价方法。一般来说,解释学习系统中学到描述的效用评价方法应该考虑到下列六个因素。

**1.效用的目标** 一般的解释学习系统只考虑与时间性能相关的效用。但在某些场合,系统可能更关心空间性能的效用问题。如果系统的存贮空间非常紧张,且学到的描述过大、占据太多空间,则效用就较低,须限制这类知识的学到。

**2.系统的问题求解策略** 不同的系统有不同的问题求解策略,就应有不同的效用评价方法。例如采用深度优先搜索的系统,其重排效果比采用广度优先搜索的系统要大一些。而对于采用最佳优先搜索的系统,学习系统的效用评价策略应该充分考虑问题求解时优先度评价策略,以使学到知识具有尽量高的优先度。

**3.系统的知识表达** 不同的系统,其知识表达方案各有所侧重,对于相同的描述项,其识别的难易程度是各不相同的。在同一系统中,对于不同的描述项,系统识别的难易程度也不同。一般来说,由容易识别的描述项组成的概念描述,匹配代价低因而效用较高。

**4.概念描述本身的特性** 一个概念可有多种概念描述方式。概念描述本身包含描述项的数目、包含描述项的种类等,直接影响

该描述的效用。

**5.系统已有的知识** 系统已经拥有的知识集的大小和内容,直接影响学到描述的效用。如果已有类似的描述存在,那么学到描述的加入就只会引起冗余,因而学到描述的效用就相对较低,因此要求效用评价方法具有冗余检查的能力。

**6.系统所要解决的问题** 上面已经提到,当小部分宏操作能解决大部分的问题时,系统的效用最高。学到描述的效用与系统要处理的问题有关,与大部分系统碰到的问题无关的描述,效用显然不高,因此把问题类型作为评价效用的一个因素来考虑是有益的。

全面地考虑这六个因素似乎不太可行,因为如果这样,效用评价本身就成为沉重的负担。尤其是最后两个因素,效用的值随着问题类型不同、知识库的变化而变化,亦即效用评价应该是动态地进行的,这更增加了效用评价本身的代价,需要进一步的研究以寻找更切实可行的、有效的效用评价方法。

#### 四、提高解释学习效用的策略

为了提高解释学习的效用,已经提出很多种策略。一般来说,这些策略可化为三种,限制学到的描述进入知识库、限制学到的描述的使用和遗忘机制。

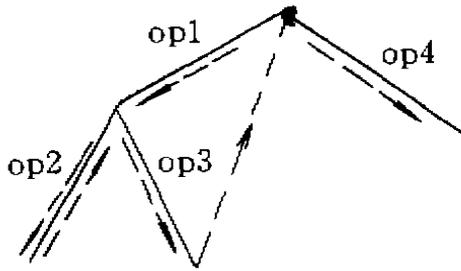
##### 1.限制学习机会

学习机会的限制意味着不是所有学习到的概念描述都能进入知识库,而必须经过选择。一种最简单的方法是限制描述的大小,只需设置一个描述大小的上限即可。

在[6]的宏操作学习系统中,利用一种完美因果性准则,只有由那些依次具有强因果依赖关系的基本操作序列构成的宏操作,才被允许进入知识库。当然,一些不具备完美因果性的操作序列,可以抽出一些无关的基本操作而成为具有完美因果性的宏操作。实际上,这种完美因果性准则降低了学习到的宏操作之间的冗余度,而使学习系统表现出较高的效用。

## 2. 限制学到的描述的使用

问题求解器根据一定的原则, 限制某些低效用描述的使用, 以提高系统的性能。一种极端的做法是, 学习到的描述只有能够完全地解决当前问题时才可使用。也就是说, 问题求解不允许回溯到搜索空间中中学到描述所在点的祖先去 (如图3所示), 也不允许利用学到的描述去解决一个子问题。这样, 虽然牺牲了许多学到的描述被成功使用的机会, 但完全避免了学到的描述被不成功使用的情况。



(箭头表示搜索顺序)

图3 空操作op1的不成功使用情况

另一种方法是精化问题求解的控制策略。匹配器在选择可用的规则时, 考虑学到描述的匹配代价, 使得效用较低的学到的知识被避免使用。

为了考虑问题类型对学到描述效用的影响, 可以由学习器在提供学到描述的同时, 提供一个相应的函数, 供问题求解器针对不同的问题分别计算描述的效用, 以决定是否使用这个描述。

## 3. 遗忘机制

正如记忆在智能行为中占有重要的地位, 遗忘的作用也是不可忽视的。人总是不自觉地忘掉某些东西, 而把记忆的能力和空间留给更加重要的信息。从一定程度上说, 没有遗忘也就没有记忆。这个观点反映到解释学习中便是, 把所有学到描述都永远地完

全保留着是不合理的, 必须把其中与问题不相关的, 效用低的一些描述忘掉。遗忘的含义是广泛的, 不仅包括明显的删去某些知识项, 也包括调整、优化知识库的知识结构, 使整个知识库具有更高的效用。但根据怎样的准则来选择所要忘记的描述呢? 实际上这又是效用的评价问题。

## 五、结束语

效用问题是解释学习中的热点之一。本文从效用的定义开始, 介绍了解释学习中效用问题的提出, 影响效用的因素, 以及提高效用的各种策略。虽然人们已对解释学习的效用问题作了许多研究, 但效用问题远未得到完全的解决, 尚有待于进一步的研究。解释学习的效用问题的解决, 不但对于机器学习领域, 而且对于整个人工智能领域都具有重要的意义。

## 参考文献

- [1] T.M.Mitchell, R.M.Keller, and S.T. Kedar-Cabelli, *Explanation-based generalization: an unifying view*, *Machine Learning*, 1(1), 1986
- [2] P. H. Winston, T. O. Binford, B. Katz and M. Lowry, *Learning physical descriptions from functional definitions, examples and precedures*, *AAAI-83*, pp.433-439, 1983
- [4] Richard M. Keller, *Defining Operatinality for Explanation-Based Learning*, *AAAI-87*, pp.482-487, 1987
- [5] Steven Minton, *Quantitative Results Concerning the Utility of Explanation-Based Learning*, *AI 42*, pp.363-391, 1990
- [6] Seiji Yamada & Saburo Tsuji, *Selective Learning of Macro-Operators with Perfect Causality*, *IJCAI-89*, pp. 603-608, 1989